

# TEHNOLOGII AVANSATE PENTRU PROCESAREA IMAGINILOR BIOMEDICALE, UTILIZÂND ALGORITMI DE RECUNOAȘTERE A FORMELOR

## STUDIU DE CAZ: AFECȚIUNI ALE FICATULUI

**Dragoș Nicolau**

dragos@ici.ro

**Dragoș Barbu**

dbarbu@ici.ro

**Laura Ciocoiu**

ciocoiu@ici.ro

**Dragoș Smada**

dsmada@ici.ro

Institutul Național de Cercetare Dezvoltare în Informatică - ICI, București

**Rezumat:** Lucrarea de față prezintă un sistem interactiv bazat pe algoritmi de analiză, segmentare și recunoaștere de organe în imaginile obținute prin rezonanță magnetică (MRI), ultrasunete (US) sau tomografie computerizată (CT). Scopul segmentării imaginilor este de a grupa clusterele de pixeli în regiuni continue, de exemplu regiuni care corespund suprafețelor individuale, obiecte sau părți naturale ale obiectelor. Segmentarea este utilizată pentru recunoașterea organelor, privite ca obiecte, estimarea limitelor de întâlnire între organe, în cazul mișcării sau a sistemelor stereo, compresia imaginilor, editarea de imagini sau a căutării imaginilor în baze de date.

**Cuvinte cheie:** analiză, imagine medicală, segmentare, compresie, reconstrucție.


**Abstract:** This paper presents an interactive system based on algorithms for analysis, segmentation and recognition of organs obtained from magnetic resonance images (MRI), ultrasounds (US) or computed tomography (CT). The purpose of image segmentation is to group clusters of pixels in the continuous regions, for example, regions corresponding to individual surfaces, natural objects or parts of objects. Segmentation is used for recognition bodies, viewed as objects, estimating the limits of encounter between organs or systems in case of motion or stereo systems of images compression, image editing, or the search for images in databases.

**Keywords:** analysis, medical image, image segmentation, compression, reconstruction.

## 1. Introducere

Lucrarea de față prezintă un sistem pentru procesarea imaginilor biomedicale, utilizând algoritmi de recunoaștere a formelor în vederea obținerii unui diagnostic atât local, cât și în Internet, îmbutățind astfel actul medical. Imaginile biomedicale sunt obținute prin achiziționarea, în timp real, a semnalelor obținute prin rezonanța magnetică (MRI), ultrasunete (US) sau tomografie computerizată (CT).

Prelucrarea digitală a imaginilor biomedicale reprezintă un domeniu de sine stătător. Acest domeniu are la bază o teorie matematică riguroasă, bine pusă la punct, dar implementările sunt mari consumatoare de resurse, în special pentru utilizarea în timp real a informațiilor extrase din imagini. Imaginea este o descrierea variației intensității luminii pe o suprafață. O imagine este deci un semnal bidimensional; prin urmare, prelucrarea imaginilor poate fi considerată și o ramură a prelucrării digitale de semnal.



Achiziția și prelucrarea imaginilor biomedicale presupune: prelucrarea, compresia și stocarea imaginilor, restaurarea și ameliorarea imaginilor prin corecții geometrice, radiometrice, ajustări de contrast, filtrarea zgomotului etc., fotogrametrie, adică măsurători ale unor obiecte, fenomene făcute pe baza unor imagini, recunoașterea formelor (pattern matching, shape recognition, face recognition), vederea artificială (computer vision, robot vision), inteligența artificială, sinteza de imagini, imagini generate de calculator.

Inteligența artificială și prelucrarea imaginilor sunt domenii ce se întrepătrund. Un număr important din algoritmi performanți folosiți la prelucrarea imaginilor utilizează metode și tehnici din domeniul inteligenței artificiale cum ar fi: rețele neuronale, arbori de decizie, K-Nearest Neighbor (cel mai apropiat vecin de distanța K), Vectori Suport Mașină, clasificatori parametrici. Pe de altă parte, inteligența artificială presupune zona de intersecție și construirea de sisteme capabile să realizeze funcții ale intelectului uman: învățarea prin experiență, înțelegerea limbajului natural, utilizarea unui raționament pentru rezolvarea unor probleme sau luarea unor decizii. Toate aceste presupun însă și acumularea unei anume cantități de informație (bază de cunoștințe, informații din mediu, etc.). Această informație este preluată de sistemele inteligente prin sensori și crează o imagine a mediului în momentul preluării datelor (**snapshot**). Din imaginea astfel obținută trebuie extrase informațiile utile. Toate acestea țin de domeniul vederii artificiale (Computer Vision, Robot Vision); este o disciplină comună atât prelucrării de imagine, cât și inteligenței artificiale și încearcă să răspundă la următoarele întrebări: ce informație trebuie extrasă din imaginile preluate, cum poate fi extrasă această informație, cum se reprezintă aceasta, cum poate fi utilizată.

O structură generală a unui sistem de achiziție și procesare este descrisă în figura de mai jos:




Figura 1. Structura unui sistem de achiziție / procesare imagine

## 2. Achiziția imaginilor

Imaginile, de mari dimensiuni, captate de la aparatura medicală - RMN (rezonanță magnetică), CT (tomografie computerizată) sau ultrasunete depind de aparat. Datorită dimensiunilor mari ale imaginilor, este necesară segmentarea și reprezentarea imaginilor în 3D obținute la UltraSunete (US) (interpretarea volumului rinichiului, pancreasului, ficatului), datelor de la Rezonanța Magnetică și crearea hărților pentru Imaginea Difuziunii Ponderate a Rezonanței Magnetice (Diffusion Weighted Imaging (DWI)) precum și imagini structurale RMI.

## 3. Procesarea imaginii

Procesarea imaginii achiziționate constă în: **preprocesare** (filtrarea, restaurarea, segmentarea, egalizarea histogramei, extragere contur), **extragerea informațiilor utile**, **analiza, interpretarea și utilizarea informațiilor**.

### 3.1 Preprocesarea

Operațiile de preprocesare se efectuează asupra imaginilor achiziționate. Aceste operații au rolul de a elimina zgomotele sau informațiile inutile din imagine sau sunt operații de restaurare. Astfel de prelucrări sunt necesare pentru a îmbunătăți atât timpii de execuție cât și rezultatele diverșilor algoritmi (clasificare, recunoaștere forme, recunoaștere fețe umane, etc.). Operațiile de preprocesare cuprind: filtrarea, restaurarea imaginilor, segmentarea, obținerea histogramei, extragerea conturului.

**Filtrarea.** Operația de filtrare este utilizată pentru eliminarea zgomotelor și pentru evidențierea muchiilor.

**Restaurarea imaginilor.** La ieșirea blocului de achiziție a imaginilor, rezultatul poate fi o imagine distorsionată. Aceste erori se pot corecta printr-o operație de reeșantionare: pentru aceste tipuri de distorsiuni geometrice se pot determina relațiile matematice necesare corecției și, folosind aceste relații, se calculează valoarea fiecărui eșantion (pixel) din noua imagine pe baza unui număr de eșantioane din imaginea distorsionată. Aceste operații de restaurare se folosesc, în general, pentru a corecta erorile din zona de interes.

