

Raport de cercetare privind proiectul (PN-II-PT-PCCA-2013-4) nr. 123: “Metode de predicție a evoluției hemangioamelor infantile în vederea prevenirii complicațiilor desfigurante prin metode intervenționale multiple” (HEMACAD)
- faza a 2-a -

Rezumat

În cadrul acestei etape s-au atins obiectivele generale și cele specifice propuse, în conformitate cu diagrama Gantt a proiectului.

O prima activitate a acestei faze a constat în **extinderea bazei de date de pacienți**. Astfel, 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. S-a ajuns până în momentul de față la un număr de 41 de cazuri supuse studiului. Pentru toate aceste cazuri s-au preluat imagini în spectrul vizibil, ecografii și imagini Doppler, pentru fiecare sesiune de achiziție, în parte. Echipa UPB a organizat și sistematizat aceste cazuri pentru o mai bună accesare a lor locală/ la distanță în paralel și de către ceilalți parteneri.

Echipa UMF a desfășurat studiul său de **implementare de noi tehnici și tehnologii de tratament**. Astfel, s-a ales împărțirea cazurilor în 4 loturi de lucru. Acestea se deosebesc în funcție de tipul de tratament care le-a fost recomandat: tratament medicamentos, scleroterapie intralezională, excizie chirurgicală sau nici o atitudine terapeutică, “watch and wait”. Ca o nouă tehnologie de tratament, echipa de cercetători UMF au efectuat câteva ședințe de training în cadrul Firmei Cutera Medical Center din București. În același timp, demersurile de achiziție a unui astfel de sistem sunt într-un stadiu avansat de realizare. Referințele acestui tip de sistem laser sunt: Laser Endovenos tip Dornier cu o lungime de undă 940 nm și o putere de 50 Watt. Principala aplicabilitate a acestuia este în tratarea leziunilor vasculare de tip taleangiectazii, hemangioame infantile și alte leziuni pigmentare restante. Echipa MTR a depus eforturi în vederea extinderii bazei de date prin diseminarea informației despre proiect prin distribuirea de materiale informative cu ocazia congreselor la care a participat. De asemenea a efectuat comunicări despre inițierea și scopul proiectului în mai multe clinici de neonatologie și pediatrie din București și din alte centre universitare din țară.

În ceea ce privește latura tehnică de analiză automată a zonelor interes, echipele UPB și Valahia au implementat algoritmi și metode automate de **preprocesare, segmentare, extragere de trăsături, aliniere, fuzionare**. Întrucât condițiile de achiziție (iluminare mediu ambiant, pacienții de vârstă până într-un an nu stau nemiscăți în timpul sesiunilor de monitorizare, imaginile și perspectivele de la o achiziție la alta sunt diferite, etc.) sunt dificile, acest lucru conduce la imagini de slabă calitate. În acest sens, echipa UPB și UVT au efectuat operații de preprocesare care au constat în aducerea imaginilor în același spațiu comun de iluminare pe baza unor algoritmi de constanță și uniformizare a iluminării, îmbunătățirea contrastului imaginilor, eliminarea zgomotului și corectarea artefactelor de deflashing din imagini. Pentru pasul de segmentare s-au utilizat algoritmi bazati pe segmentarea cromatică a din spațiul de culoare **Lab**, algoritmi K-means, Fuzzy C-Means, precum și metoda MAP-Markov. Tot pentru detecția automată a hemangiomului s-au folosit metode de Analiză Componentelor Principale (PCA) și metode de rețele neurale (Rețele Perceptron Multistrat (MLP), Rețele Self Organizing Map – SOM, Support Vector Machine - SVM). Pentru îmbunătățirea și rafinarea pasului de segmentare s-a implementat și un detector automat de piele. În ultimele două luni ale acestei faze, echipa UPB a propus și doi operatori: Local Binary Pattern – LBP și operatori de Histograma gradientelor orientați – HOG (și varianta GrSD - Gradient Structure Descriptor) pentru pasul de extragere de trăsături. Aceștia au fost utilizați ca intrări pentru antrenarea și testarea unei rețele de tip SOM. Pentru aliniere, echipa UVT a investigat combinarea metodelor de proiectie integrală cu DTW (Dynamic Time Warping). De asemenea, s-a încercat o aliniere temporală condusă de modificările de formă ale hemangiomului punând în corespondență traiectoriile de progresie. Și în acest caz s-a încercat folosirea unei deformări ne-liniare monotone care să minimizeze un cost măsurând disimilaritatea dintre trasaturile hemangioamelor. O altă idee investigată presupune

estimarea unei evoluții medii de progresie a hemangiomului printr-o analiză statistică și o vizualizare a schimbărilor care apar în timp. Prin fuzionarea de imagini se dorește să se combine informațiile complementare conținute în mai multe imagini pentru a produce o imagine cu o calitate superioară. S-a încercat combinarea informațiilor la nivel de pixel. S-au investigat mai multe metode cunoscute de descompunere piramidală. De asemenea, s-au încercat și metode liniare (superpoziție liniară, sau superpoziție ponderată PCA) precum și metode neliniare bazate pe valoarea minimă sau maximă. Rezultatele preliminare indică performanțe mai bune ale metodelor bazate pe DCT sau pe Wavelet. Metricile de evaluare au fost PSNR, SSIM, frecvențele spațiale și indexul de calitate a fuziunii. Investigațiile în fuziunea imaginilor vor fi continuate anul viitor.

Raport de cercetare Universitatea de Medicină și Farmacie Carol Davila București (CO)

Hemangioamele infantile reprezintă cel mai frecvent tip de tumoră benignă cu origine vasculară a sugarului și copilului mic cu o frecvență între 2% la naștere, și 12% până la vârsta de 1 an. Aceste tip de patologii aparțin grupului mai larg al anomaliilor vasculare care mai cuprinde malformațiile vasculare și sindroamele asociate acestora. Pacienții care s-au adresat clinicii noastre în vederea evaluării unor leziuni cutanate 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 (Figura 1) de către echipa de cercetători UMF și distribuită acestia și de către P3, firma Medical Technologies and Research. Pliantul conține informațiile de bază asupra patologiei HI, metodelor de evaluare și diferențiere a acestora cu alte patologii cutanate. De asemenea, sunt listate și posibilitățile de contact ale echipei de cercetători UMF. Broșurile au fost distribuite și în cadrul mai multor congrese naționale de pediatrie și chirurgie pediatrică desfășurate pe parcursul anului 2015.

