

Raport Științific și Tehnic (RST) in extenso proiect HEMACAD

Coordonator Universitatea de Medicina si Farmacie Carol Davila

Hemangiomul reprezintă formațiunea tumorală cel mai frecvent întâlnită la sugar și copilul mic a cărui incidență este dificil de cuantificat din cauza perioadei destul de prelungite pe parcursul careia se poate manifesta. Ultimele date ale American Pediatric Society prezintă un procent de aproximativ 5% incidență a hemangioamelor infantile la sugarii născuți pe teritoriul Statelor Unite ale Americii, până în vârsta de 3 luni. Incideța în zona Europei de est este considerată ca fiind în jurul valorii de 5%.

Pacienții care s-au adresat Clinicii de Chirurgie Pediatrică a spitalului M.S. Curie au fost trimiși de către medici de familie, dermatologi, neonatologi sau ginecologi. Unele cadre medicale din aceste categorii au beneficiat de informarea noastră prealabilă asupra patologiei HI ce a fost efectuată prin elaborarea unei broșuri informative de către echipa de cercetători UMF, aceasta fiind realizată în urmă cu un an și prezentată în cadrul unei evaluări anterioare (Figura 1). Broșurile au fost distribuite și în cadrul mai multor congrese naționale de pediatrie și chirurgie pediatrică desfășurate pe parcursul anului 2016.



Ce sunt Hemangioamele Infantile (HI)?

HI reprezintă cele mai frecvente formațiuni tumorale, benigne, de origine vasculară care apar de la vârsta de sugar. Ele apar în grupuri mari și Asociațiilor Vascular.

Informații generale

50% dintre HI sunt leziuni prezente de la naștere, iar restul de 50% apar în primele săptămâni de viață.

Incidența lor variază de la 2% la naștere la 11% până la sfârșitul primului an de viață.

Frecvența de 30% la noi născuți prematur cu greutate la naștere sub 1500 g.

Sunt mai des întâlnite la sexul feminin și la copii din zona europeană.

Localizările cele mai frecvente sunt la nivelul capului și gâtului, umărului de trunchi, extremităților și foarte rar la nivelul zonei genitale.

Proiectul de cercetare

Studiul se adresează tuturor pacienților care prezintă la naștere sau sub 6 săptămâni de la naștere formațiuni tumorale. Părinții trebuie informați din cele mai bune surse medicale pentru a se asigura un diagnostic și în funcție de localizare, vârstă și complicații posibile, să se stabilească cel mai potrivit un management terapeutic adecvat.

O adresabilitate crescută a pacienților surselor prezente aparține unor complicații estetice și funcționale importante. Vârsta ideală a primului consult este cea de 2 luni.

Studiile clinice prezentate în tabel se vor realiza cu o succesiune de examinări ecografice de 10-15 secunde, pe parcursul întregii perioade de tratament.

Definiție	Clinică
1. Prezența formei (definiție)	Pele albă/roșie, tumefacție
2. Localizare	Pele albă/roșie, tumefacție
3. Prezența formei (definiție)	Definiție: tumefacție albă/roșie, tumefacție albă/roșie, tumefacție albă/roșie, tumefacție albă/roșie
4. Localizare	Definiție: tumefacție albă/roșie, tumefacție albă/roșie, tumefacție albă/roșie, tumefacție albă/roșie
5. Prezența formei (definiție)	Definiție: tumefacție albă/roșie, tumefacție albă/roșie, tumefacție albă/roșie, tumefacție albă/roșie

Prevenirea complicațiilor estetice și funcționale ale copilului

Pentru a vizualiza mai multe informații asupra proiectului de cercetare HEMACAD puteți accesa site-ul <http://img-pub.ro/hamcad/> sau puteți să ne contactați la unul din telefoanele listate mai jos.

Contactați-ne

Spitalul Clinic de Urgență pentru Copii "M.S. Curie"

Bd. C-de Brancoveanu nr. 20 Sector 4 București, 021 440 42 40 (24h)

51 Dr. Isabela Draghici +4 0744 364 636

Dr. Maria Popescu +4 0723 406 867

Figura 1. Broșură informativă pentru pacienți și cadrele medicale

Ca și alte metode de promovare a proiectului a fost realizat un poster cu denumirea "Proposal for future diagnosis and management of facial infantile hemangioma using automatic software for image processing and statistic prediction" care a fost prezentat și o prelegere a fost susținută în cadrul congresului European al Asociației de Chirurgie Pediatrică ce a avut loc la Milano între 15 -18 Iunie 2016 (Figura 2). Acest poster a fost distribuit ulterior și către clinicile de ginecologie, dermatologie și pediatrie pentru a susține implicarea cadrelor medicale în campania de recrutare a pacienților.

În literatura de specialitate cel mai frecvent hemangioamele infantile sunt prezentate ca tumori benigne vasculare care au specificul că nu sunt prezente de la naștere în marea majoritate a cazurilor, dar se manifestă până în jurul vârstei de 3 săptămâni. Cazurile care s-au adresat Clinicii de Chirurgie a Spitalului M.S. Curie au avut vârste cuprinse între 2 săptămâni și 6 ani. Vârsta medie de introducere în studiu a pacienților este prezentată în Figura 3 și repartizată în funcție de sexul feminin sau masculin și în final per total.

Echipa de medici ai UMF a studiat și analizat toți pacienții care prezintă anomalii vasculare și care s-au adresat clinicii M.S. Curie București. În urma examinării clinice și paraclinice s-a efectuat diagnosticul diferențial al HI cu malformațiile vasculare și pacienții încadrați în prima categorie au fost introduși în cadrul studiului. Grupul de lucru al HEMACAD a fost împărțit în mai multe categorii în funcție de tipul de tratament care a fost indicat de medicul curant: scleroterapie prin injectare de Bleomicina intralezional, tratament medicamentos folosind Propranolol tablete de 10 mg, excizie chirurgicală și supraveghere medicală atentă fără intervenție terapeutică din exterior. În figura 4 aveți prezentat procentajul pentru fiecare tip de management terapeutic al studiului, numărul actual de pacienți fiind de 42 iar în figura 5 durata medie a tratamentului fiecărui pacient în funcție de tratamentul primit.

Nu am cuprins în loturile de pacienți nici un caz care să prezinte afectare a zonei ano-genitală, oculară sau auriculară, din cauza dificultăților de evaluare a datelor clinice și mai ales de efectuare a unei evaluări ecografice de acuratețe. De asemenea aceste cazuri prezintă cele mai frecvente complicații ulcerative sau hemoragice care ar fi afectat înregistrarea datelor necesare (Figura 6).

Pentru lotul tratat cu Propranolol se mențin aceleași indicații prezentate în raportarea pe anul 2015. Evaluarea pacienților se efectuează în continuare lunar și constă în recoltarea de date anamnestice, efectuarea unor fotografii cu precizarea dimensiunilor formațiunii tumorale prin măsurare, măsurarea tensiunii arteriale și a alurii ventriculare și efectuarea unei ecografii Doppler de control a unei zone bine delimitată a hemangiomului. Doar la prima evaluare este necesară internarea pacientului pentru efectuarea tuturor consulturilor necesare și supravegherea administrării primelor doze de medicație.

Răspunsul la tratament a fost favorabil în toate cazurile de administrare de Propranolol cu o rată de ameliorare mai crescută în primele luni de terapie (Figura 7). Datele clinice și imagistice au fost înregistrate și trimise pentru procesare în vederea confirmării automate a observațiilor medicale.

În privința lotului de tratament prin scleroterapie, numărul pacienților a fost scăzut pe perioada anului 2016 din cauza absenței din farmacia spitalului a substanței folosite (Bleomicină) cât și din cauza insistenței aparținătorilor de a fii introduși în lotul tratat cu Propranolol. Această metodă a fost utilizată mai ales în cazul HI de la nivelul toracelui și extremităților și a avut un procent de succes ridicat după 5 -6 ședințe de scleroterapie (Figura 8).

