

# Sistem Software pentru Diagnosticarea Automată și Asistată de Calculator a Afecțiunilor Tumorale, pe Baza Imaginilor Ultrasonografice

**Delia Mitrea**

Universitatea Tehnică din Cluj-Napoca,  
Facultatea de Automatică și Calculatoare  
Str. G. Barițiu, Nr. 26-28, Cluj-Napoca  
Delia.Mitrea@cs.utcluj.ro

**Sergiu Nedevschi**

Universitatea Tehnică din Cluj-Napoca,  
Facultatea de Automatică și Calculatoare  
Str. G. Barițiu, Nr. 26-28, Cluj-Napoca  
Sergiu.Nedevschi@cs.utcluj.ro

## REZUMAT

În lucrarea de față descriem un sistem software destinat caracterizării și diagnosticării automate și semi-automate a tumorilor maligne, pe baza imaginilor ultrasonografice. Scopul acestui sistem și al cercetărilor noastre este acela de a oferi un instrument pentru diagnosticarea non-invazivă, prin biopsie virtuală, a cancerului, acesta fiind o afecțiune de importanță majoră. Ultrasonografia este o metodă de investigare imagistică de cost scăzut, nepericuloasă pentru pacient, oricând repetabilă. Textura reprezintă o proprietate vizuală importantă a obiectelor din lumea reală și a țesuturilor din imaginile ultrasonografice, în măsură a releva aspecte subtile, care nu pot fi detectate de către ochiul uman. Am definit, astfel, pe baza imaginilor ultrasonografice, modelul imagistic textural al tumorilor maligne, descris pe larg în cele ce urmează. Prin intermediul sistemului software ce implementează modelul imagistic textural am obținut, în urma experimentelor, o acuratețe de peste 90% în ceea ce privește diagnosticarea automată a afecțiunilor considerate.

## Cuvinte cheie

Diagnoza automată și asistată de calculator, caracterizare non-invazivă, imagini ultrasonografice, textură, biopsie virtuală.

## Clasificare ACM

Human-centered computing: Human-Computer Interaction (HCI) - Interaction Paradigms: Mixed/Augmented Reality

## INTRODUCERE

Tumorile maligne reprezintă o problemă de mare interes în zilele noastre, întrucât acestea pot afecta în mod iremediabil organismul uman. Detecția precoce, sau cel puțin la timp a acestor tumori, ar putea conduce la o îmbunătățire a șanselor de vindecare și la prevenirea metastazelor. Biopsia se numără printre puținele metode de încredere în ceea ce privește diagnosticarea tumorilor maligne, reprezentând „standardul de aur” în acest sens, fiind însă o metodă invazivă, periculoasă pentru pacient, putând conduce la infecții și chiar la răspândirea în organism a tumorilor. Din acest motiv, interesează punerea la punct a unei metode non-invazive de diagnosticare a tumorilor maligne care să poată înlocui biopsia reală. O astfel de metodă s-ar putea axa doar pe imagistica medicală, dar capacitatea de interpretare a

informației vizuale de către medicul specialist este deseori limitată, deci dezvoltarea unor metode computerizate adecvate care să vină în completarea analizei medicului, ar putea constitui o soluție viabilă. În ceea ce privește metodele specifice imagisticii medicale, Tomografia Computerizată (CT), Rezonanța Magnetico-Nucleară (RMN) și endoscopia reprezintă tehnici care comportă un anumit grad de risc, fiind considerate iradiante sau de cost ridicat. Ultrasonografia (ecografia) este o metodă non-invazivă, de cost redus, putând fi repetată mult mai frecvent decât celelalte metode, în scopul urmăririi evoluției stării pacientului. Ne propunem, astfel, dezvoltarea unei metode non-invazive de diagnosticare a cancerului, bazată pe tehnici computerizate menite să prelucereze și să analizeze informația preluată din imagini ultrasonografice [1]. Metoda elaborată va contribui la realizarea unei *biopsii virtuale*, îndeplinind următoarele obiective: *caracterizarea țesutului analizat prin trăsături imagistice*, corelate cu proprietățile sale fizico-chimice; *stabilirea clasei de apartenență a țesutului*, în sensul identificării maladiei corespunzătoare. Textura reprezintă o proprietate importantă a suprafețelor obiectelor, în particular a țesuturilor organelor interne, așa cum apar acestea în imaginile medicale, fiind în măsură a furniza informații subtile privind starea patologică a acestora. În această ordine de idei, am elaborat *modelul imagistic textural* al afecțiunilor considerate, constând în: *setul exhaustiv și neredondant al trăsăturilor texturale relevante* în ceea ce privește diferențierea țesutului afectat de maladie de țesuturi vizual similare; *valorile statistice specifice* pentru trăsăturile texturale relevante: media, deviația standard, distribuția de probabilitate, intervale de încredere. Construirea modelului imagistic textural a implicat următoarele etape: o etapă premergătoare, constând în *stabilirea setului de antrenament*; *etapa de analiză a imaginilor*, constând în determinarea trăsăturilor texturale pe baza imaginilor ultrasonografice, în urma aplicării metodelor specifice analizei a texturii; *etapa de învățare*, constând în determinarea reprezentării celei mai adecvate a trăsăturilor texturale, care maximizează cantitatea de informație conținută de acestea, respectiv identificarea trăsăturilor relevante prin aplicarea unor metode specifice selecției trăsăturilor; *etapa de validare* a modelului imagistic textural, constând în evaluarea acurateței de recunoaștere a tumorilor maligne, prin furnizarea valorilor trăsăturilor texturale relevante la intrările unor clasificatori performanți.[3] În vederea experimentării și validării modelului imagistic textural, am