**Histograma** unei imagini este o funcție care indică câți pixeli are un anumit nivel de gri. De obicei, numărul de nivele de gri este 255 (un pixel este reprezentat pe un byte). Imaginea  $f(g) = p$ , unde:  $g$  = nivel de gri,  $g$  între 0 - 255;  $p$  = numărul de pixeli ce au valoarea  $g$ . La o analiză a histogramelor diverselor tipuri de imagini, se constată că, de obicei, o imagine are mai multe nivele de gri și prezintă două maxime locale. Folosind această caracteristică se poate face o segmentare cu prag a imaginii inițiale, alegând pragul ca fiind, de regulă, minimum local dintre cele două puncte de maxim. Astfel, pixelii cu nivel de gri mai mic decât pragul ales pot fi considerați ca fiind de exemplu fundalul (li se atribuie valoarea corespunzătoare negrului), iar cei pentru care nivelul de gri este mai mare decât pragul sunt pixelii obiectului. Datorită iluminării slabe, neuniforme sau situată la valori în jurul pragului de sensibilitate a senzorului, pot rezulta imagini cu contrast scăzut, imagini pentru care pixelii nu iau valori în întreaga gamă de nivele de gri. Pentru a corecta aceste defecte se folosesc de regulă: **egalizarea histogramei** sau extinderea liniară la întreaga gamă de nivele de gri. Prin aceste operații, unui pixel din noua imagine  $i$  se atribuie o valoare de gri calculată pe baza unei funcții (liniare sau exponențiale), funcții ce se determină pe baza imaginii inițiale.

### 3.2. Procesarea imaginii obținută prin captare

**Segmentarea** este un proces de partiționare a imaginii digitizate în submulțimi prin atribuirea pixelilor individuali la aceste submulțimi (denumite și clase), rezultând obiecte distincte din scenă. Algoritmii de segmentare au la bază, în general, două principii: discontinuitate, având ca principală metoda *deteția conturului* și similitudine, *cu metoda pragului și metoda regiunilor*.

*Deteția contururilor.* Un operator de contur este un operator matematic construit pentru a determina existența unui contur local în funcția imagine. Modulul furnizat de acești operatori caracterizează severitatea schimbării nivelului de gri de la o vecinătate la alta a imaginii. Cei mai simpli și cei mai rapizi asemenea operatori de deteție a conturului se bazează pe utilizarea măștilor de convoluție spațială care parcurg întreaga imagine pixel cu pixel, calculând o imagine proporțională cu discontinuitatea existentă în porțiunea de imagine corespunzătoare poziției curente a măștii.

*Metoda pragului.* Pentru aplicația privind imaginile biomedicale, datorită diferențelor semnificative între nivelele de gri ale pixelilor aferenți obiectului și respectiv fondului, criteriul de segmentare care poate fi folosit este valoarea nivelului de gri. Metoda care se utilizează în acest caz, foarte rapidă, este denumită *segmentare cu prag* și ea implementează o transformare punctuală simplă. Pixelul din punctul de coordonate  $(i,j)$  este etichetat ca fiind pixel obiect dacă valoarea sa  $f(i,j)$  este mai mare decât un prag. Obținerea unor bune rezultate cu acesta metodă depinde de modalitatea de alegere a pragului, care poate fi o valoare pentru o imagine dată sau o funcție netedă dependentă de poziția pixelului curent.

*Metoda regiunilor.* Segmentarea iterativă sau segmentarea prin tehnici de relaxare este o metodă care folosește procedee probabilistice de clasificare, în paralel și în fiecare punct, la fiecare iterație. Procesul de relaxare este conceput pentru a aduce nivelele de gri spre capetele opuse ale scării de gri astfel încât pragul  $T$  să devină o problemă banală. Acest tip de procesare este fundamental în analiza automată a scenelor și în recunoașterea de modele, unde scopul principal este de a extrage în mod automat date detaliate despre conținutul imaginii la nivel obiect. Deci, obiectivul tehnicii de segmentare este de a partiționa o imagine dată în regiuni sau componente.

**Extragerea conturului.** Există mai mulți operatori pentru extragerea conturului. Ca referință, în multe cărți de specialitate sunt prezentați trei operatori clasici: Sobel, Kirsch și pseudo-Laplace. Acești operatori sunt de tipul *fereastră glisantă*. Extragerea conturului prin acești operatori constă într-o succesiune de convoluții dintre imaginea inițială și nucleul (masca) operatorului. Opțional, pentru fiecare operator, la finalul convoluțiilor se poate face o segmentare cu prag pentru a obține o imagine binară a hărții muchiilor.

**Extragerea informațiilor utile.** Identificarea obiectelor dintr-o imagine este de multe ori dificil de realizat. O metodă de a simplifica această operație este digitizarea imaginilor în nivele de gri și apoi aplicarea unor operatori morfologici. Fundamentele prelucrării morfologice a imaginilor au un suport matematic riguros, însă în practică acest grad de sofisticare nu este întotdeauna necesar. Marea majoritate a algoritmilor din această categorie sunt operații simple. Cei mai folosiți operatori morfologici sunt *erodarea și dilatarea*. O imagine binară conține obiectul de interes și fundalul (ceea ce nu interesează); de exemplu fundalul este alb și obiectul este negru. Prin erodare fiecare pixel al obiectului care atinge fundalul este transformat în pixel-fundal. La dilatare fiecare pixel din fundal, aflat în contact cu obiectul, este transformat în pixel-obiect. Astfel, erodarea face obiectele mai mici și poate sparge un obiect mai mare în mai multe obiecte mici; dilatarea face obiectele mai mari și poate uni mai multe obiecte.

**Detectia mișcării** și urmărirea diferitelor obiecte aflate în mișcare este o operație frecvent utilizată în sistemele pentru obținerea de imagini biomedicale. Nu există, în general, o abordare generică, ci algoritmi sau soluțiile găsite sunt de obicei particulare problemei. În principiu, se face comparație / diferență între cadre succesive și / sau între cadrul curent și un cadru referință. Una dintre problemele ce apar este separarea obiectului aflat în mișcare de restul scenei (denumit generic fundal). O posibilă soluție ar fi: *calculul diferenței între cadre; segmentare cu prag; filtrarea zgomotelor; crearea unei imagini a mișcării*.