PROPOSAL FOR FUTURE DIAGNOSIS AND MANAGEMENT OF FACIAL INFANTILE HEMANGIOMA USING AUTOMATIC SOFTWARE FOR IMAGE PROCESSING AND STATISTIC PREDICTION

Maria Delia Popescu¹, Isabela Magdalena Draghici¹, Ionut Fernando Secheli²,

Marian Amado Secheli², Anca Maria Raicu², Liviu Draghici¹

¹University of Medicine and Pharmacy "Carol Davila" Bucharest,

²Department of Pediatric Surgery, „Maria Sklodowska Curie” Emergency Clinical Hospital for Children, Bucharest

Introduction

Infantile Hemangiomas are the most frequent vascular tumors in children. Specific types of hemangiomas, due to the location, dimensions and fast evolution, can determine important functional and aesthetic sequels threatening vital structures by tumor compression and/or may impair vital functions such as breathing, vision, hearing, ingestion. Due to its vascular nature, its physical properties (dimensions, skin texture) are constantly changing, making the diagnosis process and choosing an appropriate therapeutic method difficult.



Facial Hemangiomas

Methods

The study is based on data collected by serial clinical observations correlated with ultrasonographic images, and processed by a computer-aided diagnosis system (CAD).


40 patients are divided into 4 groups according to the treatment management they received: medical, sclerotherapy, surgical and no treatment. The period of evaluation is January 2013 to September 2015.

Computer Aided Diagnosis aims to provide an answer from the computer as a second opinion to help the physician to detect anomalies and quantify the disease progress.



Image acquisition and pre-processing

The usual architecture of a CAD system includes four main modules: a) Image acquisition and pre-processing b) Detection of the region of interest c) The extraction and selection of features d) Evaluation and classification of the detected region of interest



Detection and extraction of features

For each patient there are at least 3 examinations in progress, photo and ultrasound.



Patient at the age of 1 month and 1 year



Results

The software aims to overcome the limitations of current clinical practice and the lack of an interventional plan in the treatment of hemangiomas. The image below presents the segmentation interface of the program.



The results regarding the evolution of the redness and area of the hemangiomas indicates that the best ap-

proach for the facial vascular tumors is the medical treatment.



Conclusions

Creating an automatic image processing and prediction software is important in order to confirm the medical diagnosis and determine the stage of the vascular tumor. The software will examine the type of hemangioma and suggest the best possible approach taking into consideration previous similar cases, thus improving the medical performance.

Acknowledgment

This work was fully supported by the Joint Applied Research Projects "Methods of Prediction of Infantile Hemangioma Evolution Aimed at Preventing Desfigurating Complications by Multiple Intervention Procedures", grant number: PN-II-PT-PC-CA-2013-4-0201, funded by Executive Unit for Higher Education, Research, Development and Innovation Funding (UEFISCDI).

References

- [1] C. Pantelidis, R. Benjamin, H. Cremer, C. Hagel, "Neurocutaneous disorders. Hemangiomas - a clinical and diagnostic approach", Anshan UK 2010, pp 239-284.
- [2] O. Enjolras, M. Wassef, R. Chapot, "Introduction: ISSVA Classification. Color Atlas of Vascular Tumours and Vascular Malformations", New York: Cambridge University Press, 2007, pp. 2-11.
- [3] R. Mattiassi, D. A. Loose, M. Vaghi, "Hemangiomas and vascular malformations", 2009, Springer-Verlag Italia, 9-96.
- [4] S. Zambanini, R. Sablatnig, H. Maier and G. Langs, "Automatic image-based assessment of lesion development during hemangioma follow-up examinations", Artificial Intelligence in Medicine, vol. 50, Iss. 2, 2010, pp. 83-94.
- [5] S. Zambanini, G. Langs, R. Sablatnig, and H. Maier, "Automatic Robust Registration of Cutaneous Hemangiomas for Follow-up Examinations", Proc. of the 31st annual workshop of the Austrian Association for Pattern Recognition (OAGM/AAPR), pp. 121-128, 2007.
- [6] R. C. Gonzalez, R.E.Woods, Digital Image Processing, London; Sydney, Pearson Prentice Hall, 2008, U822541160, 04/G69.

Figura 2. Poster de prezentare HEMACAD la congresul EUPSA 2016




Figura 3. Vârsta medie a pacienților incluși în studiu HEMACAD




Figura 4. Împărțirea pacienților în grupuri de tratament




Figura 5. Durata medie a tratamentului tumorilor vasculare în funcție de atitudinea terapeutică folosită




Figura 6. Procentul celor mai importante patologii asociate HI



Figura 7. Evoluția unui HI tratat cu Propranolol pe parcursul a 4 luni




Figura 8. HI torace anterior tratat cu Bleomicină 5 ședințe

Lotul tratat prin metoda de excizie chirurgicală a inclus pacienții cu HI bine delimitate, la nivelul unor zone de tegument unde există un risc minim de afectare estetică desfigurantă sau acelea care nu au răspuns bine la tratamentul cu Propranolol sau Bleomicină. Riscul anestezico chirurgical din punct de vedere al intervenției este minim și durata de spitalizare nu a depășit 3 zile.



Figura 9. HI coapsă stângă excizat chirurgical

Pentru tratarea leziunilor restante ce afectează mai ales colorația tegumentului, pacienții vor fi rechemati pentru evaluare în momentul debutului tratamentului cu laser. Implementarea acestei noi metode de tratament va duce la creșterea gradului de ameliorare estetică și funcțională a leziunilor restante după tratamentul medicamentos, scleroterapic sau chirurgical. Un astfel de aparat pentru Laser terapie a fost achiziționat de către coordonatorul UMF, iar membrii echipei de cercetare efectuează cursuri de training pentru a putea demara utilizarea în condiții de siguranță a tratamentului laser.

PARTENER 1 - Universitatea Politehnica din București

Conținut

1.	Introducere.....	
2.	Baza de date.....	
3.	Pre-procesarea datelor.....	
4.	Segmentarea.....	
4.1.	Metoda Otsu.....	
4.2.	Clustering cu Fuzzy C-Means (FCM).....	
4.3.	RG-FCM (Region Growing bazat pe algoritmul FCM).....	
4.4.	Segmentarea folosind SOM-MMRNC.....	
5.	Evoluția hemangiomului.....	
5.1.	Calculul dimensiunii ariei unui pixel de hemangiom.....	
5.2.	Calculul roșeții relative a hemangiomului față de piele.....	
5.3.	Decizia automată a evoluției hemangiomului folosind logica fuzzy.....	
6.	Registration.....	
7.	Rezultate.....	
7.1.	Rezultatele segmentării.....	
7.2.	Rezultatele monitorizării.....	
7.3.	Rezultate pentru registration.....	

1. Introducere

Proiectul propune dezvoltarea unor metode avansate pentru măsurarea precisă și obiectivă a leziunilor specifice hemangioamelor infantile și totodată pe predicția evoluției acestora cu scopul determinării soluției terapeutice optime.

Echipa UPB s-a axat pe studiul metodelor de preprocesare, aliniere, segmentare, extragere de trăsături precum și monitorizarea și evaluarea zonelor de hemangiom, în concordanță cu activitățile fazei curente. Astfel, în prezentul raport vor fi descrise, pe rând, conform opis-ului de mai sus, metodele propuse și rezultatele obținute.

2. Baza de date

Baza de date constă în 79 de perechi de imagini cu hemangiom în diferite regiuni ale corpului: cap, față, gât, picioare etc. În fiecare pereche, ambele imagini surprind același hemangiom la diferite momente de timp, intervalul putând fi de săptămâni sau luni. Imaginile au fost capturate în diverse condiții de iluminare, cu diferite tipuri de camera foto, cu copilul stând natural în diverse poziții.

- Deoarece imaginile au fost capturate de la diverse distanțe față de subiect, este nevoie de prezența unui instrument de măsură (centimetru) în imagine pentru a putea calcula aria. Pentru numai 24 perechi de imagini un centimetru este prezent lângă hemangiom în ambele imagini ale unei perechi, deci monitorizarea evoluției ariei și în consecință a hemangiomului a fost posibilă doar pentru aceste 24 de perechi. Toate cele 79 de perechi au fost folosite însă pentru a calcula evoluția roșeții.
- Dintre toate cele 158 de imagini, 33 au fost etichetate manual de un specialist în două clase (hemangiom și non-hemangiom). Doar aceste imagini au fost folosite pentru a evalua calitatea segmentării




Figura 2.1. Exemple de perechi de poze cu hemangiom (a cu b; c cu d)




Figure 2.2. Exemplu de extragere a regiunii de interes (ROI)

a) Imagine originală b) ROI c) Rezultatul etichetării manuale

3. Pre-procesarea datelor

Dată fiind natura și caracteristica de *redness* a hemangioamelor, fiecare regiune de interes este convertită din spațiul de culoare RGB în spațiul de culoare CIE-L*a*b*, unde nivelul de cromaticitate a^* este cel de interes; nivelul de cromaticitate a^* deține poziționarea culorii între roșu și verde, separarea lor, cu cele mai mici valori pentru nivelul verde și cel mai ridicat pentru roșu. De asemenea, ca parte de pre-procesare, ulterior, o funcție de întindere a contrastului este aplicată pentru a aduce valorile în intervalul 0 și 255.

$$I_N = \frac{255}{M_a - m_a} \cdot (I_a - m_a) \quad (3.1)$$

unde: M_a și m_a reprezintă valoarea maximă, respectiv, valoarea minimă a nivelului de cromaticitate pentru stratul a^* , iar I_a reprezintă valoarea inițială de luminanță, respectiv I_N reprezintă valoarea de luminanță după transformarea de întindere a contrastului.