considerat următoarele tipuri de tumori abdominale: *carcinomul hepatocelular (HCC)* [1], acesta reprezentând cea mai frecventă tumoră hepatică malignă, fiind comparat cu parenchimul hepatic cirotic pe care acesta evoluează, precum și cu hemangiomul, o tumoră hepatică benignă des întâlnită; *tumorile colorectale*, acestea fiind comparate cu imagini ale Bolilor Inflamatorii Intestinale (BII), cu care pot fi confundate[2].

Sistemul software destinat caracterizării și diagnosticării tumorilor maligne îndeplinește următoarele funcționalități:

- determinarea trăsăturilor texturale, prin aplicarea unor metode specifice analizei texturilor;
- determinarea trăsăturilor texturale relevante, prin aplicarea unor metode pentru reducerea dimensionalității datelor (selecția trăsăturilor); vizualizarea efectelor pe care le produc asupra imaginii metodele de analiză a texturii, respectiv exportul valorilor trăsăturilor texturale în fișiere având diferite formate;
- determinarea valorilor specifice trăsăturilor texturale relevante: media, deviația standard, densitatea de probabilitate, intervale de încredere; antrenarea unor clasificatori utilizând setul de valori corespunzând trăsăturilor texturale relevante; utilizarea clasificatorilor antrenați în vederea diagnozei automate, pentru stabilirea clasei de apartenență a țesutului analizat.

Sistemul software, precum și metodele care au stat la baza acestuia, vor fi descrise pe larg în cele ce urmează.

#### METODE SIMILARE EXISTENTE

Metodele bazate pe textură au fost utilizate în situații multiple, în vederea caracterizării și recunoașterii unor maladii diverse pe baza imaginilor ultrasonografice. În scopul recunoașterii tumorilor maligne, au fost implementate metode de complexitate ridicată, în conjuncție cu clasificatorii cei mai performanți. Astfel, în [4], autorii au determinat statistici de ordinul întâi ale nivelurilor de gri, precum media și varianța acestora, alături de parametrii Haralick ai matricei de coocurență a nivelurilor de gri ("Gray Level Cooccurrence Matrix"-GLCM) și parametrii matricei Run-Length, în conjuncție cu un clasificator bazat pe rețele neuronale artificiale, și, de asemenea, cu un clasificator bazat pe discriminanți liniari, în scopul diferențierii tumorilor hepatice maligne de cele benigne, respectiv de ficatul normal. În cazul clasificatorului bazat pe discriminanți liniari, rata de recunoaștere a fost 79.6%, în timp ce în cazul clasificatorului bazat pe rețele neuronale artificiale, a rezultat o rată de recunoaștere de 100% [4]. Metodele bazate pe fractali au fost implementate în [5], pentru a detecta tumorile glandelor salivare, pe baza imaginilor ultrasonografice. Transformata Wavelet a fost utilizată de asemenea, pentru a analiza valorile parametrilor texturali, la rezoluții multiple, obiectivul fiind acela de a diferenția tumorile hepatice maligne de cele benigne. Metoda a furnizat rezultate satisfăcătoare, suprafața de sub curba ROC fiind 0.90. [6]. În scopul de a realiza detecția automată a adenocarcinomului prostatic, pe baza imaginilor de rezonanță magnetică (MRI), a fost implementată o metodă bazată pe transformata Gabor [7],