**Recunoașterea formelor** reprezintă o modalitate des folosită pentru a extrage informațiile din imaginile achiziționate. Recunoașterea formelor constă într-o clasificare și / sau o descriere a conținutului imaginii. Clasificarea constă în atribuirea unei forme necunoscute din imaginea preluată la o clasă dintr-un set predefinit de clase; operația de clasificare va produce la ieșire o nouă imagine care reprezintă o hartă a obiectelor aflate în scenă. În noua imagine, valorile pixelilor reprezintă de fapt codurile asociate claselor corespunzătoare. Un pas important în clasificarea automată este selecția caracteristicilor, aceasta deoarece componentele vectorului de caracteristici presupune prezența unei cantități destul de mari de informație. Această selecție este o problemă dependentă de numărul de clase și de formele analizate. Un clasificator conține, în general, trei module: modulul de *clasificare propriu-zis*, un modul de *învățare* (presupune prezența unui set de eșantioane / imagini de antrenare) și un modul de *selecție și extragere a caracteristicilor*. Setul de antrenare poate conține de exemplu o bază de date cu diferite caracteristici ale obiectelor ce pot apare în scenă (de exemplu, obiecte spectrale sau geometrice). Învățarea presupune existența acestui set de antrenare, set ce cuprinde eșantioane pentru care se știe apartenența la clase; prezența setului de antrenare este necesară în cadrul clasificării supervizate.

Algoritmul cuprinde următorii pași: normalizarea, estimarea orientării locale normalizată, estimarea frecvenței locale, estimarea regiunii de măști (regiunea de măști este obținută prin clasificarea fiecărui bloc din imaginea normalizată într-un bloc recuperabil sau nerecuperabil) și filtrarea (un grup de filtre Gabor, care sunt acordate pe sensul și frecvența creștăturilor, este aplicat pentru îmbunătățirea imaginii).

În continuare, sunt prezentate modulele componente ale sistemului de prelucrare a imaginilor în vederea recunoașterii neuniformităților pentru diferite organe.

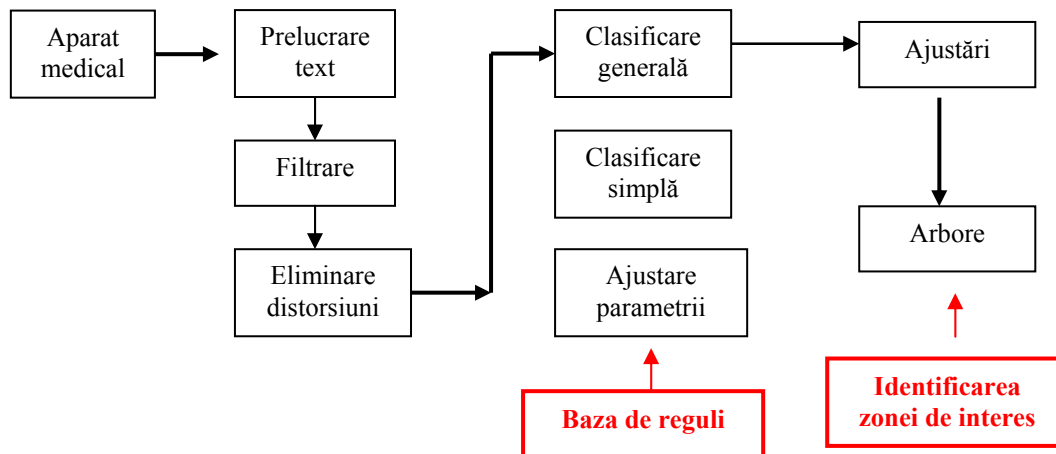


Figura 3. Schema funcțională

## 4. Implementarea algoritmilor de recunoaștere forme

**a. Captarea (încărcarea) imaginii** constă în citirea fișierelor de tip BMP cu 24 de biți per pixel.

Funcția principală destinată încărcării în memorie a imaginii citește antetul fișierului de tip BMP, din această operație rezultând lungimea și lățimea imaginii. Se alocă apoi un vector de octeți egal cu de 3 ori produsul dintre susnumitele dimensiuni, vector care conține informația cromatică, fiecare triplet de octeți memorând valoarea corespunzătoare nuanței de roșu, verde, respectiv albastru pentru un anumit pixel. Parcurgerea acestui vector se face cu ajutorul unei adresări către BYTE (octet), care este inițializat cu valoarea adresei primului octet. Dacă, de exemplu, lățimea imaginii este =  $W$ , pentru a fixa acest pointer la pixelul de coordonate  $(x, y)$ , offsetul față de începutul vectorului al acestui pointer va fi de  $3*(y*W+x+1)$ .

Datorită dimensiunilor mari ale imaginilor MRI (rezonanță magnetică), CT (tomografie computerizată) sau ultrasunete, sistemul va dezvolta instrumente inovative pentru segmentarea și reprezentarea imaginilor în 3D obținute la UltraSunete (US) (interpretarea volumului rinichiului, pancreasului, ficatului), datelor de la Rezonanța Magnetică și crearea hărților pentru Imaginea Difuziunii Ponderate a Rezonanței Magnetice (Diffusion Weighted Imaging(DWI)) precum și imagini structurale MRI; acest instrument va include și funcționalitatea semi-cantitativă a măsurării leziunilor. În anexă, sunt exemple de imagini biomedicale pentru diferite organe.

**b. Crearea măștii pentru filtrul de culoare** constă în analiza cromatică a imaginii și înlocuirea culorilor, într-o marjă predefinită, în nuanțe de alb și negru.

**c. Modulul de refacerea imaginii** se utilizează pentru a îmbunătăți procesul de recunoaștere a unei zone de interes existente; acesta constă în 3 faze:

- **îmbunătățirea texturii**, adică refacerea porțiunilor din imagine, are la bază tehnologia filtrelor. Algoritmul folosit utilizează *filtrul de mediere*, pentru fiecare vecinătate de pixeli (de obicei 3x3, dar și 5x5 sau 7x7); pixelul central se înlocuiește cu o combinație liniară a pixelilor din vecinătate. *Medierea cu prag* realizează compararea fiecărui pixel cu media vecinilor lui, medie ce poate fi calculată printr-o convoluție cu masca  $M_4$ . Modificarea pixelului curent se face doar dacă este îndeplinită o condiție de prag.

- **refacerea conturului** este operația de „netezire a conturilor” obiectelor din imagine în condițiile păstrării aspectului lor; algoritmul are efecte benefice nu numai asupra ratei de recunoaștere, ci și asupra factorului de compresie posibil, dacă se are în vedere stocarea


imaginilor scanate. Se lucrează pe vecinătăți pătratice ( $k \times k$ ), și anume pixelii negri din vecinătatea pixelului curent; submulțimile de pixeli din vecinătatea pixelului curent și pixeli de colț. Algoritmul se aplică succesiv pentru pixelii negri, apoi pentru cei albi, până când nu se mai constată modificări pe imagine sau, pentru a limita durata operării, după un număr predeterminat de pași.

- **ameliorarea contrastului unei imagini** se bazează pe operații asupra histogrammei imaginii cu contrast scăzut, pentru care se poate remarca utilizarea neeficientă a gamei dinamice posibile pentru nivelele de gri, de la cel mai întunecat nivel de gri la nivelul de gri al celui mai luminos pixel. Transformarea se realizează prin construirea unei funcții de scalare, care să transforme luminozitatea pixelilor din imagine; nivelul de gri, care este "bine reprezentat" în histograma inițială, va fi distribuit, prin egalizare.