Figure 3.1. a) ROI b) ROI în planul a^* după transformarea de întindere a contrastului

4. Segmentarea

Segmentarea automată pentru toate metodele implementate de noi pornește de la regiunile de interes (ROI) definite, iar performanța algoritmilor este evaluată în raport cu măștile de referință obținute prin etichetarea manuală a pixelilor. Au fost luate în considerare patru metode de segmentare: 1) segmentarea pe histogramă folosind un prag adaptiv (metoda Otsu), 2) clustering cu Fuzzy C-Means (FCM) 3) un algoritm îmbunătățit de creștere a regiunilor bazat pe FCM (RG-FCM) și 4) un algoritm de segmentare folosind rețeaua SOM urmată de metode morfologice de reducere a numărului de clase (SOM-MMRNC)

4.1. Metoda Otsu

Metoda Otsu realizează automat segmentarea imaginilor cu nivele de gri, pentru a separa un obiect de fundal. Folosind histograma nivelelor de gri, metoda alege automat pragul care produce separarea optimă între cele două clase, în sensul maximizării dispersiei între clase [3]. Considerând o imagine de nivele de gri cu N pixeli, cu nivelurile de gri în intervalul: $i = 1 \dots L$, având n_i pixeli cu nivelul de intensitate i , precum și distribuția de probabilitate a histogramei normalizate: $p_i = n_i / N$, atunci, pentru o valoare de prag k , dispersia inter - clase este:

$$\sigma_B^2(k) = \frac{[\mu_T \omega(k) - \mu(k)]^2}{\omega(k)[1 - \omega(k)]} \quad (4.1)$$

unde: $\mu_T = \sum_{i=1}^L i p_i$, $\omega(k) = \sum_{i=1}^k p_i$, $\mu_k = \sum_{i=1}^k i p_i$

Pragul optim k^* este ales:

$$\sigma_B^2(k^*) = \max_{1 < k < L} \sigma_B^2(k) \quad (4.2)$$

În cazul nostru, metoda a fost aplicată pe planul a^* (cu contrast îmbunătățit) din spațiul de culoare L*a*b*, pentru zona din imagine selectată. Toți pixelii cu valori mai mari decât pragul determinat prin metoda Otsu au fost considerați de hemangiom.

Un exemplu de segmentare folosind metoda Otsu este prezentat în Figura 4.1.




Figura 4.1. a) ROI; b) histograma planului a^*
c) etichetarea manuală a hemangiomului; d) segmentarea cu Otsu - valoarea pragului detectată automat = 121

4.2. Clustering cu Fuzzy C-Means (FCM)

FCM este o metodă de clustering, care permite fiecărui pixel al imaginii să aparțină la două sau mai multe clustere printr-o funcție de apartenență [4]. Algoritmul FCM se bazează pe optimizarea iterativă a următoarei funcții obiectiv:

$$J(U, V) = \sum_{i=1}^n \sum_{j=1}^c (u_{ij})^m \|x_i - c_j\|^2 \quad (4.3)$$

unde: m se numește “indice fuzzy”, $m \in [1, \infty]$, u_{ij} este gradul de apartenență al pixelului x_i la clusterul j , iar c_j este centrul clusterului.

La fiecare iterație a FCM se actualizează atât gradul de apartenență u_{ij} cât și centrul clusterului c_j , și se recalculează funcția obiectiv.

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}, \quad c_j = \frac{\sum_{i=1}^n u_{ij}^m x_i}{\sum_{i=1}^n u_{ij}^m} \quad (4.4)$$

Procesul iterativ se oprește când valoarea minimă J este atinsă. În cazul nostru, metoda a fost aplicată pe planul a^* din spațiul de culoare $L^*a^*b^*$, pentru regiunea selectată. După segmentarea cu FCM, toți pixelii aparținând clasei cu media cea mai mare au fost considerați pixeli de hemangiom. Un exemplu de segmentare folosind metoda FCM este prezentat în Figura 4.2.



Figura 4.2. a) ROI; b) rezultatul segmentării cu FCM

4.3. RG-FCM (Region Growing bazat pe algoritmul FCM)

Deoarece modulele anterioare au efectuat deja o segmentare aproximativă a zonelor de hemangiom și non-hemangiom, modulul de creștere a regiunilor a fost adaptat pentru a îmbunătăți segmentarea în zonele de frontieră. În mod similar cu [5], algoritmul de region growing propus (RG-FCM) pornește de la rezultatele obținute cu algoritmul FCM. RG-FCM are nevoie de mediile claselor obținute prin FCM.

Fie m_H media clasei de hemangiom și m_{NH} media clasei de non-hemangiom determinate cu intensitățile pixelilor FCM. Deoarece intensitatea pixelilor hemangiomului este în general mai mare decât intensitatea pixelilor de non-hemangiom, considerăm că $m_H > m_{NH}$. Algoritmul RG-FCM este alcătuit din următoarele etape:

- Se determină valoarea minimă pentru clasa hemangiom (min_H), valoarea maximă pentru clasa de non-hemangiom (max_{NH}) și pragul T_{FCM} dintre clase:

$$T_{FCM} = \frac{min_H + max_{NH}}{2} \quad (4.5)$$

- Punctele de start (“seeds”) pentru RG-FCM sunt reprezentate de toți pixelii care au intensitățile peste un anumit prag. Pragul depinde de rezultatele algoritmului FCM:

$$T_{seeds} = \frac{m_H + T_{FCM}}{2} \quad (4.6)$$

- Aceste puncte sunt deja bine clasificate ca hemangiom, astfel încât modulul de creștere a regiunilor acționează ca un algoritm de reglaj fin, la marginea suprafeței punctelor. Regiunea este crescută folosind formula:

$$|I_a - regionMean| < maxDiff \quad (4.7)$$

$$unde \quad maxDiff = \frac{2(m_H - T_{FCM})}{3}$$

În Figura 4.3 este un exemplu de calcul al parametrilor algoritmului RG-FCM.




Figure 4.3. Exemplu de parametri pentru RG-FCM

4.4. Segmentarea folosind SOM-MMRNC

(Self Organizing Map followed by a Morphological Method of Reducing the Number of Classes)

Scopul acestei metode îl constituie segmentarea automată a regiunilor de hemangiom de orice altceva; la final vor rezulta doar două clase (hemangiom și non-hemangiom). Utilizarea grupării SOM cu doar două clase (doi neuroni în stratul de ieșire) nu produce rezultate mai bune decât metodele statistice. Prin urmare, rețeaua SOM dezvoltată de Kohonen [2] este supradimensionată la $K \times K$ clase, obținând o grupare mai fină (algoritmul e descris în secțiunea 4.1). Procedând astfel, pixelii hemangiomului sunt de asemenea divizați în mai multe clase, astfel încât după gruparea SOM pasul următor este separarea automată între clasele de hemangiom și clasele de non-hemangiom.

4.1. Arhitectura SOM și rezultatele algoritmului de clustering

După finalizarea învățării, toate distanțele sunt calculate între pixelii de intrare și prototipurile neuronilor (ponderile). Fiecare pixel este clasificat în clasa c_k pentru care s-a obținut distanța minimă D_k . În conformitate cu gruparea SOM, o regiune de interes este, prin urmare, segmentată în 25 de clase, un exemplu fiind prezentat în Figura 4.4.