Printre alte metode de promovare a proiectului, a fost redactat un articol publicat în luna ianuarie 2015, numărul 8 al revistei Journal of Medicine and Life cu denumirea de “Proposal for future diagnosis and management of vascular tumors by using automatic software for image processing and statistic prediction”, iar în luna noiembrie a fost susținută în cadrul celui de-al 7-lea Congres Național al Societății Române de Chirurgie Pediatrică, prezentarea lucrării cu titlul “Diagnosis and treatment of the cutaneous and subcutaneous infantile hemangioma – experience of the Surgical Department of M.S. Curie Bucharest”. 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.

Datele din literatură prezintă o incidență de 2,4/1 în favorarea sexului feminin și un procent de 30% la sugarii născuți prematur. Datele studiului nostru relevă până în acest moment o incidență de 69% la sexul feminin cu o rație de 2,1/1 (Grafic 1) și o asociere de 41% cu prematuritatea (Grafic 2). De asemenea, 21% dintre subiecții studiului au fost supuși în timpul vieții intrauterine unei intervenții de amniocenteză, iar prezentația pelviană a fost constatată la 11%. Un alt factor comun observat a fost că 62% sunt primii copii ai familiei respective.

Alte date etiologice constatate în literatură, cum ar fi, procent crescut al placentei previa, vârsta crescută a mamei la naștere sau prezența aceleiași patologii la un membru de gradul unu al familiei, nu au fost confirmate de înregistrările studiului nostru. Din punct de vedere al distribuției pe regiuni corporale literatura de specialitate ne indică un procent de 56% la nivelul capului și gâtului, 23% la nivelul toracelui și abdomenului, 19% extremități și 2% afectează zona ano- genitală. Pacienții cuprinși în cadrul studiului nostru se încadrează în datele de literatură prezentate (Grafic 3). 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.

Ținând cont de această distribuție a regiunilor corporale afectate de HI și de vârsta pacienților, am ales și împărțirea cazurilor în cele 4 loturi de lucru. Acestea se deosebesc în funcție de tipul de tratament care le-a fost recomandat: tratament medicamentos, scleroterapie intralezională, excizie chirurgicală sau nici o atitudine terapeutică, “watch and wait”.

Spitalul de Urgență pentru Copii "M.S. Cușe" funcționează din anul 1984 și are ca obiect de activitate asistență medicală de specialitate pentru copii, cu adresabilitate întregii populații a țării, asigurată prin personalul său înalt calificat. În colaborare cu Universitatea de Medicină și Farmacie "Carol Davila" București, cadrele universitare care profesază în cadrul unității sunt angrenate în proiecte de cercetare științifică medicală, așa cum este "Metode de prevenție a evoluției hemangioamelor infantile în vederea prevenirii complicațiilor disfigurante prin metode intervenționale multiple" (HEMACAD), realizat prin programul Parteneriate în domenii prioritare - PN II derulat cu sprijinul MEN - UEFISCDI.

**DIAGNOSTICUL
ACȚIUNII
TERAPIE**

Diagnosticul și Tratatamentul Hemangioamelor Infantile

Prevenirea complicațiilor funcționale și estetice la rugări și copii



Ce sunt Hemangioamele Infantile (HI)?

HI reprezintă cele mai frecvente formațiuni tumorale, benigne, de origine vasculară care apar de la vârsta de sugat. Ele aparțin grupului mare al Anomaliilor Vasculare.

Informații generale

30% dintre HI sunt leziuni prezente de la naștere, iar restul de 70% apar în primele săptămâni de viață.

Incidența lor variază de la 2% (la naștere) la 11% până la sfârșitul primului an de viață. Frecvență de 30% la noi născuți prematuri cu o greutate la naștere sub 1500 g.

Sunt mai des întâlnite la sexul feminin și la copii din rasa caucaziană.

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

Proiectul de cercetare

Studiul se adresează tuturor pacienților care prezintă la nivel cutanat sau subcutanat astfel de formațiuni tumorale. Părinții trebuie îndrumați către centrele specializate pentru a se asigura un diagnostic și în funcție de localizare, vîrstă și complicațiile posibile, să se stabilească cît mai precoce un management terapeutic adecvat.

O adresabilitate crescută a pacienților asigură prevenirea apariției unor complicații estetice și funcționale importante. Vîrsta ideală a primului consult este cea de 2 luni.

Stadiile clinice prezentate în tabel se vor corela cu o succesiune de examinări ecografice ce vor fi efectuate, pe parcursul întregii perioade de tratament.

Stadiu	Clinică
1. Prodromal (primale săptămâni)	Pete albe/roșatic, telangiectatic
2. Inițial	Picula dintr-o masă grasă și indurată
3. Proliferativ	Colorat roșu-intens alături, picule indurată, reliefată, marginea inflorată, creștere rapidă în dimensiuni
4. Mature	Colorarea devine roșu-draclis sau purpuru, posibilă ulcerăi centrale, scade în dimensiuni
5. Regresiv (dincolo de 6 ani)	Hemangiomatice, picule "globule", zona de indurată devine subcutanată, papuloasă, se observă reliefat vîndet de dincolo din porfonic

În funcție de localizare, dimensiunile tumorii, vîrsta copilului și starea generală, pacienții pot primi tratamente medicamentoase; se pot efectua mai multe ședințe succesive de scleroterapie locală intralezională; se poate practica excizia chirurgicală a formațiunii sub anestezie generală sau se decide temporizarea cuicui management terapeutic.

În funcție de rezultatele acestui studiu se dorește crearea unei metode automatizată de detectare a HI și de stabilire a celei mai adecvate modalități de tratament, în viitorul cît mai apropiat.

Prevenirea complicațiilor estetice și funcționale ale copilului

Pentru a vizualiza mai multe informații asupra proiectului de cercetare HEMACAD puteți accesa situl <http://imag.pub.ro/hemacad/> sau puteți să ne contactați la unul din telefoanele listate mai jos.