în combinație cu parametrii Haralick derivați din matricea GLCM și cu clasificatori Bayesieni. Au rezultat următoarele valori ale parametrilor de performanță: sensibilitatea a fost 42.35% (mai bună decât cea a experților umani, de 36.41%), în timp ce specificitatea a avut valoarea 97.25%. Din cele prezentate mai sus, rezultă importanța metodelor bazate pe textură și relevanța parametrilor texturali în ceea ce privește detecția tumorilor maligne. Astfel, metodele imagistice computerizate, bazate pe textură, pot contribui substanțial la identificarea precoce, pe cale neinvazivă, a unor afecțiuni ce sunt în măsură a pune în pericol viața umana. În pofida varietății metodelor utilizate în vederea caracterizării și recunoașterii tumorilor maligne, nu a fost definit un model unificat corespunzător fiecărei astfel de clase, care să pună în evidență setul trăsăturilor texturale relevante și valorile specifice acestora. În cercetarea noastră, am urmărit să definim un asemenea model și să facem, de asemenea, corelația între trăsăturile texturale și proprietățile structurale ale țesutului, în scopul realizării biopsiei virtuale. Sistemul software realizat implementează metodele corespunzătoare acestui model imagistic.

#### SOLUȚIA PROPUȘĂ

##### Definirea modelului imagistic textural

**Modelul imagistic textural al carcinomului hepatocelular (HCC)** constă în mulțimea trăsăturilor texturale relevante pentru caracterizarea acestei tumori maligne, considerate în reprezentarea lor optimă, respectiv în valorile statistice, specifice asociate acestor trăsături. Pentru a defini modelul imagistic textural pornim de la un spațiu inițial al trăsăturilor texturale potențial relevante, determinate prin metode specifice de analiză a texturii:

$$F = \{f_i\}_{i=1,\dots,n} \quad (1)$$

Am urmărit să transpunem acest set de trăsături într-o reprezentare cât mai adecvată, astfel încât acestea să conducă la o acuratețe de recunoaștere cât mai bună. În acest scop, s-au realizat următoarele demersuri: aplicarea unor *metode de extragere a trăsăturilor*, care să evidențieze caracteristici ale acestor trăsături, precum varianța sau capacitatea lor de a separa între clase: Metoda Analizei Componentelor Principale (PCA), metodele Analizei Discriminantilor Liniari (LDA), respectiv a Analizei Discriminantilor Multipli (MDA) [8]; *selecția acelor trăsături* ce pot fi considerate *relevante* pentru procesul de clasificare, prin metode specifice selecției trăsăturilor [9]. Aceste demersuri sunt ilustrate în (2):

$$F = \{\text{Trasaturi\_texturale\_potential\_relevante}\}; \\ F_R \subset F - \text{subspatiul trasaturilor texturale} \quad (2) \\ \text{relevante, in reprezentarea cea mai adecvata}$$

Ambele demersuri implică utilizarea metodelor destinate reducerii dimensionalității datelor, pentru a obține setul final de trăsături,  $F_R$ , atașat modelului imagistic textural, conform expresiei (3):

$$F_R = \{\text{trasaturi\_texturale\_relevante}\}; \quad (3)$$

$$F_R \Leftarrow \text{Reducerea\_Dimensionalitatii}(F)$$

Acestor trăsături le sunt asociate valori specifice, precum valoarea medie, deviația standard, distribuția de probabilitate, precum și o măsură a relevanței fiecărui atribut. Modelul imagistic textural rezultat are, astfel, reprezentarea formală descrisă în (4):