Figura 4.4. a) imaginea originală; b) planul a^* din CIE $L^*a^*b^*$; c) imaginea segmentată în 25 de clase folosind SOM clustering

Am sortat nodurile SOM conform valorilor prototipurilor. Fie ordinea neuronilor $N_1, N_2, \dots, N_{25}$, unde N_1 este neuronul cu prototipul cel mai similar hemangiomului și N_{25} neuronul cu prototipul cel mai puțin similar hemangiomului. Cu ajutorul acestor valori descendente, am calculat un set de măști cumulative; acestea sunt măști alb-negru create în conformitate cu următoarele reguli: *Masca_1* evidențiază doar pixelii care sunt grupați sub neuronul N_1 ; *Masca_2* evidențiază doar pixelii care sunt grupați sub neuronii N_1 și $N_2, \dots$ și așa mai departe. Așa cum era de așteptat, *Masca_25* scoate în evidență toți pixelii. Un exemplu de un set de măști este reprezentat în Fig. 4.5. Pasul următor este determinarea măștii care generează segmentarea optimă.

4.2. Determinarea măștii optime

În cele mai multe cazuri am observat că regiunile hemangiomului au de obicei margini netede și rotunjite (și foarte puține "lacune" ascuțite sau "tentacule"). Pornind de la această observație, am calculat netezimea și apoi am determinat masca cu cele mai netede contururi.




Figura 4.5. Exemplu de 25 de măști obținute din imaginea din Fig. 3; a) Pixelii grupați sub neuronul N_1 ; b) Pixelii grupați sub neuronul N_1 și $N_2, \dots, y$

4.2.1. Calculul netezimii măștilor

Netezimea fiecărei măști este calculată folosind algoritmul descris mai jos:

Pentru fiecare $Mask_k$:

- Calculează închiderea măștii $Mask_closed_k$ prin închidere morfologică
- Calculează $Num_closed(k)$, care este numărul de pixeli ce diferă între $Mask_k$ și $Mask_closed_k$
- Calculează deschiderea măștii $Mask_opened_k$ prin deschidere morfologică
- Calculează $Num_opened(k)$, care este numărul de pixeli ce diferă între $Mask_k$ și $Mask_opened_k$
- Calculează netezimea imaginii folosind formula:

$$Smoothness(k) = Num_closed(k) + Num_opened(k) \quad (4.8)$$

4.2.2. Aplicarea unui filtru cvasi-median pentru netezire

Așa cum a fost descris la secțiunea 4.2.1, obiectivul este de a găsi minimul văii dintre primul și ultimul maxim local. Cu toate acestea, există cazuri când minimul pe linia albastră (Fig. 5), apare într-o altă locație decât cea sugerată de tendința generală a văii. În scopul de a corecta minimele ciudate ca acestea, am folosit un filtru cvasi-median de netezire.

$$qmSmoothness(k) = medianSmoothness(k) \cdot 0.75 + meanSmoothness(k) \cdot 0.1 + Smoothness(k) \cdot 0.15 \quad (4.9)$$

unde $medianSmoothness$ este rezultatul aplicării unui filtru median de lungime 3 și $meanSmoothness$ este rezultatul aplicării unui filtru de mediere de lungime 3. $qmSmoothness$ este desenată în Figura 4.6 cu o linie verde. Prin aplicarea unui filtru median, am eliminat extremele și am obținut tendința generală a netezimii, prin urmare, componenta mediană are cel mai mare coeficient. Dacă am fi utilizat numai componenta mediană, am fi ajuns la situația că minimul văii se află la două sau trei locații adiacente; prin urmare, avem nevoie de o componentă de filtrare medie și un eșantion pentru a putea face distincția între aceste valori egale ale componentei mediane.

4.2.3. Excluderea extremelor

Toate valorile $qmSmoothness$ până la primul maxim local sau după ultimul maxim local sunt excluse de la căutarea de minim local, deoarece acestea nu sunt în vale. În plus, este puțin probabil ca toți pixelii de hemangiom să fie grupați în primii neuroni, astfel că primii 2 neuroni sunt excluși de la căutare. De asemenea, este puțin probabil ca pixelii de hemangiom să fie grupați în mai mult de 70% din neuroni, prin urmare, ultimele 8 valori sunt de asemenea excluse de la căutare. În Figura 4.6, valorile excluse sunt marcate cu un eșantion roșu.




Fig. 4.6. Linia albastră = netezirea pentru fiecare mască; linia verde = $qmSmoothness$ pentru fiecare mască; linii roșii = măști excluse; disc violet = masca selectată (în acest caz $Mask_{14}$)

4.2.4. Decizia

Decizia se bazează pe locația minimului global pe linia verde (după excluderea extremelor), marcată cu un disc violet. De cele mai multe ori, minimul pe linia albastră și minimul pe linia verde se află în aceeași locație, dar în cazul în care acestea sunt diferite, minimul verde conferă o grupare mai bună.

5. Evoluția hemangiomului

Urmărirea evoluției hemangiomului este importantă pentru deciziile ce se vor lua privind tratarea acestuia. Evoluția hemangiomului se manifestă prin modificarea dimensiunii și a culorii lui. Progresul bolii se manifestă prin creșterea ariei și prin intensificarea culorii hemangiomului; în cazul regresiei bolii, suprafața hemangiomului se micșorează iar culoarea lui se atenuează. Pentru a aprecia modul de evoluție a bolii în cazul unui pacient, pe baza unei perechi de fotografii luate la momente diferite de timp, s-a propus o metodă care să evalueze schimbările produse atât în dimensiunea cât și în intensitatea culorii hemangiomului.

În figura 5.1 este prezentată schema logică a operațiilor efectuate asupra fiecărei imagini înaintea efectuării comparației celor două caracteristici pentru două momente de timp diferite:

- Segmentarea regiunii de interes (ROI)
- Calculul ariei hemangiomului (cm^2)
- Calculul roșeții relative a hemangiomului față de pielea înconjurătoare

Pe baza celor două caracteristici extrase pentru fiecare imagine din perechea de imagini se apreciază evoluția în timp atât a roșeții relative cât și a suprafeței hemangiomului respectivului pacient. Având evoluțiile legate de suprafața și de roșeața relativă, pe baza unui sistem cu logică fuzzy se apreciază evoluția hemangiomului: staționar, involuție sau progres a bolii.




Figura 5.1. Schema logică pentru detecția roșeții relative și a ariei hemangiomului

Segmentarea regiunii de interes

Calculul ariei hemangiomului se face pe baza rezultatului obținut cu metoda FCM (Fuzzy C- means). Un exemplu de rezultat obținut cu FCM este prezentat în Figura 4.2.

5.1. Calculul dimensiunii ariei unui pixel de hemangiom

Determinarea dimensiunii unui pixel de hemangiom (în cm^2) este necesară în vederea determinării ariei întregului hemangiom pentru a transforma aria exprimată în pixeli (arie cunoscută în urma segmentării) în arie exprimată în centimetri pătrați. În plus, calculul ariei este necesar la compararea dimensiunii ariei hemangiomului la momente diferite de timp. În vederea calculului ariei unui pixel de hemangiom este necesar ca imaginea să conțină o riglă lângă hemangiom.



Figura 5.2. Selectarea lungimii de 1cm (punctele roșii)

Pentru a putea face calculul, utilizatorul trebuie să selecteze prin două click-uri lungimea de un centimetru. Se extrage apoi parametrul d care este dimensiunea în pixeli pentru un centimetru. Rezultă de aici că aria unui pixel de hemangiom este: $A_p = \frac{1}{d^2} \text{cm}^2$. Din segmentarea regiunii de interes se determină numărul N de pixeli de hemangiom. Aria hemangiomului în cm^2 va fi:

$$A = N \cdot A_p = \frac{N}{d^2} \text{cm}^2 \quad (5.1)$$

5.2. Calculul roșeții relative a hemangiomului față de piele

Fiecare regiune de interes (ROI) este mai întâi segmentată utilizând algoritmul Fuzzy C-means cu două clase. Funcțiile de apartenență conțin gradele de apartenență ale fiecărui pixel la fiecare clasă. Valoarea 0 sau 1 indică neapartenența, respectiv totală apartenență a unui pixel la o clasă. Gradele între 0 și 1 indică apartenența parțială a unui pixel la o clasă. În scopul descreșterii riscului de a obține o falsă clasificare a unui pixel ca fiind de hemangiom sau de piele, se utilizează praguri de valori mai mari decât valoarea implicită: un pixel e declarat ca fiind de hemangiom dacă gradul lui de apartenență la clasa *hemangiom* este mai mare decât 0.6, iar un pixel e declarat ca fiind de piele dacă gradul lui de apartenență la clasa *piele* este mai mare decât 0.95. Pixelii care nu satisfac nici unul dintre aceste criterii sunt trecuți într-o a treia clasă (Figura 5.3).