Contactați-ne

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


Ed. C-tin Brancoveanu nr. 20 Sector 4
București, 021 480 42 60 (268)

51 Dr. Isabela Dușgăș +4 0744 364 856
Dr. Maria Popescu +4 0723 426 867


Figura 1. Broșura promovată ca material informativ



Graficul 1. Repartiția pe sexe a pacienților (procent)



Graficul 2. Greutatea la naștere a pacienților cuprinși în studiu (procent)



Graficul 3. Distribuția pe regiuni corporale a HI (procent)




Figura 2. Tipuri de HI neintroduse în studiu a) HI auricular b) HI limba HI pleoapa inferioara d) HI zona genitală

HI distribuite mai ales la nivelul zonei faciale au primit în totalitate tratament medicamentos folosind Propranolol. Acesta reprezintă un produs beta blocant folosit la pacienții pediatrici pentru tratarea hipertensiunii arteriale, aritmiilor, Tetralogiei Fallot, tireotoxicozelor și afecțiunilor migrenoase. În anul 2008 acțiunea benefică a Propranololului asupra HI a fost descoperită întâmplător și studiile care au urmat au confirmat introducerea acestui nou tip de terapie. La nivel celular acesta induce apoptoza celulelor endoteliale, inhibă procesul de angiogeneză și produce vasoconstricție cu scăderea fluxului arterial la nivelul HI.

Protocolul de utilizare a Propranololului în cazul lotului nostru de studiu cuprinde următoarele considerente: pacienți cu vârsta peste 3 luni, greutatea în momentul debutului tratamentului de 5 kg sau mai mult și care să nu prezinte alte afecțiuni cardio vasculare importante. Screeningul necesar înainte de introducerea terapiei cuprinde:

- Examen clinic complet insistând asupra sistemului cardio-respirator
- Analize de laborator (Hb, probe de coagulare, glicemie, uree)
- Electrocardiogramă și ecocardiogramă
- Ultrasonografie abdominală și de părți moi a zonei afectate
- Recoltarea datelor fotografice inițiale

Datele fotografice au fost recoltate folosind același dispozitiv performant fotografic și încercând să se păstreze cât mai constante condițiile mediului înconjurător (intensitate luminoasă, echilibru lumină artificială vs naturală) și distanța de la care s-au efectuat fotografiile. Pentru mărirea acurateții s-au efectuat și înregistrări video. În cazul HI ce afectează o arie foarte întinsă de tegument s-a decis, de comun acord cu echipa de procesare a datelor, alegerea unei zone reprezentative care va fi studiată și înregistrată în cadrul fiecărei examinări. Această alegere a fost comunicată și cadrelor medicale care efectuează examinarea ecografică.

Controlul și înregistrarea datelor fotografice și imagistice se face la 1 lună.

Pentru pacienții care prezintă leziuni multiple, de la trei HI sau mai multe, se recomandă efectuarea unei examinări atente prin ultrasonografie abdominală întrucât prezintă un risc crescut de asociere cu hemangioamele viscerale, în special hepatice. În cazul pacienților noștri am încercat să efectuăm această investigație pentru fiecare caz. De asemenea, pentru cei ce prezintă leziunii faciale extinse se încearcă delimitarea în profunzime a HI prin efectuarea de RMN sau CT cerebral.

În vederea efectuării tuturor acestor investigații cât și pentru supravegherea debutului de tratament se recomandă o internare a pacientului de minim 3 zile. Aceștia vor fi monitorizați cu atenție din punct de vedere al tensiunii arteriale și alurii ventriculare de la debutul terapiei și pe măsură ce doza de Propranolol se modifică.

Indicațiile pentru introducerea tratamentului medicamentos sunt acelea de afectare oculară, compromitere a căilor respiratorii cu sindrom obstructiv, prezența unor complicații ulcerative sau a altor complicații funcționale. Vârsta de începere a tratamentului variază între 12 săptămâni și 17 luni cu o vârstă medie de 15 săptămâni.

Doza inițială administrată a fost de 1 mg/kg/zi împărțită în trei doze egale și aceasta a fost crescută pe parcursul celor 3 zile de internare până la 2 mg/kg/zi. Pe parcursul acestor ajustări de tratament s-a monitorizat la 8 ore tensiunea arterială și se urmărește și efectul imediat al terapiei asupra HI. Se recomandă administrarea în primele zile de spitalizare a Propranololului de către cadrele medicale în vederea acomodării aparținătorilor cu metoda de tratament. Administrarea produsului se efectuează pe parcursul unei mese pentru a reduce riscul de hipoglicemie. De asemenea se recomandă întreruperea administrării dacă pacientul prezintă vărsături sau stare generală modificată.

Propranololul este administrat ca pulbere preparată în pliculețe speciale de către farmacia spitalului, substanța de bază fiind sub forma de tablete de 10 mg. Propranolol sub formă de suspensie a fost introdus în urmă cu 6 luni pe piața medicamentoasă din România, dar în acest moment prezintă un preț de comercializare ridicat ce nu justifică înlocuirea tabletelor.

Dintre pacienții studiați, un singur caz a necesitat reducerea dozei de Propranolol până la 0.5mg/kg/zi pentru stabilizarea unor tulburări de hipotensiune și bradicardie manifestate prin lipsa apetitului și o stare letargică. Alți doi pacienți au necesitat sistarea tratamentului după 2 luni pentru tratarea unor afecțiuni pulmonare, manifestate prin bronșiolite repetate.

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 3, 4, 5). Datele clinice și imagistice

au fost înregistrate și trimise pentru procesare în vederea confirmării automate a observațiilor medicale.

Pentru tratarea leziunilor restante ce afectează mai ales colorația tegumentului, pacienții vor fi rechemati pentru evaluare în momentul achiziției unui sistem de tratament 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. Referințele acestui tip de sistem laser sunt: Laser Endovenos tip Dornier cu o lungime de undă 940 nm și o putere de 50 Watt. Principala aplicabilitate a acestuia este în tratarea leziunilor vasculare de tip teleangiectazii, hemangioame infantile și alte leziuni pigmentare restante. Referatul de achiziție a acestui echipament este momentan aprobat, iar în vederea efectuării tratamentelor echipa de cercetători UMF a efectuat câteva ședințe de training în cadrul Firmei Cutera Medical Center din București.