$$TM = \{V_f | V_r = [\text{Relevanta, Media, Deviatia standard,} \quad (4)$$

*Distribuția de probabilitate]*

### Metode utilizate în faza de analiză a imaginilor

În vederea caracterizării cu mare acuratețe a țesutului tumoral, au fost determinate următoarele trăsături texturale, rezultate în urma aplicării unor metode deja existente de analiză a texturii: statistici de ordinul întâi ale nivelurilor de gri (media, valoarea minimă și maximă), statistici bazate pe muchii și trăsături de tip gradient, statistici privind microstructurile texturale, obținute după aplicarea nucleelor de convoluție ale lui Laws, mărimi statistice de ordinul doi ale nivelurilor de gri, respectiv ale muchiilor, sub forma matricei de coocurență a nivelurilor de gri, respectiv a matricei de coocurență a orientărilor muchiilor, împreună cu parametrii Haralick asociați [10]. Transformata Wavelet a fost de asemenea utilizată pentru caracterizarea texturilor la rezoluții multiple. Entropia Shannon a fost determinată pe fiecare componentă a semnalului, rezultată în urma aplicării recursive a transformatei Wavelet, la două niveluri de rezoluție [11]. În scopul obținerii unor trăsături texturale mai rafinate, în vederea îmbunătățirii acurateței procesului de diagnoză automată a afecțiunilor tumorale, au fost elaborate noi metode destinate analizei texturilor. Astfel, a fost definită matricea de coocurență generalizată de ordinul  $n$ , împreună cu parametrii Haralick asociați. În particular, s-au determinat matricea de coocurență a nivelurilor de gri de ordinul trei, cinci și șapte, respectiv matricea de coocurență a muchiilor de ordinul trei, atât considerând rezoluția obișnuită a imaginii, cât și după aplicarea transformatei Wavelet [3].

### Descrierea etapei de învățare

În timpul etapei de învățare, s-a realizat reducerea dimensionalității datelor, prin aplicarea atât a unor metode specifice selecției trăsăturilor, cât și a unor metode destinate extragerii trăsăturilor. Prin intermediul metodelor destinate selecției trăsăturilor, s-a urmărit separarea trăsăturilor relevante de cele non-relevante. Prin intermediul metodelor destinate extragerii trăsăturilor, s-a încercat transpunerea setului inițial de date într-un nou spațiu, în care să fie evidențiate proprietăți ale datelor precum: principalele moduri de variație ("Principal Component Analysis" - PCA); capacitatea acestora de a separa între clase ("Linear Discriminant Analysis" - LDA).

Cele două categorii de metode au fost comparate ca performanță. Cele mai performante metode au rezultat a fi cele pentru selecția trăsăturilor, anume metoda bazată pe stabilirea corelației dintre parametrii texturali și parametrul clasă, metoda bazată pe modelarea univariată a

trăsăturilor texturale prin mixturi de distribuții gaussiene, precum și metodele de evaluare a atributelor bazate pe câștigul informațional [9].

### Etapa de validare a modelului imagistic textural

Faza de validare a modelului imagistic textural a constat în evaluarea modelului generat prin furnizarea valorilor trăsăturilor relevante la intrările clasificatorilor. În acest scop, au fost comparați o serie de clasificatori și combinații de clasificatori, utilizând întregul set de date disponibil. Cei mai performanți clasificatori s-au dovedit a fi Perceptronul Multinivel (Multilayer Perceptron - MLP), Mașinile cu Vectori Suport (Support Vector Machines - SVM), respectiv clasificatorii bazați pe arbori decizionali de tip Păduri Aleatoare (Random Forest)[12]. În ceea ce privește combinațiile de clasificatori, rezultatele cele mai performante au fost furnizate de AdaBoost, respectiv de metoda de generalizare prin stivuire (stacking) [12]. Performanța clasificatorilor a fost evaluată atât prin intermediul ratei de recunoaștere, cât și prin intermediul sensibilității, specificității, al suprafeței de sub curba ROC, respectiv al timpului necesar construirii modelului.

## DESCRIEREA SISTEMULUI SOFTWARE CORESPUNZĂTOR IMPLEMENTĂRII MODELULUI IMAGISTIC TEXTURAL

### Scop și funcționalități

Sistemul software care implementează modelul imagistic textural realizează atât caracterizarea imaginilor ultrasonografice ale pacienților diagnosticați cu cancer hepatic, respectiv colonic, sau suspecti de aceste maladii, cât și recunoașterea automată a clasei regiunii de interes selectată de utilizator în imagine. Actorii (entitățile externe care interacționează cu sistemul software) sunt utilizatori de următoarele tipuri:

**Administratorul:** realizează generarea valorilor trăsăturilor texturale, rezultate în urma aplicării metodelor de analiză a texturii asupra imaginilor din baza de date, fiecare dintre acestea având selectată o regiune de interes în interiorul formațiunilor tumorale, în interiorul organului analizat, sau pe peretele intestinal afectat de BII; aplică metodele de reducerea dimensionalității datelor asupra setului de valori generat, obținând trăsăturile relevante, în spațiul de reprezentare cel mai adecvat; determină valorile caracteristice trăsăturilor relevante - media, deviația standard, intervalele de încredere, densitatea de probabilitate, aplicând metode specifice, în fiecare caz; antrenează clasificatorul utilizând setul de valori ale trăsăturilor texturale generate anterior.