Pentru aprecierea intensității roșeții hemangiomului, deoarece imaginile pot fi făcute în condiții de iluminare diferite, vom utiliza roșeața relativă calculată ca diferență între roșeața hemangiomului și roșeața pielii înconjurătoare.




Figura 5.3 a) Imaginea originală; b) Regiunea de interes (ROI); c) Regiunea de interes segmentată prin folosirea FCM; d) galben = pixeli de non-hemangiom (folosiți la calculul roșeții relative), turcoaz = pixeli de hemangiom (folosiți la calculul roșeții relative), albastru = pixeli excluși de la calculul roșeții.

Roșeața fiecărei clase (hemangiom și non hemangiom) este calculată cu formula (5.2):

$$f_R(S) = \frac{1}{|S|} \sum_{i \in S} \frac{2(S_R)_i - (S_G)_i - (S_B)_i}{2((S_R)_i + (S_G)_i + (S_B)_i)} \quad (5.2)$$

unde S este suprafața pentru care se calculează caracteristica de tip roșeață iar $(S_R)_i, (S_G)_i, (S_B)_i$ sunt valorile canalelor R, G, B ale unui pixel din această suprafață. Se calculează astfel o valoare a intensității roșeții pentru hemangiom și una pentru piele (non-hemangiom).

Caracteristica de roșeață relativă este calculată ca diferența dintre roșeața zonei de hemangiom $f_R(\text{Hemangiom})$ și roșeața zonei de piele înconjurătoare (non-hemangiom) $f_R(\text{nonHema})$.

$$dR = f_R(\text{Hemangiom}) - f_R(\text{nonHema}) \quad (5.3)$$

5.3. Decizia automată a evoluției hemangiomului folosind logica fuzzy

În Figura 5.4 este reprezentată schema logică a sistemului de detecție și evaluare a evoluției hemangiomului pe baza unui sistem cu logică fuzzy bazat pe doi parametri: *suprafața* și *roșeața relativă*.

Utilizând pentru fiecare imagine perechea de caracteristici (*roșeața relativă* și *aria*) vom calcula evoluția în timp a intensității roșeții și evoluția dimensiunii ariei pentru fiecare pacient. Aceste doua marimi sunt utilizate într-un sistem cu logica fuzzy pentru a aprecia evoluția bolii. Sistemul cu logică fuzzy utilizează funcții de apartenență. O funcție de apartenență este o curbă care definește modul în care fiecare punct al spațiului de intrare ii este alocată o valoare a gradului de apartenență între 0 și 1. Primul pas este de a alocă fiecărei intrări gradul ei de apartenență la fiecare multime fuzzy prin funcția de apartenență. Intrarea este întotdeauna o valoare în intervalul $[-100\%, 100\%]$ (deoarece parametrii de intrare, aria și roșeața relativă, reprezintă valori procentuale). În cazul nostru sunt 2 date de intrare: *aria* și *roșeața relativă*. Pentru fiecare dată de intrare sunt 3 funcții de apartenență: *descreștere*, *staționaritate* și *creștere* (Figurile 5.5 și 5.6).

Funcția de apartenență optimă pentru fiecare multime fuzzy este găsită printr-un proces de încercare și eroare (*trial and error process*). În procesul de recunoaștere, sistemul fuzzy, prin utilizarea funcțiilor de apartenență de intrare, calculează gradele de recunoaștere atât pentru *arie* cât și pentru *roșeața relativă*. Intrările sunt procesate de sistemul fuzzy logic pe baza unor reguli fuzzy bine definite. În cazul nostru, regulile sunt:

1. dacă (aria descrește) și (roșeața descrește) atunci (output1 regresează)
2. dacă (aria descrește) și (roșeața este staționară) atunci (output1 regresează)
3. dacă (aria descrește) și (roșeața crește) atunci (output1 este staționară)
4. dacă (aria crește) și (roșeața descrește) atunci (output1 este staționară)
5. dacă (aria crește) și (roșeața este staționară) atunci (output1 progresează)
6. dacă (aria crește) și (roșeața crește) atunci (output1 progresează)
7. dacă (aria este staționară) și (roșeața descrește) atunci (output1 este staționară)
8. dacă (aria este staționară) și (roșeața este staționară) atunci (output1 este staționară)
9. dacă (aria este staționară) și (roșeața crește) atunci (output1 progresează)

În Figura 5.8 este o reprezentare grafică a acestor reguli.




Figura. 5.4. Schema logică a sistemului automat de monitorizare a evoluției hemangiomului folosind sistemul cu logică fuzzy bazat pe doi parametri: *aria* și *roșeața relativă*.




Figura 5.5. Funcțiile de apartenență pentru *arie*




Figura 5.6. Funcțiile de apartenență pentru *roșeața relativă*

Corespunzător, pentru fiecare dată de ieșire, trei funcții de apartenență vor fi definite ca: *regres*, *staționaritate* și *progres* (Figura 5.7).




Figura 5.7. Funcțiile de apartenență pentru ieșirea *output1* (evoluția)




Figura 5.8. Reprezentarea grafică a regulilor

În testele efectuate de noi am evaluat patru aspecte: A) evoluția dimensiunii suprafeței hemangiomului care poate fi: *descrescătoare*, *crescătoare*, *staționară*; B) evoluția roșeții relative a hemangiomului față de piele, care poate fi: *intensificată*, *atenuată* sau *staționară*; C) evoluția hemangiomului pe baza modificării suprafeței și a roșeții relative care poate fi: *regres*, *progres*, *staționaritate* și D) potrivirea automată a suprafeței hemangiomului. Pentru punctele A, B și C am utilizat ca referință deciziile expertului/medicului.

6. Registration

În secțiunea anterioară am stabilit că evoluția și monitorizarea hemangiomelor este bazată pe cei doi parametri: suprafață și nivelul de roșeață - redness. Însă, este de asemenea utilă pentru înțelegerea modului în care se modifică/evoluează hemangiomul suprapunerea regiunilor la două momente de timp. De aceea, ariile hemangiomelor vor necesita re-scalarea (A), pentru consecvența comparației, și rotația (B), în scopul de a avea aceeași orientare a regiunilor. Pornind de la ideea prezentată în [1], am dezvoltat o metodă proprie de potrivire, după cum se poate vedea în Figura 6.1

A. Rescalarea ariilor de hemangiom

Pentru fiecare subiect, imaginile de hemangiom sunt preluate la diferite momente de timp, cu camere diferite și cu diferiți parametri de distanță și orientare. Din secțiunea IVB avem extrasi parametrii A_{p1} și A_{p2} , reprezentând aria hemangiomului din fiecare imagine, astfel că următorul pas este de a aduce ambele regiuni de interes la aceeași scală raportată la aria reală. Întrucât procedura de rescalare introduce zgomot, abordarea a constat în rescalarea unei singure imagini. Because resizing usually introduces noise, the decision was to only resize one image cu un factor egal cu radicalul raportului dintre cele două arii corespunzătoare.

dacă ($A_{p1} > A_{p2}$), modifică ROI₁ cu factorul $\sqrt{\frac{A_{p2}}{A_{p1}}}$ altfel, modifică ROI₂ cu factorul $\sqrt{\frac{A_{p1}}{A_{p2}}}$




Fig.6.1. Metoda de potrivire automată a zonelor de hemangiom

B. Ajustarea orientării zonelor de hemangiom

Pentru setul de date existent, perechile de imagini sunt preluate la diferite stadii de dezvoltare a hemangiomului, astfel că forma acestora este aproximativ similară. Orientarea axei principale a elipsei e realizată cu aceleași momente de ordinul 2, deoarece regiunea de interes are pentru fiecare ROI o valoare (număr de grade între -90 și +90) v_1 și v_2 respectiv. Prin rotația ROI₂ cu v_1-v_2 , regiunile de interes pot fi aliniate corect sau incorect (când ROI₂ necesită o rotire de 180 grade). Pentru a stabili dacă acest pas de rotire este sau nu necesar, se calculează corelațiile normalizate dintre ROI₁ și cele două versiuni ale lui ROI₂ (re-orientate cu v_1-v_2 și cu v_1-v_2-180 grade respectiv). Diferența de orientare aleasă și cea mai bună suprapunere sunt date de cea mai bună corelație rezultată.