Figura 3. HI facial a) la debut b) după 2 luni de Propranolol c) după 7 luni de Propranolol




Figura 4. HI facial a) la debut b) la 2 luni de tratament c) la 5 luni de tratament




Figura 5. HI retroauricular a) la debutul terapiei b) la 2 luni de terapie

Un lot mai mic de pacienți au fost aceia tratați prin metoda de scleroterapie locală folosind Bleomicina. Aceasta substanță reprezintă un complex antibiotic obținut prin fermentare folosită cu precădere ca și tratament oncologic. Riscurile de toxicitate pulmonară sau șoc anafilactic sunt mai crescute în cazul asocierii între administrarea de Bleomicină și prezența substanțelor necesare unei anestezii generale, astfel încât în momentul de față scleroterapia se efectuează fără analgezie. Pentru acest lot de lucru condițiile de includere ale pacienților au fost: vârsta mai mare de 3 luni, pacienții să nu prezinte teren atopic ce favorizează reacțiile alergice sau probleme cardio pulmonare. Se pot efectua un număr de până la 6 injecții intralezionale, la o distanță de minim 7 zile. Doza introdusă nu depășește 2 ml soluție diluată de Bleomicină (1 flacon Bleomicină pulbere + 7 ml ser fiziologic + 2 ml Dexametazonă), și se ajustează în funcție de tipul de HI abordat. Rezultatele au fost favorabile în cazul HI superficiale și a unui singur HI subcutanat (Figura 6).




Figura 6: HI torace posterior a) la debutul terapiei b) după 5 injecții de Bleomicină



Figura 7: HI scalp a) la debutul terapiei b) după 4 injecții c) după 7 injecții

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 8: HI excizate chirurgical a) torace anterior b) torace lateral c) laterocervical stg d) torace anterior

Raport de cercetare Universitatea de Politehnică București (P1)

Introducere

Hemangioamele infantile – HI – sunt tumori vasculare benigne caracterizate prin proliferare de celule endoteliale și care în cursul etapelor de dezvoltare prezintă o creștere a numărului de vase sangvine ce începe din periferie spre centrul formațiunii. Din cauza acestei dezvoltări vasculare culoarea, dimensiunea și textura tumorii se modifică în permanență îngreunând atât diagnosticul, cât și metodele terapeutice. Datorită posibilităților de regresie spontană a acestor leziuni, metoda de tratament abordată este bazată pe principiul de “watch and wait” pentru a evalua pe o perioadă mai mare dacă pacientul va necesita un anumit tip specific de terapie. Principiile terapeutice aplicabile actual sunt: 1. Oprirea etapei de proliferare; 2. Grăbirea regresiei unor hemangioame importante; 3. Prevenirea, dar și tratarea unor probleme funcționale; 4. Cu cât perioada de proliferare se încheie mai rapid, cu atât va fi mai bun rezultatul final.

În practica clinică uzuală, evoluția hemangiomului este estimată doar prin simpla măsurare a leziunii în cadrul examinărilor clinice periodice. Faza și gradul de regresie sunt estimate doar pe baza inspecției vizuale a statusului leziunii precum și prin înregistrarea vizuală, la diferite examinări periodice, ale procentului de suprafață a leziunii cu aspect, mai estompat - a zonei raportată la regiunea încă afectată de prezența hemangiomului. Desigur, modalitatea de urmărire a evoluției hemangiomului amintită anterior este imprecisă, neconsistentă, iar procesul de regresie este subiectiv.

Din punct de vedere clinic, în prezent, nu există un set de reguli standard pe baza cărora să se realizeze o predicție a evoluției în timp a hemangiomului; în mod uzual evaluarea progresiei sau regresiei este realizată tot vizual, ceea ce conduce atât la un diagnostic lipsit de acuratețe (din moment ce sunt luate în considerare doar diametrele și niciun aspect de formă nu este analizat) cât și la un diagnostic subiectiv (deoarece estimarea regresiei hemangiomului variază substanțial de la clinician la clinician). Studiul propus intenționează ca bazându-se pe date clinice, strânse prin observații clinice seriate, corelate cu date imagistice, să dezvolte un algoritm de tratament care să prezică cu acuratețe rezultatele finale cele mai bune din punct de vedere estetic și funcțional pentru un anumit tip de leziune. Algoritmul de tratament va fi transpus din punct de vedere practic într-un software medical ușor de accesat și de real folos pentru toate cadrele medicale care diagnostichează această patologie.

În cadrul acestei faze, echipa UPB a atins obiectivele urmărite prin activitățile aferente etapei.

PRE-PROCESAREA IMAGINILOR

Îmbunătățirea calității imaginii este un pas esențial în procesul de obținere a segmentării automate a zonei de hemangiom. Procesul de achiziție al imaginilor este dificil (după cum se poate observa în *Figura 1*), atât prin natura procesului: pacienții sunt copii care nu stau nemișcați în timpul sesiunilor de achiziție al imaginilor cât și prin natura condițiilor date de mediul de achiziție, de la o sesiune la alta: iluminare ambientală variabilă, diferența de perspectivă geometrică a zonei de interes. Toate aceste aspecte duc la o calitate slabă a imaginilor inițiale.

Pentru a depăși aceste neajunsuri legate de procesul de achiziție, am implementat un pas de preprocesare care constă în mai multe sub-etape: îmbunătățirea contrastului, îndepărtarea artefactelor și deflashing, eliminarea zgomotului și consistența în scopul uniformizării culorii; acești pași sunt detaliați în cele ce urmează.



Figura 1. Imagini inițiale de calitate slabă

A. Îmbunătățirea contrastului

Pentru compensarea variațiilor impuse de condițiile variabile ale configurației de achiziție, au fost testate câteva tehnici de îmbunătățire a contrastului. După cum se poate observa în *Figura 2*, toate cele trei canale de culoare R, G și B au un contrast slab; pentru a îmbunătăți contrastul dintre regiunea de interes (ROI) raportat la zonele de țesut de piele din vecinătate, o egalizare de histogramă adaptivă a fost aplicată. Această tehnică de îmbunătățire bazată pe egalizarea de histogramă adaptivă (Contrast Limited Adaptive Histogram Equalization - CLAHE) are avantajul de procesare la nivel de blocuri de regiuni, în loc de utilizarea întregii imagini; acest lucru implică: contrastul fiecărui bloc (regiune) este îmbunătățit independent de informația dominantă din imagine. Dintre toate celelalte metode propuse, aceasta a prezentat cele mai bune rezultate (vezi *Figura 3*).