**d. Modulul de segmentare a imaginii** realizează împărțirea unei imagini în suprafețe dreptunghiulare sau circulare de dimensiuni mai mici, denumite subferestre (subdomenii); acest lucru este util la găsirea locului unei zone de interes în cadrul imaginii. Funcția de lucru preia drept argumente: adresa vectorului ce conține informația cromatică a imaginii de partiționat, lungimea imaginii de partiționat, lățimea imaginii de partiționat, lungimea segmentului de tip partiție, lățimea segmentului de tip partiție. Valoarea de retur este un vector de pointeri, fiecare din ei memorînd adresa de unde începe zona de memorie a unei partiții.

Model de implementare a unei segmentări "pipeline" este următorul:

0	Imaginea inițială, cu inimă, plamâni, cavitate toracică
Rest_0	Imaginea inițială, fără inimă, plamâni, cavitate toracică
1	Abdomen
Rest_1	Abdomen, fără ficat, vase hepatice, splină
2	Zona ficat, vase hepatice, splină
Rest_2	Zona ficat, vase hepatice, splină, fără vezică biliară
3	Splină
Rest_3	Splină, fără "aerul" din jur
4	Zona: ficat, vase hepatice
Rest_4	Zona: ficat, vase hepatice, fără "aerul" din jur
5	Ficat
Rest_5	Ficat, fără vase hepatice
6	Tumoare hepatică
Rest_6	Tumoare hepatică, fără "aerul" din jur



#### 4.1. Modelarea procesului de segmentare se realizează în mai multe faze:

- **detectarea unei zone de interes** ce constă în compararea imaginii ce reprezintă zona de interes cu porțiuni ale imaginii de analizat; compararea unui pixel dintr-un segment (subferestră a imaginii analizate) cu a unuia din imagine (se face pe baza mediei cromatice a celor 8 pixeli din jurul fiecărui pixel analizat). Primul pas în detectarea zonei de interes constă în detectarea texturii. Se consideră că imaginea de analizat este normală, dacă compararea se înscrie în marja de eroare prestabilită. Dacă imaginea nu se regăsește în baza de imagini ca textură ideală, se recurge la **baza de reguli**.

Datorită variațiilor biologice, modelarea complet automată nu poate fi realizată [4,5]. Prin urmare, pentru utilizarea clinică pare realistă dezvoltarea unui sistem care să permită asistarea interactivă a proceselor de segmentare [4-8], constrângerea fiind minimizarea interacțiunilor.

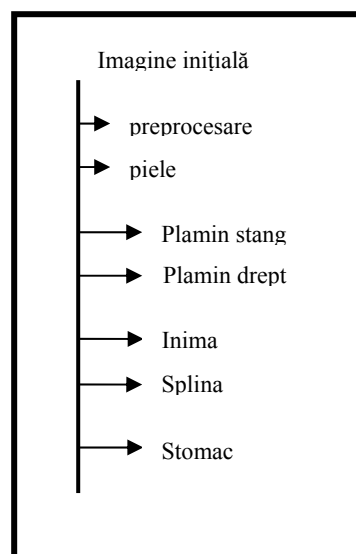
Așa cum a subliniat recent în [5], asistarea procesului de segmentare constă în utilizarea unui sistem care să permită construirea unei „conducte de operatori” interactivi și parametrizați de prelucrare a imaginii, care oferă, în cele din urmă, un model pentru un anumit obiect de interes din imaginea de intrare inițială. Acest lucru înseamnă că sistemul va fi capabil să gestioneze combinația de operatori selectați de utilizator. Sistemele de flux de date, cum ar fi KHOROS, SCIRun sau ITK sunt exemple în care această strategie este adoptată.

Având în vedere specificitatea diferitelor structuri medicale, este foarte dificilă determinarea unei „conducte” unice de operatori care să permită segmentarea simultană a tuturor structurilor de interes, pornind de la imaginea inițială. Din acest motiv, pentru o modelare completă se ia în considerare o abordare secvențială, caz în care structurile ierarhice sunt segmentate una după alta, fiecare având adaptate propriile sale secvențe de prelucrare. Într-un astfel de caz sunt construite mai multe „conducte” specifice ale operatorilor, acest fapt conducând la un flux complex de date.

De exemplu, utilizatorul va începe segmentarea pulmonară din imaginea inițială, apoi se continuă segmentarea pentru următorul organ, inima (de asemenea, din imaginea inițială), și așa mai departe, până când toate structurile sunt modelate.

Sistemele de gestionare a operatorului de „conducă” (pipelining) nu iau în considerare, implicit, structurile deja segmentate atunci când se extrage o structură nouă. De exemplu, la extragerea unei tumori hepatice, calculele se vor restrânge, în mod automat, în zona ficatului, dacă acesta a fost deja segmentat. Astfel, se poate reduce timpul de calcul, ceea ce este important într-un context clinic [12]. Mai mult decât atât, procesarea poate fi îmbunătățită, dacă nu sunt luate în considerare date irelevante (de exemplu, date în afara ficatului atunci când se face segmentarea tumorii hepatice). De exemplu, în cazul unei histograme bazate pe prag local (thresholding), utilizarea imaginii de ansamblu poate duce la o determinare incorectă a pragului optim, din cauza modurilor irelevante ce pot distorsiona histograma.

Graful segmentării



Din aceste motive, **zona de interes** (regiunea de Interes) este adesea prima reprezentare a limitelor aproximative a regiunilor pentru unele imagini: pentru inițializarea unei proceduri de segmentare a inimii [14], sau pentru a oferi o segmentare aproximativă a unor structuri de rafinat (zona de interes optimă este imaginea rămasă asociată cu părinții direct valabili).

În această lucrare, propunem o metodă de determinare automată a zonei de interes, în cursul unei proceduri de segmentare ierarhică interactivă, utilizând, a priori, cunoștințele despre structura topologică a imaginii medicale de analizat. Când se face segmentarea unui anumit set din structurile medicale, această metodă permite definirea unei zone de interes optimă în funcție de **informațiile contextuale** legate de natura obiectelor deja segmentate.

O **informație a priori** referă, în esență, relațiile spațiale între structurile anatomice. Acestea iau, în considerare, o strategie specială (pentru ordinea în segmentare) definită de „dificultatea segmentării”: pielea este segmentată mai întâi (structura cea mai simplă de recunoscut [15]), apoi scheletul, plămâni, rinichii și, în sfârșit, ficatul (structura cea mai dificilă de recunoscut [15]).