7. Rezultate

7.1. Rezultatele segmentării

Pentru a putea evalua performanțele algoritmilor de segmentare, pentru fiecare ROI s-au calculat parametrii *True Negative (TN)*, *True Positive (TP)* și *scorul global (Overall score)* folosind ecuațiile (7.1), (7.2) și (7.3).

$$TN = \frac{\text{numărul de pixeli de nonhemangiom clasificați ca nonhemangiom}}{\text{numărul total de pixeli de nonhemangiom}} \cdot 100 \quad (7.1)$$

$$TP = \frac{\text{numărul de pixeli de hemangiom clasificați ca hemangiom}}{\text{numărul total de pixeli de hemangiom}} \cdot 100 \quad (7.2)$$

$$\text{Overall score} = \frac{TN + TP}{2} \quad (7.3)$$

Figura 7.1 conține o regiune de interes segmentată cu metodele propuse.




Figura 7.1. a) ROI; b) ROI segmentat manual c) rezultat cu Otsu; d) rezultat cu FCM; e) rezultat cu RG-FCM:

roșu = pixeli de hemangiom corect clasificați (TP)
albastru = pixeli de nonhemangiom clasificați ca hemangiom
verde = pixeli de hemangiom clasificați ca non-hemangiom
negru = pixeli de non-hemangiom clasificați ca non-hemangiom(TN)

În Figurile 7.1-7.6 este prezentată o comparație a rezultatelor segmentării obținute cu metodele de segmentare propuse.




Figura 7.2. Compararea rezultatelor în funcție de *TN* [%] pentru fiecare ROI




Figura 7.3. Compararea rezultatelor în funcție de *TP* [%] pentru fiecare ROI




Figura 7.4. Compararea rezultatelor în funcție de scorul global [%] pentru fiecare ROI




Fig. 7.5. Overall Scores obținut cu SOM-MMRNC și FCM pentru fiecare ROI.
Pe axa Ox este reprezentat indicele regiunii de interes




Fig. 7.6. Diferența dintre Overall Score obținut cu SOM-MMRNC și Overall Score obținut cu FCM

În cele 33 de imagini folosite pentru testarea rezultatelor segmentării au fost utilizați 15.242.356 pixeli de non-hemangiom și 15.753.341 pixeli de hemangiom. Calculând scorurile globale TP și TN se obțin rezultatele din Tabel 1.

Tabel 1 Scorul de clasificare globală

Algorithm	Global TP [%] (hemangiom)	Global TN [%] (non-hemangiom)	Scor global [%] (TP +TN)/2
Fuzzy C-means	87.78	90.98	89.38
Otsu	88.23	90.61	89.42
RG-FCM	91.51	89.04	90.27

Figura 7.7 prezintă câteva exemple ale segmentării folosind metodele SOM-MMRNC și FCM.




Figura 7.7. Segmentare cu SOM-MMRNC și FCM

7.2. Rezultatele monitorizării

A. Rezultate ale evoluției redness-ului hemangiomului

Au fost utilizate 79 de perechi pentru a stabili evoluția hemangiomului din punct de vedere al parametrului *redness*. Pentru a putea stabili cum se schimbă redness-ul între două momente succesive de timp, s-a calculat evoluția relativă a redness-ului conform ecuației:

$$D = \frac{dR_2 - dR_1}{dR_1} 100 \quad (7.4)$$

unde dR_1 și dR_2 au fost calculate pentru fiecare pereche în parte, conform formulei 5.3. Empiric au fost alese următoarele praguri:

- dacă $D > 20\%$ atunci redness-ul crește
- dacă $D < -20\%$ atunci redness-ul descrește
- dacă $D \in [-20\%, +20\%]$ atunci redness-ul este staționar

Pentru toate cele 79 de perechi de imagini, evoluția redness-ului a fost corect estimată pentru **86.08%** din cazuri. Pentru cele 24 de perechi folosite și pentru evoluția ariei, rezultatul a fost de **83.33%**.

B. Rezultate ale evoluției ariei hemangiomului

Evoluția ariei hemangiomului a fost testată pentru 24 de perechi de imagini (deoarece doar pentru aceste perechi a existat și un centimetru în imagine). Pentru fiecare pereche s-a calculat o creștere procentuală folosind formula:

$$IncreaseArea = \frac{A_2 - A_1}{A_1} \quad (7.5)$$

unde A_1 și A_2 reprezintă ariile hemangioamelor exprimate în cm^2 . Empiric au fost stabilite următoarele reguli:

- dacă $IncreaseArea < -7\%$ atunci aria descrește
- dacă $IncreaseArea \in [-7\%, +7\%]$, atunci aria este staționară
- dacă $IncreaseArea > 7\%$, atunci aria crește

Folosind aceste reguli s-a obținut un scor de estimare a evoluției suprafeței hemangiomului de **87.5%**. În Tabelul 1 sunt rezultatele obținute pentru cele 24 de seturi de imagini. Rezultatele obținute cu metodele propuse au fost comparate cu diagnosticul medicului.

Tabel 1. Rezultatele estimării ariei și redness-ului

Nr	Redness			Area		
	Valoare	Decizie algoritim	Decizie medic	Valoare	Decizie algoritim	Decizie medic
1	-25.98	Regres	Regres	1.83	Stationaritate	Stationaritate
2	-53.34	Regres	Regres	-7.53	Regres	Regres
3	35.95	Progres	Progres	10.13	Progres	Stationaritate
4	-11.75	Stationaritate	Regres	-13.69	Regres	Regres
5	-27.63	Regres	Regres	-42.73	Regres	Regres
6	-35.08	Regres	Regres	-22.70	Regres	Regres
7	-46.77	Regres	Regres	-51.74	Regres	Regres
8	-17.99	Stationaritate	Regres	-28.14	Regres	Regres
9	0.45	Stationaritate	Stationaritate	3.81	Stationaritate	Stationaritate
10	-48.37	Regres	Regres	-44.72	Regres	Regres
11	-48.61	Regres	Regres	-51.95	Regres	Regres
12	-36.58	Regres	Regres	-36.63	Regres	Regres
13	-12.32	Stationaritate	Regres	-37.63	Regres	Regres
14	38.26	Progres	Stationaritate	-5.54	Stationaritate	Stationaritate
15	-59.39	Regres	Regres	-14.32	Regres	Regres
16	1.26	Stationaritate	Stationaritate	3.87	Stationaritate	Stationaritate
17	-31.16	Regres	Regres	-13.30	Regres	Regres
18	-59.70	Regres	Regres	-26.34	Regres	Regres
19	-32.02	Regres	Regres	-13.35	Regres	Regres
20	-60.20	Regres	Regres	-23.30	Regres	Regres
21	-41.46	Regres	Regres	-20.48	Regres	Regres
22	2.90	Progres	Progres	57.59	Progres	Stationaritate
23	-20.83	Regres	Regres	7.58	Progres	Regres
24	-23.07	Regres	Regres	-34.75	Regres	Regres

C. Rezultate ale estimării evoluției hemangiomului

Pentru evoluția hemangiomului folosind logica fuzzy au fost testate 24 de perechi de imagini. Pentru ieșirea clasificatorului fuzzy am folosit pragurile $Th_1 = 0.45$ și $Th_2 = 0.65$ cu următoarele condiții:

- dacă $(output \leq Th_1) \rightarrow regres$
- dacă $(output > Th_1)$ și $(output < Th_2) \rightarrow stationaritate$
- dacă $(output \geq Th_2) \rightarrow progres$

Folosind rezultatele din Tabel 1 ca intrări pentru sistemul cu logică fuzzy, s-au obținut valorile din Tabelul 2 pentru evoluția hemangiomului.

Tabel 2. Evoluția hemangiomului folosind logica fuzzy

Nr	Output	Evoluția hemangiomului folosind logica fuzzy	Evoluția hemangiomului bazată pe decizia medicului
----	--------	--	--

1	0.37	Regres	Regres
2	0.33	Regres	Regres
3	0.66	Progres	Stationaritate
4	0.44	Regres	Regres
5	0.29	Regres	Regres
6	0.32	Regres	Regres
7	0.23	Regres	Regres
8	0.36	Regres	Regres
9	0.52	Stationaritate	Stationaritate
10	0.25	Regres	Regres
11	0.23	Regres	Regres
12	0.28	Regres	Regres
13	0.42	Regres	Regres
14	0.64	Stationaritate	Stationaritate
15	0.33	Regres	Regres
16	0.52	Stationaritate	Stationaritate
17	0.34	Regres	Regres
18	0.30	Regres	Regres
19	0.34	Regres	Regres
20	0.31	Regres	Regres
21	0.33	Regres	Regres
22	0.66	Progres	Stationaritate
23	0.39	Regres	Regres
24	0.32	Regres	Regres

Așa cum se poate observa din Tabel 2, s-a obținut un scor de estimare a evoluției hemangiomului de 91.67%.