Figura 2. Canalele de rosu, galben și verde ale imaginii din *Figura 1.a*




Figura 3. Aplicarea tehnicii CLAHE pentru *Figura 1.a*, asigură o creștere a contrastului păstrând în același timp o calitate bună a fundalului

B. Eliminarea artefactelor

Extragerea zgomotului. În primul rând, un pas de eliminare a zgomotului a fost aplicat pentru eliminarea structurilor fine din imagine. Pentru aceasta, un filtru median (cu o fereastră de 5X5) este utilizat; la fel au fost aplicate și filtre de netezire precum Nagao și Kuwahara. Acestea din urmă conservă contururile, netezesc detalii fine în timp ce păstrează și accentuează contururile la scară mai mare. Cele mai bune rezultate au fost obținute cu filtrul Nagao.

C. Deflashing

Modificări locale de iluminare (Deflashing). Vizează atenuarea efectului flash pe piele care, în multe cazuri, împiedică stabilirea exactă a marginii hemangiomul (vezi *Figura 1.a*). Soluția abordată pentru corecția efectului de deflashing este bazat pe utilizarea unei metode de **α -blending**.

Algoritmul propus

Metoda **α -blending** dintre două imagini presupune calcularea (la nivel de pixel) a unei combinații convexe dintre pixelii corespunzători prin aplicarea unui factor de amestec – combinare $\alpha \in [0,1]$ care controlează ponderile pe care valorile pixelilor le vor avea în imaginea rezultat.

$$Output = \alpha \cdot I_1 + (1 - \alpha) \cdot I_2. \quad (1)$$

Această metodă este deosebit de utilă pentru procesarea doar a unor zone de imagine, fără ca efectul de frontieră - margine (între zonele prelucrate și neprelucrate) să fie vizibil. În cazul nostru particular (deflashing), dorim să crească ușor saturația și să reducem intensitatea numai pentru zonele cu saturație scăzută și intensitate mare. În acest scop, vom identifica harta binară de pixeli cu saturație redusă și cu valori mari ale intensității, și vom folosi o versiune puternic blurată a acesteia sub forma unei hărți alfa-amestecare dintre imaginea originală și versiunea sa cu saturație crescută și intensitate mai mică (după cum se poate vedea în *Figura 4*).

Rezultate




Figura 4. Rezultatele obținute în urma procesului de deflashing: (a) Imaginea originală. (b) Imaginea cu saturația mărită și intensitatea redusă. (c) Zonele de intensitate mare și saturație redusă ale imaginii (a). (d) Harta Alpha-blending obținută printr-un efect puternic de blurare a hărții binare (c). (e) Imaginea rezultat, obținută prin alpha-blending a imaginilor (a) și (b) cu harta obținută în (d).

După cum se poate observa, efectul de flash (prezent în colțul din dreapta sus a zonei de hemangiom), iar zona de hemangiom care era estompată, acum este mult mai vizibilă.

D. Consistența – Uniformizarea culorii

În cadrul acestei etape pentru îmbunătățirea calității imaginilor inițiale s-a aplicat și o metodă de consistență (constantă) a culorii care constă în aducerea în același plan de culoare a imaginilor preluate în condiții de iluminare diferite. Culoarea sursei de lumină are o influență semnificativă în determinarea culorilor obiectelor din scenă. Același obiect, preluat cu aceeași cameră, dar în condiții de iluminare diferită, poate varia într-o gamă foarte largă în termeni de valori ale culorii.



Figura 5. Exemple de cazuri ale aceluiași pacient preluate la diferite momente de timp cu surse de lumină ambientală diferite

În cazul particular al aplicației de față, culoarea este un parametru important pe baza căruia se decide un anumit diagnostic în evoluția hemangiomului: proliferare sau regresie. Faza de proliferare este caracterizată de o nuanță de roșu intens care atestă că zona respectivă este caracterizată de o activitate vasculară intensă și, invers, faza de regresie este caracterizată de un transfer spre o nuanță de gri sau zone un roșu mai estompat a zonei de interes sau a unei regiuni parțiale a zonei de interes.

Din acest motiv, trebuie aplicat un pas de corecție a culorii pentru a compensa variația culorii datorată variației iluminării ambientale.

Algoritmul propus

În studiul de față, pentru alegerea transformatei optime, au fost aplicați 5 algoritmi de uniformizare a culorii: *Grey-World*, *Shades of Gray*, *max-{RGB}*, *Grey-Edge* și *weighted Grey-Edge*. Testele au demonstrat că niciuna dintre transformările de mai sus nu este ideală, dar au arătat că pentru o imagine dată există cel puțin o transformare care conduce la rezultate corecte.

De aceea, problema s-a conturat în alegerea transformatei ideale pentru fiecare caz considerat, în parte. Pentru obținerea metodei aferentă estimării celui mai bun iluminant, am folosit următoarea abordare: singurul parametru constant între două imagini succesive de hemangiom ale aceluiași pacient este pielea cu atributele sale (în special, culoarea). De aceea, pentru corectarea condițiilor de iluminare a surselor diferite și aducerea imaginilor de hemangiom în același spațiu de iluminare, a fost aplicat următorul algoritm, alcătuit din cinci pași:


1. Aplicarea tuturor algoritmilor de consistență a culorii (*Grey-World*, *Shades of Gray*, *max-{RGB}*, *Grey-Edge* și *weighted Grey-Edge*) pe imagini subsecvențe ale aceluiași pacient;
2. Identificarea automată a zonelor de piele din fiecare imagine prin utilizarea unui algoritm de segmentare de piele (detectorul de piele va fi prezentat într-o secțiune următoare a acestui raport);
3. Calcularea mediei culorii de piele din fiecare imagine ca media componentelor de cromaticitate **a** și **b** (din spațiul *Lab*) pe zonele de piele determinate la pasul anterior;

4. Calcularea distanței euclidiene dintre mediile componentelor de cromatică:


$$dist((a_1, b_1), (a_2, b_2))_i = \sqrt{(a_1 - a_2)^2 + (b_1 - b_2)^2}$$

5. Alegerea transformării optime de consistență a culorii dată de minimul distanței euclidiene , unde
 $i \in \{ \text{Grey-World, Shades of Gray, max-}\{\text{RGB}\}, \text{Grey-Edge și weighted Grey-Edge} \};$

Schema de mai jos ilustrează algoritmul aplicat:



Rezultate In figura de mai jos sunt evidentiata cateva exemple obtinute pentru metoda de alegere optima a transformarii de consistenta a culorii:



II. SEGMENTAREA IMAGINILOR

A. Detecția automată a pielii

Detecția pielii este o etapă esențială în segmentarea și clasificarea zonelor de hemangiom. Acest pas poate fi folosit atât ca o etapă premergătoare determinării - segmentării regiunii de interes – hemangiom (bazându-ne pe observația că hemangiomul este inclus în zonele de piele) cât și separat pentru pasul de antrenare din cadrul metodelor de clasificare al zonelor hemangiom – non-hemangiom.