În timpul procedurii, sunt luate în considerare pozițiile relative pentru a defini o zona de interes în interiorul căreia poate fi restrânsă prelucrarea. De exemplu, după ce a fost segmentată regiunea ambilor plămâni, se folosește, a priori, o cunoaștere de bază asupra anatomiei umane, cum ar fi de exemplu: „ficatul și rinichii sunt sub plămâni”. Abordarea lor oferă o bună aproximare a structurilor, forme care sunt apoi rafinate. Algoritmul propus concentrându-se numai pe segmentarea aproximativă realizează:

a) **Gestionarea scenariului sau a strategiei de segmentare.** Acest lucru este necesar pentru că se va realiza un software interactiv de segmentare, iar strategia definită de utilizator este necunoscută a priori. Această metodă este concepută pentru a sprijini variațiile de informații contextuale (de exemplu, natura structurilor anterior segmentate).

b) **Încorporarea unei metode pentru a gestiona informațiile a priori:** informații topologice, care încorporează structuri suplimentare, cum ar fi tumori hepatice și vasele hepatice. Cunoștințele de bază consistă, de exemplu, în: „tumori hepatice fac parte din ficat”, „vasele hepatice intra în ficat, nu în plămâni”. Algoritmul propus se bazează pe o traducere corespunzătoare a acestor informații într-un graf care descrie relații corespunzătoare topologice.

Graful este folosit în timpul procesului de segmentare și adaptat automat la context și la strategie pentru a facilita determinarea automată și optimă a zonei de interes care realizată manual ar fi foarte dificilă. De exemplu, în cazul în care pielea (sau corpul), ambii plămâni și o parte a vaselor hepatice sunt segmentate, zona de interes care urmează să fie luată în considerare pentru extragerea ficatului va fi regiunea asociată cu corpul, cu excepția zonei legate de plămâni. Deoarece vasele hepatice sunt cunoscute că intră în ficat, punctele corespunzătoare imaginii vor aparține acestei zone de interes, deși acestea sunt deja identificate. După ce a fost extras ficatul, în cazul în care utilizatorul decide să segmenteze mai mult sau să extragă tumorile hepatice (denumite în continuare „țintă”), metoda va propune, în mod automat, să restrângă calculele în zona ficatului. Punctele imagine referitoare la vasele hepatice vor fi excluse. Într-adevăr, tumorile hepatice și vasele hepatice sunt excluse a priori, deoarece o informație a priori nu menționează cunoștințe cum ar fi „tumori hepatice intersectează vasele hepatice”. Metoda propusă gestionează obiective singulare definite de utilizator (de exemplu, tumori hepatice, ficat, splină), dar și preprocesarea unei zone dintr-un segment următor dintr-un grup de obiective (denumite „zonă”). Alegerea acestei zone ce urmează să fie preprocesată este, de asemenea, optimizată prin încercarea de a prevedea tipul de ținte ce sunt luate ulterior în considerare de către utilizator.

Informațiile structurale integrează, de asemenea, informații topologice (inclusiv relațiile dintre obiecte). Scopul zonei de interes este integrarea acestor informații în cadrul unei proceduri interactive pentru segmentarea ierarhică și încorporarea noțiunilor de „zonă” și „obiective”. Abordarea realizată în lucrare putea fi extinsă la alte regiuni anatomice și modalități de tratare a imaginii; în această fază, aceasta se concentrează asupra structurilor abdominale și a imaginilor CT.

În secțiunea următoare, se realizează descrierea metodei de preprocesare și procesare (segmentare), precum și modulele software aferente. Această zonă de interes se referă la segmentarea mai multor structuri medicale dintr-o imagine CT pentru un pacient.

## 5. Descrierea algoritmului de procesare (segmentarea)

În cadrul procedurii de modelare ierarhică o importanță deosebită o au descrierea **informațiilor a priori** și a celor **contextuale** și definirea explicită a regiunilor optime de interes.

**Informația a priori** folosită de metoda descrisă se referă la relațiile topologice dintre regiunile din imaginea CT, în funcție de tipul sau de natura lor (de exemplu, ficat sau plămân). Se ia în considerare o imagine, a priori, compusă din tipuri diferite de regiuni. O procedură de segmentare aplicată unei imagini inițiale poate conduce la o imagine segmentată, care conține regiunile a priori cunoscute. Informația considerată a priori prevede relații topologice definite prin funcții între tipuri diferite; de exemplu, vasele hepatice aparțin atât ficatului cât și corpului, dar nu se intersectează cu splina. În urma segmentării sunt extrase: **zona de interes** și restul (întreaga imagine, fără zona de interes). Imaginea CT ar putea cuprinde Corp, splină, ficat, VaseHepatice, TumoraHepatică. Segmentarea pentru zona ficatului realizează extragerea ficatului precum și vasele hepatice și eventuala tumoră.

### Procedura de segmentare ierarhică

Abordarea ierarhică constă într-o secvență de prelucrare  $P_t$ , unde  $t$  reprezintă momentele de timp. La sfârșitul procesării  $P$ , segmentarea este încheiată. Fiecare  $P_t$  este asimilată cu o



„conductă” de operatorii de prelucrare a imaginii. Imaginea de intrare de prelucrat conduce, în urma segmentării, la imaginea dorită. Se definește ca parametru tipul de prelucrare. Prelucrarea este limitată la zona de interes optim, calculat în funcție de natura „structurilor deja segmentate” (denumite „informații contextuale”).

Segmentarea unei structuri numită „țintă” (ficat, tumoră hepatică, corp, splină) se realizează utilizând o imagine binară (mască) corespunzătoare țintei segmentate; aceasta conduce la o nouă regiune identificată și extinde informațiile contextuale pentru următorul pas.

### **Informațiile contextuale**

La  $t = 0$ , atunci când a început prima secvență de prelucrare, întreaga imagine originală este identificată implicit; în graful inițial de dependențe sunt valabile puține noduri. Nodurile invalide corespund unor tipuri de obiecte care nu au fost încă segmentate. Se înregistrează tipurile de regiune, care au fost segmentate în primii  $t-1$  pași. La orice moment  $t$  se înregistrează părinții valizi și structurile deja segmentate.

Atunci când se termină pasul  $t$ , informațiile contextuale sunt actualizate, în funcție de tipul de prelucrare (de exemplu, preprocesare sau segmentare).

### **Prelucrări definite de utilizator**

#### **a. Zona de interes optimă pentru segmentarea unei „ținte”**

Pentru prima etapă de segmentare ( $t=0$ ), zona de interes optimă este imaginea de ansamblu. Prin urmare, prelucrările vor fi restrânse la zona, care este de așteptat, să cuprindă obiectul de interes, în conformitate cu informațiile contextuale. Această zonă este restrânsă prin eliminarea obiectelor segmentate care se suprapun. Astfel de obiecte pot fi de același tip cu ținta solicitată. Presupunem că două obiecte de tip similar nu se intersectează (de exemplu, două tumori hepatice); regiunile care se suprapun peste obiectul de interes aparțin zonei de interes propuse. Astfel, se evită eliminarea structurilor, cum ar fi vasele hepatice (presupuse a fi deja detectate), atunci când se face segmentarea ficatului. Dacă acest lucru nu este gestionat, devine imposibilă găsirea unei părți din marginea ficatului peste care se suprapun de vasele hepatice. În acest sens, apare clar că  $R_t$  este cea mai mică regiune (prin urmare, optimă) care, în conformitate atât cu informațiile a priori cât și cu cele contextuale, conține obiectul de interes.