**Medicul specialist:** selectează o regiune de interes în interiorul formațiunii suspecte; vizualizează valorile trăsăturilor texturale corespunzătoare acelei regiuni și/sau efectul asupra imaginii al metodelor de analiză a texturii; vizualizează valorile specifice trăsăturilor texturale relevante și densitățile de probabilitate ale acestora; detectează clasa de apartenență a regiunii de interes, prin aplicarea clasificatorului antrenat, stabilind diagnosticul.

### Structura sistemului software

Arhitectura sistemului presupune existența a trei părți componente: *baza de date*; *interfața de comunicare directă cu baza de date* pentru inserarea datelor legate de

pacient și a imaginilor ecografice; aplicația software pentru construirea și utilizarea modelului imagistic. Atât baza de date, cât și interfața de comunicare directă cu baza de date au fost realizate în mediul Microsoft Access. Baza de date conține următoarele tipuri de entități, corespunzătoare tabelor: *pacienți* (date despre pacienți: nume, prenume, vârstă, greutate, antecedente heredocolaterale), *studiu* (examen ecografic), *ecografii*, *date medicale ficat*, *date formațiuni focale* (corespunzătoare regiunilor de interes selectate de utilizator pe imaginile ecografice), *seturi de trăsături texturale* (tipurile de trăsături texturale care se determină), *valorile trăsăturilor texturale* determinate, *model imagistic textural* (se memorează trăsăturile relevante corespunzătoare fiecărei clase analizate și valorile lor specifice), *intervale de încredere* (pentru memorarea limitelor intervalelor de încredere ce corespund fiecărei trăsături texturale relevante). Interfața de comunicare cu baza de date oferă posibilitatea de completare a datelor legate de pacient (nume, prenume, vârstă, greutate, antecedente heredocolaterale), a datelor generale rezultate în urma examenului (studiului) ecografic, facilitează alegerea imaginilor ecografice de pe disc pentru stocarea în baza de date a referințelor (căilor) către acestea, oferă posibilitatea selecției unor regiuni de interes de formă rectangulară pe imaginile ecografice, precum și a precizării tipului regiunii de interes (clasa de țesut), respectiv a caracteristicilor regiunii de interes constatate în urma examenului ecografic.

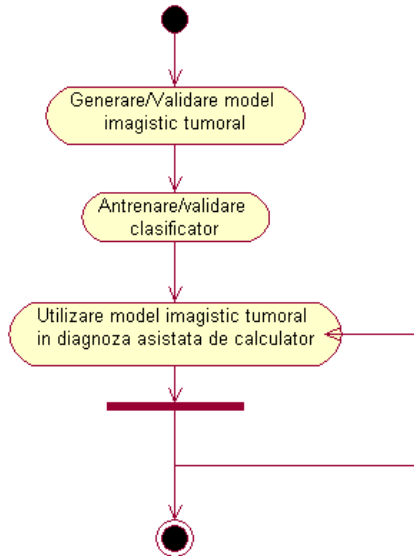


Figura 1. Schema generală de funcționare a sistemului

Aplicația software pentru construirea și utilizarea modelului imagistic textural constă din trei mari module: *modulul corespunzător învățării modelului imagistic*; *cel corespunzător utilizării acestuia în scopul diagnozei asistate de calculator* (vizualizarea efectelor metodelor de analiză a texturii asupra imaginii, respectiv a valorilor specifice ale trăsăturilor texturale relevante); *cel corespunzător diagnozei automate*, bazat pe clasificatori specializați. Această aplicație a fost realizată în mediul Visual Studio 2008, în limbajul Visual C++. Schema generală de funcționare a sistemului este ilustrată prin intermediul diagramei de activitate din Figura 1. Funcțiile

modulului destinat construirii modelului imagistic textural rezultă din Figura 2.




Figura 2. Sub-meniul pentru generarea modelului imagistic

Selecția trăsăturilor relevante, estimarea densităților de probabilitate ale acestora, respectiv antrenarea și validarea clasificatorilor s-a realizat utilizând funcțiile bibliotecii open-source Weka 3.5 [13]. În scopul selecției trăsăturilor relevante au fost implementate metodele Correlation based Feature Selection, Information Gain Attribute Selection, Gain Ratio Attribute Selection [9], iar în scopul determinării densităților de probabilitate a fost exploatată metoda Rețelelor Bayesiene de Încredere [12]. Modulul destinat utilizării modelului imagistic textural în diagnoza asistată de calculator oferă posibilitatea vizualizării valorilor specifice parametrilor texturali (media și deviația standard), a intervalelor de încredere pentru fiecare parametru textural, respectiv a distribuțiilor de probabilitate asociate parametrilor texturali. Sub-meniul corespunzător acestui modul este prezentat în Figura 3.