Totodată, este utilizat și pentru determinarea metodei optime de consistență a culorii, după cum se poate vedea în schema de mai sus.

Segmentarea pixelilor ce aparțin pielii poate fi realizată pe baza informațiilor de culoare ce caracterizează acest obiect. Astfel, cercetătorii au arătat că pielea umană se poate încadra într-un interval restrâns de nuanță și nu este în totalitate saturată, iar ca înfățișare este formată prin combinarea sângelui (roșu) cu melanina (maro, galben). Prin urmare, culoare pielii umane nu poate lua valori aleatoare într-un spațiu de culoare, ci mai degrabă se grupează într-o zonă restransă a acelui spațiu de culoare. Câteva studii au aratat că diferența de culoare a pielii în rândul oamenilor se găsește mai degrabă în cadrul informațiilor de intensitate decât în cele de cromatică. Prin urmare, dacă imaginea poate fi reprezentată într-un spațiu de culoare ce separă luminanța de cromatică, detecția pielii din imagine ar putea fi mult ușurată.

Algoritmul propus

În acest sens, pe planul de culoare **Lab** s-au stabilit două praguri:

- 1) pe planul de luminanță: $L = 60$;
- 2) pe planul cromaticității: $threshold_a_skin = 4.00$; Astfel, pentru ca un pixel din imagine să fie un pixel de piele, acesta trebuie să îndeplinească două condiții:

- 1) Valoarea lui pe planul de luminanță > 60 ;


- 2) $dist_ab_min < threshold_a_skin$

$$dist_ab_min = \min(dist_ab_min, \sqrt{(prot_ab[j][0] - a)^2 + (prot_ab[j][1] - b)^2})$$

Unde $dist_ab_min$ = distanța euclidiană între perechile prototipurile cromaticității a și b ($prot_ab[j][0]$, $prot_ab[j][1]$) și valorile cromaticității propriu-zise (a, b).

În urma testelor s-au ales 31 de perechi de puncte prototip ($prot_ab[j][0]$, $prot_ab[j][1]$), ale căror valori să caracterizeze cât mai precis zona de piele.

Rezultate. În figura de mai jos sunt evidențiate câteva exemple obținute:



După cum se poate observa, algoritmul extrage într-o mare măsură zonele de piele din imagine, fiind un punct de plecare pentru extragerea ulterioară a regiunii de interes – a hemangiomului.

B. Segmentarea automată a regiunilor de hemangiom utilizând metoda MAP-Markov

Segmentarea unei imagini prin metoda estimatorului maximum a posteriori (MAP) revine la asocierea unei configurații $\mathbf{x}$ oricărei imagini de intrare $\mathbf{y}$. Rezultatul segmentării MAP, notat cu $\mathbf{x}^*$, este soluția unei probleme de optimizare (maximizarea verosimilității a posteriori).

Astfel, fie $\mathbf{Y} = (Y_{s1}, \dots, Y_{sM})$ un proces aleator asociat imaginii de intrare S (formată din M pixeli) și o realizare a lui $\mathbf{Y}$. Fie Λ mulțimea celor două clase dorite (hemangiom și non-hemangiom). Fie $\mathbf{X} = (X_{s1}, \dots, X_{sM})$ câmpul aleator care exprimă procesul de segmentare și

$\mathbf{x} = (x_{s1}, \dots, x_{sM}) \in \Lambda^M$: imaginea de etichete (o configurație a imaginii S). Repartiția de probabilitate a lui $\mathbf{Y}$ condiționată de o configurație dată, notată $P(\mathbf{Y}|\mathbf{X}=\mathbf{x})$, este exprimată prin densitatea condiționată de probabilitate $f(\mathbf{y}|\mathbf{X}=\mathbf{x})$. Clasificatorul Bayesian folosește probabilitatea a-posteriori:

$$P(\mathbf{X}=\mathbf{x}|\mathbf{Y}=\mathbf{y}) = P(\mathbf{X}=\mathbf{x}) f(\mathbf{y}|\mathbf{X}=\mathbf{x}) / \sum P(\mathbf{X}=\mathbf{x}) f(\mathbf{y}|\mathbf{X}=\mathbf{x})$$

Clasificatorul MAP este: $\mathbf{x}^* = \arg \min \{ -\ln P(\mathbf{X}=\mathbf{x}) - \ln f(\mathbf{y}|\mathbf{X}=\mathbf{x}) \}$. Metoda MAP presupune independența valorilor pixelilor și modelul Gaussian $N(\mathbf{N}; \mu_s, \Sigma_s)$ pentru $f(y_s|X_s = x_s)$. În aceste ipoteze, o configurație MAP $\mathbf{x}^* = (x^*_{s1}, \dots, x^*_{sM})$ este soluția următoarei probleme de optimizare locale:

$$\mathbf{x}^*_s = \arg \min ((y_s - \mu_s)^T \Sigma_s^{-1} (y_s - \mu_s) + \ln(\det \Sigma_s))$$

Regularizarea imaginii segmentate reprezintă rafinarea segmentării, iar metoda adoptată în acest caz a fost regularizarea MAP-Markov. Aceasta este soluția următoarei probleme de optimizare:

$$\mathbf{x}^{**} = \arg \min (\sum ((y_s - \mu_s)^T \Sigma_s^{-1} (y_s - \mu_s) + \ln(\det \Sigma_s)) + U(\mathbf{x})),$$

unde $U(\mathbf{x}) = \beta \sum \delta(x_s, x_t)$ este energia configurației în ipoteza modelului Potts. Suma se face după toate clicile de ordinul doi $\{s, t\}$, iar $\delta(x_s, x_t) = -1$ dacă $x_s = x_t$, și $\delta(x_s, x_t) = 1$ dacă $x_s \neq x_t$.