#### **b. Zona de interes optimă pentru preprocesarea unei „zone”**

Scopul existenței unui pas de preprocesare  $t$  este de a pregăti o imagine de intrare pentru următoarea segmentare a structurilor medicale (ținte). Atunci când se determină zona de interes pentru a fi utilizată pentru preprocesare, sunt necunoscute a priori viitoarele tipuri de „ținte” (preprocesarea se referă la corpul următorului segment: de exemplu, ficat, splină sau vasele hepatice). „Țintele” - splină, ficat și vase hepatice - sunt implicate, deoarece, în funcție de ipoteza anterioară, acestea constituie ținte posibile după această etapă de preprocesare. Chiar dacă sunt considerate a priori structuri deja segmentate, nimic nu garantează că acestea au fost extrase în întregime. Într-adevăr, metoda suportă o segmentare „progresivă” a structurilor medicale. În practică, acest lucru poate fi deosebit de util pentru extragerea unui set de tumori hepatice în mai multe etape (de exemplu, începând cu cele mai mari, înainte de a extrage cele mai mici, folosind mai multe „conduce” specifice). Pentru vase acest lucru poate fi util atunci când segmentele (de exemplu, părți ale unei structuri vasculare) partajează diferite proprietăți în termeni de intensitate (de exemplu, variații de intensitate rezultate din repartizarea neomogenă a agentului de contrast în imagistica X-ray): mai mulți pași de segmentare pot fi considerați pentru a extrage și a modela întregul sistem vascular hepatic, fiecare fiind optimizat pentru un contrast specific.

Segmentarea suplimentară a ficatului poate fi realizată pe o zonă parțial preprocesată, cu excepția punctelor de ficat suprapuse de vasele hepatice. Acest lucru este similar pentru tumori hepatice. O astfel de strategie constă într-un studiu dedicat poziției tumorilor hepatice față de vasele hepatice, iar cunoștințele despre limitele ficatului ar fi, prin urmare, inutile. Se înregistrează contextul precum și zona preprocesată.

Algoritmul propus conduce la zona de interes aparent optimă, din cauză că dimensiunea este minimizată cu privire la posibilele viitoare obiective solicitate de utilizator.

## 5.1 Algoritmul de procesare a imaginii biomedicale constă în:

- a. Definirea și gestionarea informațiilor a priori
- b. Definirea și gestionarea informațiilor contextuale
- c. Definirea secvenței de prelucrare  $P_t$  la orice moment  $t$

a. Partea de **informații a priori** este furnizată de către un fișier (dicționar medical) dinamic încorporat în software la lansarea acestuia. Acesta constă în definirea naturii informațiilor, a părinților valizi (**relațiile topologice**), a caracteristicilor imaginii (**eticheta**).

b - c. La fiecare pas  $t$ , se calculează **cunoștințele a priori și contextuale**; secvența de prelucrare  $P_t$  gestionează validarea sau invalidarea nodului adecvat din structura grafului. (Imaginea de nivel gri permite stocarea unui set de imagini binare într-o structură unică). Pentru a identifica secvența de procesat, dicționarul medical asociază pentru fiecare tip o anumită valoare dintr-o gamă dinamică specifică, definită de câmpul „eticheta”.

La un pas dat  $t$ , poate fi cerută extragerea imaginii binare pentru a calcula zona de interes optimă: se poate aplica operator logic (ȘI sau SAU) setului de puncte imagine. Aceasta corespunde unui algoritm de **pattern matching** (model de potrivire) limitat la o gamă dinamică specifică (set de biți).

Se înregistrează evoluția **informațiilor contextuale** care rezultă din segmentarea zonei rămase la pasul  $t$  de prelucrare  $P_t$  (de exemplu, vasele hepatice). Nodul respectiv devine valabil la pasul  $t+1$ . Informațiile considerate a priori sunt corespunzătoare etapelor Achiziție, Corp, PlămânStâng, PlămânDrept, Splină, Os, Ficat, TumorăFicat, VasHepatic. Zona decupată se concentrează asupra vaselor hepatice segmentate la limita ficatului: punctele (imagine) situate în interiorul ficatului nu au aceeași intensitate ca acelea care sunt în afară. Această tehnică de codificare permite să se includă mai multe imagini binare în imagine la orice moment  $t$  decât atribuirea mai clasică - un bit pentru fiecare tip de organ. Singura constrângere este că straturile trebuie să fie definite în funcție de relațiile topologice: structurile care se suprapun sunt asociate cu diferite straturi. Într-adevăr, acest lucru evită fuzionarea și, prin urmare, pierderea informațiilor referitoare la imaginea de ieșire atunci când se face înregistrarea ei în caz de segmentare la momentul  $t+1$ .

Algoritmul de segmentare constă în:

Sistemul folosește etichetele asociate tipurilor de organe ce urmează să fie luate în considerare de către operatorul specific lui  $R_t$  pentru zona de interes. Se definesc parametrii „extrage”, „păstrează” și „elimină”. Se transmite imaginea la momentul  $t-1$  către operatorul specific lui  $R_t$  și se realizează operațiile de segmentare conform parametrilor definiți pentru etichetele asociate tipurilor de organe din  $R_t$ .

Operatorul implicit este necesar numai pentru scopuri de segmentare. Atunci când utilizatorul consideră că obiectul de interes este corect segmentat, operatorul notifică aceasta, datorită unui mecanism de bază de validare a software-ului. Imaginea rezultată din ultimul operator asociat lui  $R_t$  este apoi transferată operatorului lui  $R_{t+1}$ .

La momentul  $t$  se transferă informații contextuale actualizate de la un pas de prelucrare la următorul, astfel încât poate fi calculat  $R_t$  pentru zona de interes optimă. Setul de prelucrare  $P_t$  asociat cu pasul  $t$  referă atât imagini extrase cât și imagini rămase de procesat. Etichetele (tipurile asociate diferitelor organe) corespund structurilor medicale **Achiziție, Corp, PlămânStâng, PlămânDrept, Splină, Os, Ficat, TumorăFicat, VasHepatic**.

Pentru fiecare pas  $t$ , care corespunde unei prelucrări  $P_t$ , secvența utilizator de acțiune este:

(1) selectarea imaginii de intrare la momentul  $t$ . În cele mai multe cazuri, imaginea de intrare este cea produsă de la pasul de preprocesare. Acțiunea de procesare este comandată de utilizator. Acest lucru presupune crearea unei conduite vide de operatori. Informațiile

contextuale, la acest moment, sunt prelucrate automat.