Figura 3. Sub-meniul pentru utilizarea modelului imagistic în scopul diagnozei asistate de calculator

Modulul destinat diagnozei automate oferă posibilitatea apelării unor clasificatori performanți, pentru a stabili clasa de apartenență a țesutului analizat, pe baza setului de antrenare obținut în urma construirii modelului imagistic textural, conținând valorile trăsăturilor texturale relevante, pentru fiecare regiune de interes marcată în interiorul imaginilor din baza de date. Sub-meniul corespunzător acestui modul este ilustrat în Figura 4.




Figura 4. Sub-meniul pentru clasificare (diagnoză) automată

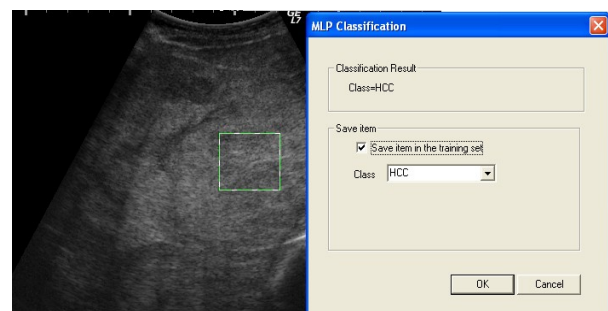


Figura 5. Furnizarea rezultatului diagnozei automate într-o casetă de dialog


Rezultatul clasificării este furnizat apoi într-o casetă de dialog, sub forma diagnosticului pacientului examinat, așa cum este indicat în *Figura 5*.

Sistemul software a fost instalat la Clinica Medicală III din Cluj-Napoca, fiind utilizat de către medicii specialiști în ultrasonografie.

## REZULTATE EXPERIMENTALE

În scopul experimentării modelului imagistic textural, s-a utilizat un set de date conținând 300 de pacienți bolnavi de HCC, 150 de pacienți suferind de hemangiom, 70 de pacienți afectați de tumori colorectale, respectiv 70 de pacienți cu BII. Stabilirea naturii formațiunilor tumorale s-a realizat prin biopsie. Imaginile ultrasonografice au fost preluate prin intermediul unui ecograf de tip Logiq 7, utilizând aceleași setări de preluare: frecvența 5.5 MHz, câștigul (gain) 78, adâncimea 16 cm. Pentru fiecare pacient au fost preluate câte trei imagini, corespunzătoare unor orientări diferite ale transductorului. În *Figura 6* este ilustrat efectul aplicării transformatei Wavelet asupra unei imagini ultrasonografice reprezentând o tumoră colorectală. Transformata Wavelet a fost aplicată recursiv, la două niveluri. La fiecare aplicare a transformatei Wavelet, se înjumătățesc atât rezoluția verticală, cât și cea orizontală. Prima componentă (sub-imagini) obținută (colțul din stânga sus) este rezultatul aplicării unei combinații de filtre trece-jos, având un efect de netezire asupra imaginii. Cea de-a doua sub-imagini obținută la un anumit nivel (dreapta, sus) este rezultatul aplicării unei combinații de filtre trece-sus, și reprezintă muchiile verticale. A treia sub-imagini (stânga, jos) reprezintă muchiile orizontale, iar cea de-a patra sub-imagini (dreapta, jos) reprezintă curbura. Remarcăm faptul că în interiorul formațiunii tumorale muchiile orizontale, muchiile verticale, și, respectiv, curbura sunt mai frecvente și mai accentuate. În ceea ce privește trăsăturile texturale relevante determinate în urma experimentelor multiple realizate, putem concluziona că următoarele trăsături s-au dovedit a fi cele mai importante în procesul de separare a tumorilor maligne de alte țesuturi: omogenitatea și energia GLCM, atât de ordinul doi, cât și de ordin superior, determinate atât la un singur nivel de rezoluție, cât și în manieră multirezoluție; aceste trăsături denotă diferența de omogenitate dintre țesutul tumoral malign și alte tipuri de țesuturi. Astfel, țesutul tumoral malign este întotdeauna mai neomogen, datorită tipurilor variate de țesut (ex. țesut tumoral pur, țesut necrozat, țesut afectat de fibroză) care intră în structura formațiunii tumorale. O altă trăsătură importantă a fost entropia GLCM, denotând caracterul haotic al structurii formațiunii tumorale. Indexul de autocorelație a fost de asemenea relevant, punând în evidență diferențele de granularitate existente între țesutul tumoral și cel non-tumoral. Trăsături precum frecvența muchiilor, variabilitatea în orientarea muchiilor și parametrii Haralick ai matricei EOCM au rezultat a fi relevante în situații multiple. *Tabelul 1* ilustrează densitatea de probabilitate a Energiei GLCM de ordinul șapte în cazul claselor HCC, hemangiom și, respectiv, parenchim cirotic pe care a evoluat HCC. Se observă că această trăsătură, care denotă omogenitatea, ia valori maxime în cazul hemangiomului (probabilitatea de apariție a valorilor celor mai mari, din