După cum se poate observa din scurta descriere de mai sus, pentru a obține imaginea segmentată prin metoda MAP, trebuie să cunoaștem mediile (μ_s) și matricele de covarianță (Σ_s) pentru fiecare din cele două clase dorite (hemangiom și non-hemangiom). Clasificatorul trebuie așadar întâi să "învete" aceste valori, folosind un mic set de pixeli cunoscuți din imagine. Ideea algoritmului propus de noi a fost de a automatiza procesul de segmentare MAP prin alegerea automată a mulțimilor de pixeli de învățare, utilizând două ipoteze: regiunile de hemangiom sunt mai texturate și mai roșietice decât regiunile de piele sănătoasă.

Pentru a extrage din imagine doar acei pixeli aparținând unor regiuni texturate, am construit o imagine de densitate a conturilor prin convoluția dintre imaginea de contururi obținută cu operatorul Canny și un nucleu de netezire de 15×15 . Apoi, din această imagine se vor păstra doar regiunile de densitate maximă a conturilor, prin aplicarea unui prag. În *Figura 1.a* este prezentat un exemplu de imagine originală, iar în *Figura 1.b* este imaginea de densitate a conturilor obținută (o culoare mai închisă reprezintă o densitate mai mare). Pentru a forma imaginea de învățare a clasei de hemangiom (*Figura 1.c*) am impus și condiția ca pixelii să fie roșietici (componenta de roșu din RGB să fie cu 55% mai mare decât cea de albastru și tot cu 55% mai mare decât cea de verde).

Pentru a obține o segmentare optimă, ne-am pus problema alegerii celui mai potrivit spațiu de culoare pentru a efectua segmentarea, fiind cunoscut faptul că, pentru metoda MAP, separabilitatea claselor nu este independentă de spațiul de culoare folosit. Am ales cinci spații de culoare pentru acest studiu: YCbCr, RGB, $L^*a^*b^*$, spațiul culorilor opuse (OPP) și $L^*u^*v^*$.

Algoritmul propus. Algoritmul propus pentru alegerea spațiului de culoare optim este următorul:

- pentru fiecare imagine din baza de date de imagini
 - pentru fiecare din cele cinci spații de culoare
 - repetă de 10 ori procedura următoare:
 - se aleg aleatoriu două mulțimi de pixeli: una din regiunea de hemangiom și una din regiunea de fundal și se folosesc pentru antrenarea clasificatorului MAP (folosim adevăr-terenul pentru selectarea pixelilor)
 - se efectuează segmentarea MAP și se calculează eroarea de segmentare
 - end repetă
 - calculează eroarea medie de segmentare pentru spațiul de culoare curent
 - end pentru

- end pentru
- calculează eroarea medie de segmentare pentru toate imaginile în contextul fiecărui spațiu de culoare.

După această procedură se obține eroarea de segmentare medie pentru fiecare din cele cinci spații de culoare și se alege spațiul de culoare pentru care eroarea este minimă.

Baza de imagini pentru aceste experimente a fost formată din 40 de imagini (aprox. 800x600 pixeli fiecare) selectate din cele achiziționate pe perioada proiectului. Pentru fiecare imagine am generat și o versiune "adevăr teren" pentru a verifica automat rezultatul segmentării.

Rulând algoritmul de selecție a spațiului de culoare optim pe aceste imagini am obținut valorile de bordererror (BE) din *Figura 2*.

Rezultate




Figura 1. a) Imaginea originală; b) imaginea de densitate a conturilor; c) imaginea de învățare pentru MAP; d) imaginea segmentată prin metoda MAP; e) imaginea regularizată MAP-Markov




Figura 2. Erori medii de segmentare obținute prin rularea algoritmului de selecție a spațiului de culoare optim

Eroarea de segmentare ("bordererror") este dată de formula următoare:

$$BE = \text{Area}((A \cup M) - \text{Area}(A \cap M)) / \text{Area}(M),$$

unde A este regiunea obținută după segmentarea MAP și M este regiunea de hemangiom obținută din imaginea de adevăr teren corespunzătoare. Deoarece pentru spațiul $L^*a^*b^*$ am obținut eroarea minimă, am ales să folosim acest spațiu de culoare pentru antrenarea clasificatorului MAP și pentru segmentarea / regularizarea propriu zisă. Un exemplu de imagine obținută prin segmentare este în *Figura 1.d* (regiunea de hemangiom este afișată cu roșu), iar în *Figura 1.e* este un exemplu de imagine regularizată (cu $\beta=0.8$). Totuși, prin aplicarea acestei metode de segmentare, mici regiuni de piele mai roșietice care sunt similare cu regiunile de hemangiom mai pot fi confundate cu acestea, pentru unele imagini din baza de date, de exemplu pentru imaginea din *Figura 3.a*. Astfel, pentru a îmbunătăți segmentarea, am adăugat un pas de post-procesare constând în eliminarea unor mici regiuni depărtate de regiunea principală de hemangiom (în ipoteza că în imagine aceste regiuni nu pot fi decât segmentate eronat). Astfel, în *Figura 3.b* este prezentat rezultatul segmentării, iar în *Figura 3.c* se poate observa eliminarea micii regiuni segmentate eronat (îmbunătățirea BE în acest caz a fost de 7%).




Figura 3. a) imaginea originală; b) imaginea segmentată MAP-Markov; c) eliminarea regiunii de non-hemangiom

În Tabelul 1 se pot observa erorile medii (bordererror) obținute pentru toate cele 40 de imagini de test folosite. Eroarea medie finală este mai mică de 20%, acest rezultat fiind mai bun decât cel obținut în articolul [1], unde se raporta o eroare medie de 32.1%. Pentru peste 65% din imagini am obținut BE mai mic de 20%. Valoarea minimă a BE a fost de 2.91% și valoarea maximă de 51.02%. Spre comparație, în [1], BE minim a fost de 3.6% și maxim de 247,7%.

Aceste rezultate au fost prezentate la conferința internațională de e-Health și Bioinginerie (EHB 2015) care s-a desfășurat la Iași în perioada 19 – 21 noiembrie 2015.