(2) definirea unor proprietăți de prelucrare: tipul (adică „țintă” sau „zonă”) și numele (de exemplu, „tumoare 1” sau „restul”). Tipurile sunt furnizate de dicționarul medical și sunt afișate pentru utilizator datorită unui meniu ce se poate derula (scrollabil). Sunt inserați automat operatorii atașați  $R_t$  activi în zona de interes și parametrii corespunzători. Utilizatorul poate dezactiva utilizarea operatorilor în  $R_t$  activ în zona de interes. Dacă este activat,  $R_t$  din zona de interes este calculat în mod automat, în funcție de tipul selectat.

(3) introducerea (sau eliminarea) operatorilor de prelucrare a imaginii din cei disponibili, ca și parametrizarea acestora, precum și prelucrarea efectivă (restricționată la  $R_t$ ). Utilizatorul poate vizualiza datele de ieșire pentru  $R_t$  ale fiecărui operator (sau „conductă”).

(4) utilizatorul trebuie să valideze rezultatul, astfel încât, informațiile contextuale să fie actualizate. De asemenea, se pot calcula mesh-uri 3D și se pot defini culoarea și transparența.

Pentru un pas dat, zona de interes depinde de acuratețea structurilor anterior segmentate. Prin urmare, în cazul în care una sau mai multe structuri nu sunt corect delimitate, segmentarea regiunilor viitoare poate fi deteriorată. De exemplu, segmentarea ficatului poate fi inexactă dacă extragerea anterioară a unei structuri vecine, cum ar fi stomacul, nu a fost corect realizată (de exemplu masca pentru stomac încorporează puncte din imaginea aparținând ficatului). Într-un astfel de caz, utilizatorul trebuie să corecteze prelucrarea anterioară prin introducerea, de exemplu, de operatori suplimentari.


Software-ul va fi astfel realizat pentru a oferi un mecanism care să permită să se actualizeze automat datele din aval, astfel încât această modificare este luată în considerare pentru etapele ulterioare: vor fi recalculat numai zona de interes necesară și prelucrările aferente.

Este prezentat în continuare un exemplu de funcționare a acestui algoritm.

- La un moment  $t$ , este selectată o preprocesare (de exemplu, utilizatorul a ales ZonaCorp): splina este îndepărtată. Cu toate acestea, în cazul în care VaseHepatice vor fi luate în considerare la  $t$ , masca corespunzătoare va fi inclusă în  $R_t$ .

- La un moment  $t = t + n \cdot \text{pas}$ , eticheta este VaseHepatice; zona de interes este limitată la unirea atât a restului corpului cât și a ficatului, care sunt doi țapi direcți, valabili, de acest tip. „Rest”-urile de la Corp elimină, din zona de interes, toate organele (de exemplu, ambii plămâni, splină, oase și ficat). „Rest”-urile de la Ficat (care să permită să recupereze zona ficatului eliminată, anterior) respinge tumorile hepatice.

Software-ul **BioMed** are o interfață grafică prietenoasă pentru gestionarea procedurilor de modelare. Acțiunile utilizatorului sunt limitate la conexiuni explicite, inserare (și / sau activare / dezactivare operator), selecția tipului de validare și de segmentare.



## Comunicare - Diseminare în Internet

Site-ul BioMed este conceput ca o modalitate de comunicare între elaboratorii produsului și specialiști / medici din / în spitale și universități privind experiența în procesarea imaginilor biomedicale. Site-ul **BioMed** este un instrument interactiv necesar informării specialiștilor din spitale și instruirii studenților în tehnologiile pentru determinarea neregularităților. Accesul la site-ul BioMed este public; pentru informațiile din baza de date accesul este unul privat, prin autentificare securizată, (administratorul central, administratorul instituțiilor implicate).

Secțiunea **Spitale**, conține informații structurate pe tipuri de spitale, secții în cadrul spitalului, pacienți și date pacienți, imagini biomedicale capturate de aparate și rezultatul procesării imaginii utilizând algoritmi de recunoaștere a imaginii și algoritmi de clasificare a leziunilor.

**Biomed** Tehnologii avansate pentru procesarea imaginilor biomedicale utilizând algoritmi de recunoașterea formelor

C.F.R nr. 2

Adresa: Bd. Marasti nr. 63, Sectorul 1 / Bucuresti / Judet: Bucuresti  
Telefon Fix: 021 316 25 31  
Fax: 021 316 49 01  
E-mail: centrulbolirema@yahoo.com

SERVICII MEDICALE  
Consultatii de specialitate:

- chirurgie
- dermatovenerologie
- explorari functionale - EKG
- fizioterapie
- ginecologie
- laborator analitic
- medicina interna
- neurologie - EEG
- oftalmologie
- O.R.L. - audiometrie
- ortopedie
- psihiatrie
- radiologie: radioscopii, radiografi, radiografi dentare, MRF
- urologie Cabinele medicina de familie Cabinele stomatologice Cabinele tehnica dentara Laborator de psihologie C.F.R. si auto Ambulatoriu efectueaza examinari medicale pentru siguranta circulatiei, fise medicale auto (toate categoriile), fise medicale pentru permis port arma si examinari medicale pentru angajari.

Sectii

- > Gastroenterologie
- > Medicina interna
- > Cardiologie
- > Oftalmologie
- > OH
- > Radiologie
- > Urologie


Nume Pacient	Adresa	Oras/Judet	Telefon Fix	Telefon Mobil	E-mail
Dragomirescu Marcel	Lapusneanu nr 5	Bucuresti/ Bucuresti	021 4237157	0767564669	spaga@yahoo.com
Petre Petru	Lapusneanu nr 5	Bucuresti/ Alba	438858899	0738564565	petre@yahoo.com

C.F.R nr. 2 / Gastroenterologie

**Dragomirescu Marcel**  
Adresa: Lapusneanu nr 5 / Bucuresti / Judet: Bucuresti  
Sex: M / Varsta: 29  
Telefon Fix: 0214237157  
Telefon Mobil: 0767564669  
E-mail: spaga@yahoo.com


**Analiza Tomograf Computerizat (CT)**

**Analiza Abdomen**



Imagine Ideala

**Analiza Ficat**



Imagine Reala - Ficat

## 6. Concluzii

Scopul lucrării este prezentarea cercetărilor pentru elaborarea unei tehnologii pentru procesarea imaginilor biomedicale utilizând algoritmi de recunoaștere a formelor. Principala idee constă în modelarea și simularea funcțiilor unor organe, cum ar fi ficatul. Am ales acest organ - ficatul și glandele - pancreasul și splina, deoarece bolile lor sunt greu de diagnosticat timpuriu, ele nu prezintă simptome imediat de la apariție. Când pacienții prezintă simptome, ele sunt vagi și este posibil să nu le observe. Astfel, este important să furnizăm doctorilor tehnologii pentru procesarea imaginilor biomedicale pentru bolile acestor organe.