ultimul interval, este maximă), ia valori minime în cazul HCC, respectiv valori moderate în cazul parenchimului cirotic.



*Figura 6. Vizualizarea efectelor transformatei Wavelet asupra unei imagini reprezentând o tumoră colo-rectală (a. Imaginea originală, având conturul tumoral marcat de medicul expert; b. Efectul aplicării recursive a transformatei Wavelet)*

*Tabelul 1. Tabelul distribuției de probabilitate pentru Energia GLCM7*

| Energia GLCM7     | $(-\infty, 0.000267]$ | $(0.000267, 0.000455]$ | $(0.000455, \infty)$ |
|-------------------|-----------------------|------------------------|----------------------|
| Hemangiom         | 0.051                 | 0.401                  | 0.549                |
| HCC               | 0.158                 | 0.724                  | 0.118                |
| Parenchim cirotic | 0.003                 | 0.865                  | 0.131                |

*Tabelul 2* exprimă densitatea de probabilitate a omogenității GLCM de ordinul trei, în cazul claselor: tumoră colorectală și BII. Se observă că omogenitatea GLCM de ordinul trei este maximă în cazul BII și minimă în cazul tumorilor colorectale.

*Tabelul 2. Tabelul distribuției de probabilitate pentru Energia GLCM3*

| GLCM3 omogenitate   | $(-\infty, 0.0208]$ | $(0.0208, \infty)$ |
|---------------------|---------------------|--------------------|
| BII                 | 0.144               | 0.856              |
| Tumori colo-rectale | 0.569               | 0.431              |

*Figura 7* ilustrează comparativ acuratețea clasificatorilor, obținută în cazul combinației dintre trăsăturile texturale clasice și cele noi, respectiv cea obținută în cazul aplicării acelorași clasificatori, doar pentru trăsăturile texturale clasice. Clasificatorii luați în considerare în acest caz au fost următorii: Perceptron Multinivel (MLP), Mașini cu Vectori Suport (SVM), Păduri Aleatoare (Random Forest), precum și meta-clasificatorul de generalizare prin stivuire (stacking) cu clasificatorii elementari specificați mai sus. Acești clasificatori au fost evaluați utilizând strategia validării încrucișate cu 5 iterații. Perechile de clase



considerate au fost următoarele: HCC/parenchim cirotic pe care a evoluat HCC; HCC/hemangiom; tumori colo-rectale/BII. Instanțele existente au fost împărțite în mod egal, în cazul fiecărei perechi de clase. Ratele de recunoaștere medii obținute au fost următoarele: 97.058%, în cazul diferențierii dintre HCC/parenchim cirotic; 95.2% în cazul diferențierii dintre HCC/hemangiom; 93.54% în cazul diferențierii dintre tumori colo-rectale/BII.

## CONCLUZII

Metodele aplicate în contextul sistemului software ce implementează modelul imagistic textural al tumorilor maligne au condus la rezultate satisfăcătoare în ceea ce privește diagnoza automată, precum și cea asistată de calculator a acestor afecțiuni. Astfel, trăsăturile texturale relevante și valorile lor caracteristice au corespuns proprietăților cunoscute a-priori ale țesutului tumoral

malign, relevând și alte caracteristici, mai subtile ale acestuia. De asemenea, metodele de clasificare implementate au condus la o acuratețe crescută, de peste 90%. Sistemul software dezvoltat a fost instalat la Clinica Medicală III din Cluj-Napoca, fiind utilizat, în prezent, de medicii specialiști în ultrasonografie de la această clinică. Datorită funcționalităților sistemului, s-a reușit, în multe cazuri, evitarea biopsiei. În ceea ce privește dezvoltările ulterioare, sistemul software descris poate fi ușor extins în vederea caracterizării și diagnosticării altor afecțiuni similare. Experimentarea acestuia pe noi seturi de date va consolida, totodată, rezultatele obținute în timpul etapei de validare. În scopul completării funcționalităților corespunzătoare biopsiei virtuale, vom dezvolta, de asemenea, metode pentru identificarea cu precizie a conturului tumoral, pe baza texturii.