7.3. Rezultate pentru registration

Pentru registration este dificil să se analizeze calitativ și cantitativ rezultatul metodei propuse, cea mai simplă modalitate de evaluare fiind cea vizuală, precum cea din exemplul următor.




Figura 7.8 a) și c) imagini originale; b) și d) ROI₁ și ROI₂ e) Regiuni de interes suprapuse (roșu = suprafață comună, verde = suprafață în ROI₁ care lipsește în ROI₂, albastru = suprafață în ROI₂ care lipsește în ROI₁)

Bibliografie

- [1] Zambanini S., Sablatnig R., Maier H., Langs G., *Automatic image based assessment of lesion development during hemangioma follow-up examinations*, Artificial Intelligence in Medicine, vol. 50, Iss. 2, 2010, pp. 83-94.
- [2] Kohonen T., *Self-Organizing Maps*, Springer Series in Information Sciences, Berlin, Heidelberg, Springer, 2000, ISBN-10: 3540679219, ISBN-13: 978- 3540679219, Edition: 3rd
- [3] N. Otsu, *A Threshold Selection Method from Gray-Level Histograms*, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 9, No. 1, 1979, pp. 62-66.
- [4] J. C. Bezdec, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981
- [5] Ashraf Afifi, *A Hybrid Technique Based on Combining Fuzzy K-means Clustering and Region Growing for Improving Gray Matter and White Matter Segmentation*, (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 3, No. 7, 2012

Algoritmii prezentați în acest raport au fost publicați în următoarele articole:

1. C. Neghină, M. Zamfir, M. Ciuc, A. Sultana, M. Popescu, “Automatic monitoring system for the detection and evaluation of the evolution of hemangiomas”, International Conference on Image Processing Theory, Tools and Applications (IPTA), Oulu, Finland, December 12-15, 2016, (acceptat)
2. C. Neghină, M. Zamfir, M. Ciuc, A. Sultana, “Automatic detection of hemangioma through a cascade of Self-Organizing Map clustering and morphological operators”, Procedia Computer Science, Volume 90, pp. 145 – 150, Published by Elsevier, ISBN: 978-1-5108-2708-0, 2016 (articol prezentat în cadrul conferinței 20th Conference on Medical Image Understanding and Analysis, MIUA 2016, 6-8 July 2016, Loughborough, UK) (ISI)
3. Cătălina Neghină, Marta Zamfir, Alina Sultana, Elena Ovreiu, Mihai Ciuc, “Automatic detection of hemangiomas using unsupervised segmentation of regions of interest”, IEEE International Conference on Communications (COMM), pages: 69 – 72, ISBN: 978-1-4673-8198-7, București, Romania, 9 – 11 June, 2016 (ISI)


Raport de cercetare UVT (2016)

În cea de a treia fază de proiect echipa UVT de tineri s-a concentrat pe:

- Construirea unui sistem CBIR (*Content Based Image Retrieval*) îmbunătățit pentru căutarea imaginilor pe baza trăsăturilor.
- Optimizarea operațiilor de calcul pentru căutare distribuită.

Tehnologiile de căutare CBIR nu sunt toate identice ca arhitectură de calcul. În sistemul anterior propus și implementat în [1], procesul de căutare era compus din următorii pași:

1. Utilizatorul selectează o imagine pentru procesul de căutare
2. Utilizatorul selectează o regiune de interes ROI (ROI-eng. *Region of Interest*) din imaginea de căutare. În funcție de imaginea achiziționată, ROI poate fi și întreaga imagine (Fig. 1)
3. Tot procesul se desfășoară în browser-ul utilizatorului. Tot în browser se extrag trăsăturile imaginii selectate
4. Imaginea ROI și trăsăturile calculate se trimit către server
5. Folosind limbajul de programare SQL se calculează o metrică de tip p (exemplu: $p = 2$ pentru norma Euclidiană) pentru identificarea imaginilor similare
6. Se afișează în browser-ul utilizatorului rezultatele căutării



Imaginea Originala

Imagine ROI

Figura 1. Selectarea imaginii ROI pentru căutare

Principala problemă a sistemului CBIR implementat este următoarea: limitarea algoritmilor de clasificare și căutare de conținut similar în arhitectura CBIR propusă. De exemplu, dacă se folosește o rețea neuronală, atunci calculul matriceal necesar pentru predicție nu se mai poate realiza în mod optim în SQL, deoarece acest limbaj nu a fost creat pentru calcule procedurale complexe. Se poate face o excepție prin crearea unui proceduri stocate într-un dialect proprietar SQL care cuprinde implementate principiile programării structurate, dar dezavantajul constă în creșterea timpului de execuție. În limbajul SQL standard nu se poate aplica pentru fiecare înregistrare din baza de date un calcul matriceal implementat într-o procedură stocată, deoarece folosirea procedurilor stocate pentru calcule seriale asupra setului de înregistrări este foarte inefficientă. În sistemul implementat, s-a constatat experimental că folosirea limbajului SQL permitea optimizarea procesului de căutare distribuită într-o arhitectură *scale in* în rețea a server-ului de baze de date. În acest mod, procesul de calcul paralel distribuit se reducea la o căutare distribuită în nodurile server-ului bazei de date. Este un avantaj din punct de vedere al implementării, dar principalul dezavantaj este limitarea numărului de operații de calcul.

Folosirea trăsăturilor derivate din matricea de coocurență nu a condus la rezultate satisfăcătoare din punct de vedere al predicției evoluției hemangioamelor sau al clasificării acestora datorită constrângerii numărului de operații. Pentru a aceasta vom considera o arhitectură distribuită de calcul bazată pe un cluster de tip Hadoop (exemplu Apache Spark) și tehnici Machine Learning.

Arhitectura Apache Spark distribuită a sistemului CBIR propus

Pentru calcul și căutare distribuită trebuie folosit un limbaj de programare care permite compilarea codului și oferă suport pentru calcul distribuit. Limbajul de programare Java permite folosirea lui Apache Spark împreună cu algoritmi de învățare/clasificare.

Apache Spark este sistem analitic de date în memorie foarte scalabil pentru calcul distribuit. Aplicațiile pot fi dezvoltate în mai multe limbaje de programare: Java, Scala, R și Python. Apache Spark cuprinde patru module principale : SQL, MLlib, GraphX și Streaming. Acestea pot cuprinde alte sub-module conform Figurii 2.




Figura 2. Arhitectura Apache Spark [2]

Algoritmii de tip Machine Learning (ML) sunt implementați în modulul MLib. Modulul conține funcții din următoarele domenii:

- Statistică
- Clasificare
- Regresie
- Clustering
- Optimizare
- Etc.

Trăsăturile extrase vor fi salvate în format tabelar. Pentru accesul la baza de date se folosește modulul Spark SQL care permite accesul la date în format JSON cât și integrarea cu alte sisteme. Formatul JSON (eng. JavaScript Object Notation) este un format text standard care este o alternativă mai simplă la formatul XML pentru schimbul de date între aplicații. Un alt avantaj al formatului JSON este faptul că unele baze de date pot returna datele în format JSON și este mai ușor de folosit într-o aplicație client Web care folosește JavaScript.

Trăsături texturale analizate

Arhitectura distribuită propusă oferă două avantaje principale: atât procesul de învățare, cât și procesul de căutare se realizează se integrează eficient într-o arhitectură de calcul de tip scale-in. Descriptorul texturii este format din trăsăturile extrase dintr-o imagine texturată reprezintă. Pentru sistemul CBIR îmbunătățit, descriptorul texturii este compus din trăsăturilor extrase din matricea de coocurență medie GLCM (Gray Level Coocurrence Mean)[4-5]. Vom folosi următoarele notații:

1. $C_i(d)$ matricea de coocurență pentru direcția i calculată pentru pixelii cu distanța d .
2. Cm_d matricea de coocurență medie pentru pixelii cu distanța d

Formula de calcul pentru Cm_d pentru 4 și 8 este următoarea:

- $Cm_d = \frac{1}{4} \sum_{i=1}^4 C_i(d)$ pentru 4 direcții ($0^\circ, 90^\circ, 180^\circ$ și 270°)
- $Cm_d = \frac{1}{8} \sum_{i=1}^8 C_i(d)$ pentru 8 direcții ($0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ$ și 315°)

Trăsăturile extrase din matricea $Cm(d)$ pentru construirea descriptorului texturii sunt același ca în implementarea anterioară a sistemului CBIR:

Energie:

$$Ene(d) = \sum_i \sum_j Cm_d(i, j)$$

Entropie:

$$Ent(d) = - \sum_i \sum_j Cm_d(i, j) \log(Cm_d(i, j))$$

Contrast:

$$Cont(d) = (i - j)^2 \sum_i \sum_j Cm_d(i, j)$$

Omogenitate:

$$Omo(d) = \sum_i \sum_j \frac{1 - |i - j|}{Cm_d(i, j)}$$

Varianță:

$$Var(d) = \frac{1}{L} \sum_i \sum_j (Cm_d(i, j) - \mu)^2$$

unde:


$$\mu = \frac{1}{L \times L} \sum_i \sum_j Cm_d(i, j)$$

este media aritmetică a matricei de coocurență medie. Pentru clasificare și învățare sunt folosiți algoritmi ML din modulul Apache Spark MLib.