Sistemul se bazează pe integrarea cunoștințelor specifice ale pacientului, fizice, afective și spirituale și predispoziția, obținute prin procesarea imaginilor biomedicale (ex. MRI, CT, US). Datorită dimensiunilor mari ale imaginilor MRI, CT sau ultrasunete, software-ul **BioMed** dezvoltă instrumente inovative pentru segmentarea și reprezentarea imaginilor ficatului și a pancreasului în 3D (interpretarea volumului) obținute de la UltraSunete (US), a datelor de la Rezonanța Magnetică și crearea hărților pentru Imaginea Difuziunii Ponderate a Rezonanței Magnetice (Diffusion Weighted Imaging (DWI)) și imaginii structurale MRI; acest instrument va include și funcționalitatea semi-cantitativă a măsurării leziunii.

Pentru atingerea acestor obiective BioMed dezvoltă un instrument depozitar al tehnicilor de recunoaștere a formelor aplicate bazelor de date biologice și medicale: Rețele Neuronale Artificiale, arbori de decizie, cel mai apropiat vecin de distanță k (K-Nearest Neighbor), Vectori Mașină Suport, clasificatori parametrici.

Sistemul va dezvolta și aplicații e-learning pe Internet pentru scenarii reale. O unealtă de vizualizare medicală prietenoasă va fi dezvoltată pentru a asigura o introducere corectă a datelor, simularea modelului și vizualizarea datelor medicale la rezultat.

## BIBLIOGRAFIE

1. **PRATT, WILLIAM K.** Digital image processing: PIKS Scientific inside. 4th ed., A Wiley-Interscience publication, ISBN: 978-0-471-76777-0, 2007.
2. **JAIN, ANIL K.** Fundamentals of digital image processing. Prentice Hall Information and System Sciences Series, ISBN: 0-13-336165-9, 1989.
3. **BANKMANN, ISAAC N.** Handbook of Medical Imaging. Processing and Analysis. Academic Press Series in Biomedical Engineering, ISBN: 0-12-077790-8, October 2000.
4. Handbook of Biomedical Image Analysis. Vol. 1: Segmentation Models Part A. Eds.: D. L. W. Jasjit Suri, Swamy Laximinarayan Kluwer Academic/ Plenum Publishers, 2005.
5. Handbook of Biomedical Image Analysis. Vol. 2: Segmentation Models Part B. Eds.: D. L. W. Jasjit Suri, Swamy Laximinarayan Kluwer Academic/ Plenum Publishers, ISBN:0-306-48605-9, 2005.
6. **LEE, CHRISTINA W. C.; M. E. TUBLIN; B. E. CHAPMAN.** Registration of MR and CT Images of the Liver: Comparison of Voxel Similarity and Surface Based Registration Algorithms. Comput Methods Programs Biomed, 2005, May; 78(2):101-14.
7. **MARTIN-FERNANDEZ, M.; ALBEROLA-LOPEZ, C.** An Approach for Contour Detection of Human Kidneys from Ultrasound Images using Markov Random Fields and Active Contours. Medical Image Analysis, 2005.
8. **MASUTANI, Y.; K. UOZUMI; AKAHANE MASAOKI; OHTOMO KUNI.** Liver CT Image Processing: a Short Introduction of the Technical Elements. European journal of radiology, 2006; 58(2):246-51.
9. **FASQUEL, J.-B.; V. AGNUS; J. MOREAU; L. SOLER; J. MARESCAUX.** An Interactive Medical Image Segmentation System Based on the Optimal Management of Regions of Interest Using Topological Medical Knowledge. Computer methods and programs in biomedicine, 82 (3) 216–230, 2006.
10. **SEONG-JAE LIM; YONG-YEON JEONG; YO-SUNG HO.** Automatic Liver Segmentation for Volume Measurement in CT Images. J. Visual Communication and Image Representation, 17(4): 860-875 (2006).
11. **STOITSIS, JOHN; IOANNIS VALAVANIS; STAVROULA G. MOUGIAKAKOU; SPYRETTA GOLEMATI; ALEXANDRA NIKITA; KONSTANTINA S. NIKITA.** Computer Aided Diagnosis Based on Medical Image Processing and Artificial Intelligence Methods. Nuclear Instruments and Methods in Physics Research Section A, Volume 569, Issue 2, pp. 591-595.
12. **CHIA-HSIANG, WU; SUN YUNG-NIEN.** Segmentation of Kidney from Ultrasound B-mode Images with Texture-Based Classification. Computer Methods and Programs in Biomedicine, 84(2-3): 114-123 (2006).
13. **CAMPADELLI, PAOLA; ELENA CASIRAGHI; ANDREA ESPOSITO.** Liver Segmentation from Computed Tomography Scans: A Survey and a New Algorithm. Artificial Intelligence in Medicine, 45(2-3): 185-196 (2009).
14. **BEZY-WENDLING, JOHANNE; KRETOWSKI MAREK.** Physiological modeling of tumor-affected renal circulation. Computer Methods and Programs in Biomedicine, 91(1): 1-12 (2008).
15. **ZAFER, ISCAN; YÜKSEL AYHAN; DOKUR ZÜMRAY; KORÜREK MEHMET; ÖLMEZ TAMER.** Medical Image Segmentation with Transform and Moment Based Features and Incremental Supervised Neural Network. Digital Signal Processing, Vol. 19, Issue 5, September 2009, pp. 890-901.

16. **SPIEGEL, MARTIN; HAHN DIETER A.; DAUM VOLKER; WASZA JAKOB; HORNEGGER JOACHIM.** Segmentation of Kidneys Using a new Active Shape Model Generation Technique Based on Non-Rigid Image Registration. *Computerized Medical Imaging and Graphics*, 33 (2009), No. 1, pp. 29-39.
17. **TAKAYUKI, KITASAKA; MORI KENSAKU; SUENAGA YASUHITO.** Development of Advanced Image Processing Technology and Its Application to Computer Assisted Diagnosis and Surgery. K. Aizawa, Y. Nakamura, and S. Satoh (Eds.): *Pacific Rim Conference on Multimedia 2004, LNCS 3331*, Springer-Verlag Berlin Heidelberg, 2004, pp. 514–521.
18. **WALA, TOUHAMI; BOUKERROUI DJAMAL; COCQUEREZ JEAN-PIERRE.** Fully Automatic Kidneys Detection in 2D CT Images: A Statistical Approach. J. Duncan and G. Gerig (Eds.): *MICCAI 2005, LNCS 3749*, Springer-Verlag Berlin Heidelberg 2005 pp. 262–270.
19. **WONG, KOON-PONG.** Medical Image Segmentation: Methods and Applications in Functional Imaging. Springer, ISBN: 0-306- 48605-9; *Handbook of Biomedical Image Analysis, Vol.2: Segmentation Models, Part B, Chapter 3*, 2005, pp. 111-182.
20. **BOMMANNA RAJA, K.; M. MADHESWARAN; K. THYAGARAJAH.** Ultrasound Kidney Image Analysis for Computerized Disorder Identification and Classification Using Content Descriptive Power Spectral Features. *Journal of Medical Systems*, Vol. 31, 2007, pp. 307–317.