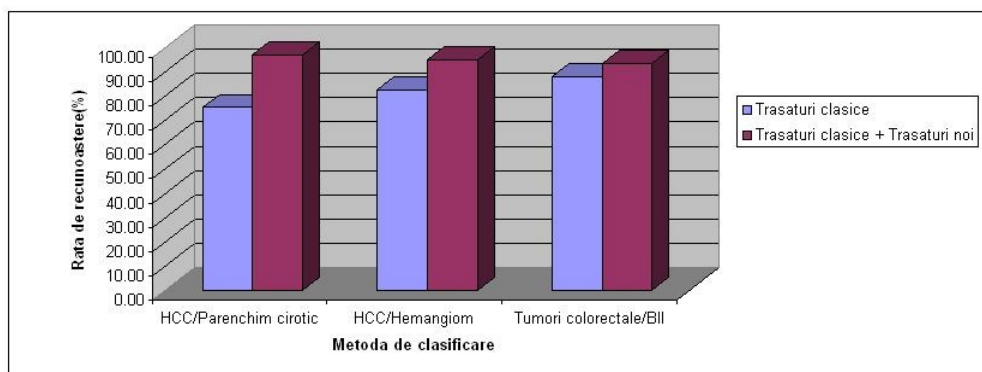


Figura 7. Creșterea ratei de recunoaștere datorită noilor trăsături definite

## REFERINȚE

1. J.Bruix, "Hepatitis B Virus and Hepatocellular Carcinoma", *Journal of Hepatology*, vol 39, issue.1, pp. S59- S63, 2003
2. L. Ruess, "Inflammatory bowel diseases in children and young adults: correlation of sonographic and clinical parameters during treatment," *American Journal on Roentgenology*, vol. 175, no. 1, pp. 79–84, 2000
3. D. Mitrea, S. Nedeveschi, R. Badea, „The role of the multiresolution textural features in improving the characterization and recognition of the liver tumors, based on ultrasound images”, *Proceedings of 14-th IEEE International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC 2012)*, pp. 192-200, 2012
4. H. Sujana, S. Swarnamani, S. Suresh, „Application of Artificial Neural Networks for the classification of liver lesions by texture parameters” , *Ultrasound in Med. & Biol.*, Vol. 22, No. 9, 1996, pp. 1177- 1181.
5. T. Chikui, K. Tokumori, K.Yoshiura, K.Oobu, S.Nakamura, K. Nakamura, „Sonographic texture characterization of salivary gland tumors by fractal analysis” , *Ultrasound in Med. & Biol.*, Vol. 31, No.10, 2005, pp. 1297–1304
6. H. Yoshida, D.Casalino, B. Keserci, A. Coskun, O. Ozturk, A. Savranlar, „Wavelet-packet-based texture analysis for diferentiation between benign and malignant liver tumours in ultrasound images”, *Physics in Med. and Biol.*, No.48, 2003, pp.3735-3753.
7. A. Madabhushi., M.D. Felman, D.N. Metaxas, J.Tomaszewski, D. Chte, „Automated Detection of Prostatic Adenocarcinoma From High-Resolution Ex Vivo MRI”, *IEEE Trans. on Medical Imaging*, Jan.2005, pp. 1611-1626
8. L.J.P. Van der Maaten, E.O.Postma, H.J. van der Herik, „Dimensionality reduction: A comparative review”, January 2008, pp. 1-22
9. M. Hall, “Benchmarking attribute selection techniques for discrete class data mining: IEEE Trans On Knowledge and Data Eng., vol. 15, no. 3, pp. 1-16, 2003
10. A.K.Jain *Fundamentals of Digital Image Processing*, Englewood Cliffs, NJ: Prentice Hall, 1989
11. E. Stollnitz, T. DeRose, “Wavelets for computer graphics”, *IEEE Computer Graphics & Applications*, vol.15, no.3, pp. 76–84, 1995
12. R. Duda, *Pattern Classification*(2nd ed). Wiley Interscience, 2003
13. Weka 3, *Data Mining Software in Java* (2011), <http://www.cs.waikato.ac.nz/ml/weka/>