Mai multe detalii despre aceste cercetări vor fi publicate în volumul unei conferințe internaționale în 2017.

Echipa de cercetatori cu experiență s-a axat pe studierea și aplicarea unor metode de pre-procesare a imaginilor cu hemangioame, alinierea lor. S-a investigat o metodă de combinare a metodelor bazate pe proiecția integrală [6]-[8] pentru estimarea translațiilor, rotațiilor și factorului de scală.

S-a studiat robustetea metodei pentru nivele diferite de zgomot Gaussian (Tabelul 1). Simularile au dovedit că metoda propusă are performanțe comparabile cu o metodă mult mai complexă propusă în [18]. Performanțe bune se obțin pentru factori de scală între 0.7 și 1.3, rotații mai mici de 15 grade și translații mai mici de 100 pixeli. Ordinea de aplicare cu cele mai bune rezultate a fost scalare, rotație, translație. Metoda propusă este mult mai simplă decât cea bazată pe transformata Radon deoarece nu implică transformări FFT complexe din punct de vedere numeric.



Nivel de zgomot	Metoda	Factor de scala	Rotatie cu 3 grade	Translatie (10, 10)
$\sigma_n = 0$	Metoda propusa	0.8	3	(10, 10)
	Metoda din [18]	0.80	2.8	(10, 10)
$\sigma_n = 30$	Metoda propusa	0.8	3.4	(10, 10)
	Metoda din [18]	0.82	2.8	(10, 10)

Tabelul 1.

Mai multe detalii pot fi găsite în articolul publicat în volumul IWSSIP 2016 [9].

S-a investigat combinarea metodelor de proiectie integrală cu DDTW (Derivative Dynamic Time Warping) [10]. S-au obținut rezultate mai bune în cazul rotațiilor, dar fără îmbunătățiri semnificative în cazul translațiilor. Deși folosirea DDTW conduce la o robustețe marită, există limite în cazul aplicării pe imagini cu hemangioame. Rezultatele cercetărilor în domeniul alinierii bazate pe DDTW și LPB (Local Binary Pattern) vor fi publicate în 2017.

Amplificarea schimbărilor subtile din fișiere video

S-a încercat utilizarea secvențelor video cu hemangioame și amplificarea schimbărilor subtile de culoare [11]. Rezultatele sunt încurajatoare, deși zgomotul este destul de puternic amplificat, iar prezenta artefactelor este supărătoare. Prin urmare, investigarea unor metode satisfăcătoare de reducere a zgomotului și selecția corectă a parametrilor metodei de amplificare euleriană va fi continuată în 2017.

Bibliografie

1. N. Angelescu, H. G. Coanda, I. Caciula, C. Dragoi and F. Albu, "SQL query optimization in Content Based Image Retrieval systems," 2016 International Conference on Communications (COMM), Bucharest, 2016, pp. 395-398, doi: 10.1109/ICComm.2016.7528344
2. Mike Frampton, *Mastering Apache Spark*, Packt Publishing, ISBN-13: 978-1783987146, 2013
3. Wang S, Summers RM. Machine learning and radiology, *Med. Image Anal.*, Vol. 16, No. 5, 2012
4. Haralick, R. M., Shanmugam, K., Dinstein, I., Texture Features for Image Classification, *IEEE Transactions of System, Man and Cybernetics*, Vol.SMC-3, No.6, 1973
5. Petrou M., Pedro G.S., *Image Processing: Dealing With Texture*, John Wiley & Sons Inc., 2006.
6. Albu F., "Registration of Differently Scaled Images", US Patent 20130070126, 2013
7. Albu F, Murray L., Stec P., Raducan I., "Fast Rotation Estimation", US Patent 13028203, 2011
8. Albu, F., Florea C., Zamfir A., Drimborean A., "Low Complexity Global Motion Estimation Techniques for Image Stabilization", Proc. of ICCE 2008, January 2008, pp. 465-467
9. Albu, F., "Low Complexity Image Registration Techniques based on Integral Projections", IWSSIP 2016, May 2016
10. E.J. Keogh, M.J.Pazzani, "Derivative dynamic time warping", Proc. of the First SIAM International Conference on Data Mining (SDM'2001) (2001), pp. 1-11
11. Wadhwa, Neal, et al. "Phase-based video motion processing". *ACM Transactions on Graphics (TOG)* 32.4,80, 2013.

Raport de cercetare SANAFORT (2016)

În cadrul proiectului HEMACAD, Sanafort SRL a depus eforturi în vederea extinderii bazei de date prin diseminarea informației despre proiect prin distribuirea de materiale informative cu ocazia următoarelor **congrese** la care a participat, precum și prin actualizarea platformei web și elaborarea de materiale informative :

- [TÂRGUL INTERNAȚIONAL DE MEDICINĂ ȘI FARMACIE ROMMEDICA](#), BUCUREȘTI, 14 APRILIE 2016, ORGANIZAT LA CENTRUL EXPOZIȚIONAL ROMEXPO
- CONGRESUL NAȚIONAL DE MEDICINA MUNCII, BUCUREȘTI, 26-28 MAI 2016
- [CONFERINȚA NAȚIONALĂ DE CARDIOLOGIE ÎN MEDICINA GENERALĂ, EDITIA 2016](#), BUCUREȘTI, 31 MAI 2016, ORGANIZATA DE SOCIETATEA ACADEMICA DE MEDICINA A FAMILIEI
- CONFERINȚA NAȚIONALĂ ” MEDICINA DE FAMILIE – PRIMA LINIE ÎN ASISTENȚA MEDICALĂ”, BRAILA, 29 Iunie – 2 Iulie 2016
- [CONFERINȚA INTERDISCIPLINARĂ MEDACADEMY, ”DIRECTII ȘI PERSPECTIVE TERAPEUTICE ÎN BOLILE CRONICE”](#), 23 SEPTEMBRIE 2016, BUCUREȘTI, PALATUL PATRIARHIEI
- [CONFERINȚA NAȚIONALĂ DE MEDICINA A FAMILIEI – EDITIA 2016](#), BUCUREȘTI, 19 OCTOMBRIE 2016
- AR MEDICA, 3-5 NOIEMBRIE 2016, ARAD

Pe parcursul conferințelor au fost distribuite materiale informative către medici și au fost realizate comunicările despre inițierea și scopul proiectului efectuate în mai multe clinici de neonatologie și pediatrie din București și din alte centre universitare din țară precum :

Clinicile de neonatologie vizate și informate asupra proiectului sunt :

- Spitalul Universitar de Urgență București
- Spitalul de Obstetrică și Ginecologie Polizu
- Spitalul Universitar de Urgență ELIAS
- Spitalul Clinic de Obstetrică și Ginecologie Prof. Dr. Panait Sarbu
- Spitalul Clinic de Urgență ”Sf. Pantelimon” București
- Clinica Sanador
- Clinica Regina Maria
- Clinica Medcover
- Spitalul Clinic Județean de Urgență Targu Mures
- Spitalul Clinic de Obstetrică - Ginecologie "Elena Doamna" Iasi

Clinicile de pediatrie vizate și informate asupra proiectului sunt:

- Spitalul de Copii Grigore Alexandrescu
- Spitalul Clinic de Urgență pentru Copii - MS Curie București
- Spitalul Clinic de Urgență pentru Copii "Sfânta Maria" - Iasi
- Spitalul Clinic Județean de Urgență Targu Mures

Reprezentanții firmei Sanafort SRL au diseminat informațiile referitoare la patologia hemangioamelor în unitățile medicale din teritoriul cu scopul de a orienta pacienții către spitalul Marie Curie unde se efectuează procedurile de tratament.