Tabel 1. Erori medii pentru toate imaginile

Faza	Segmentare MAP	Regularizare MAP-Markov	Eliminare regiuni depărtate
Valoarea BE	20.89%	20.42%	19.49%

C. Segmentarea imaginilor prin conversia în planul Lab

În vederea segmentării imaginilor cu hemangiom s-a făcut mai întâi un studiu al valorilor pixelilor de hemangiom, respectiv ale pixelilor de piele din imagini, în spectrul vizibil, pentru a vedea cât de bine se separă hemangiomul de piele. Deoarece spațiul **Lab** este un spațiu de culoare mai potrivit analizei imaginilor într-un mod similar analizei legate de percepția umană, s-a făcut mai întâi o conversie a valorilor de hemangiom (din cropuri de hemangiom) și a valorilor de piele (din cropuri de piele) din spațiul de culoare **RGB** în spațiul de culoare **Lab**. Hemangiomul este foarte bine pus în evidență în planul **a**.


Hemangiom în spațiile de culoare **RGB** și **Lab**:




RGB



plan L




plan a



plan b

Pentru a analiza cât de bine se separă valorile de hemangiom de cele de piele, s-a făcut o reprezentare a lor în planul definit de valorile **a** și **b** (ale spațiului **Lab**). Din figura următoare se vede că valorile în planul definit de **a** și **b** nu sunt bine separate. În urma acestei segmentări, în zona *piele-hemangiom* au intrat și alte categorii de pixeli cum ar fi *pixeli din textile roșii*. Se pot alege, însă, niște valori care să delimiteze pielea și hemangiomul, de alte componente din imagine, urmând ca ulterior să fie diferențiate între ele.

Se dorește segmentarea automată a imaginilor în K clase ca prim pas pentru detecția hemangiomului. Pentru o mulțime de N puncte, descrise de vectori de dimensiune p ce trebuie împărțite în K clase (grupuri, clustere), algoritmul este descris mai jos.



D. Utilizarea metodei K-means clustering pentru segmentarea automată a imaginilor

Algoritmul propus

a) Inițializare :

a.1) se atribuie cei N vectori în K clase, ca în metoda propusă de *Arthur and Vassilvitskii*

a.2) o altă variantă este inițializarea centrelor claselor cu anumite valori dorite;

b) pentru fiecare din cei N vectori se calculează distanța față de centrele claselor și se atribuie vectorul X_i clasei k pentru care distanța este minimă.

c) după parcurgerea completă a setului de vectori se recalculează mediile claselor.


d) dacă niciun vector nu a fost mutat în altă clasă (sau media niciunei clase nu s-a modificat), algoritmul se încheie; dacă nu, se reia algoritmul de la *pasul b*.

Rezultate obținute.


Am implementat algoritmul folosind ambele metode de inițializare. În continuare sunt rezultatele obținute pentru segmentarea unei imagini în 4 și 5 clase.



Imagine originală




Imagine segmentată în 4 clase
folosind inițializare a.1




Imagine segmentată în 4 clase
folosind inițializare a.2



Imagine originală



Imagine segmentată în 5 clase
folosind inițializare a.1



Imagine segmentată în 5 clase
folosind inițializare a.2

În toate cele 4 cazuri de mai sus se constată că atât hemangiomul cât și alte obiecte roșii sunt clasificate greșit în aceeași clasă.

E. Utilizarea metodei PCA pentru detecția hemangiomului

PCA = Principal Component Analysis; Analiza Componentelor Principale

Algoritmul PCA presupune următoarele etape:

- se calculează matricea de covarianță a formelor de intrare
- se calculează valorile proprii și se ordonează descrescător: $\lambda_1 > \lambda_2 > \dots > \lambda_n$
- se calculează vectorii proprii asociați valorilor proprii: $[\Phi_1, \Phi_2, \dots, \Phi_n]^T$
- se construiește matricea K a vectorilor proprii: $K = [\Phi_1, \Phi_2, \dots, \Phi_n]^T$
- numărul m de trăsături care se rețin după transformarea unitară se obține din valoarea maximă admisibilă a erorii medii pătratice de estimare: $\varepsilon > p\%$
- fiecărei forme de intrare X_i se va aplica transformarea Karhunen-Loève:

$$Y = K \cdot X = [y_1, y_2, \dots, y_m]^T$$

Se vor reține numai $m < n$ componente ale lui Y , restul de $n - m$ componente fiind înlocuite cu valoarea 0, obținându-se astfel $\tilde{Y}$. Pentru vizualizarea lui $\tilde{Y}$ în spațiul inițial, se va aplica dezvoltarea Karhunen-Loève: $\tilde{X} = K^T \cdot \tilde{Y}$.

Baza de date

S-au folosit 4 clase, aceleași ca și la metoda SOM descrisă ulterior. Vectorii pentru care se calculează matricea transformării KL se obțin din cropuri de dimensiune $n \cdot n \cdot 3$ ($n = 11$). Deci un vector în spațiul inițial are 363 de componente.


Algoritmul propus

După proiectarea în spațiul KL , pentru a conserva 99.5% din energie se rețin 8 componente. Se vor proiecta apoi în spațiul KL redus mediile celor 4 clase.

Segmentarea unei imagini de test s-a realizat astfel:

- s-a realizat pentru imaginea de test transformarea de consistență a culorii (numim această imagine *imag_TCC*)
- s-a realizat trecerea din spațiul RGB în spațiul *CIE Lab* a imaginii *imag_TCC*
- valorile din planul *a* au fost aduse printr-o transformare liniară în intervalul $[0, 255]$ și s-a realizat segmentare pe planul *a* cu prag = 130
- pentru $x = 1$ la numărul de linii
 - pentru $y = 1$ la numărul de coloane
 - dacă $a(x,y) > \text{prag}$ // *a* reprezintă planul *a* din *CIE Lab* atunci pentru pixelul de coordonate (x,y) din imaginea *imag_TCC* se consideră cropul RGB de dimensiune $n \cdot n$ care este centrat în pixelul curent. Cropul respectiv va fi transformat într-un vector care va fi apoi proiectat în spațiul KL redus. Se calculează distanța dintre vectorul în spațiul KL redus și mediile claselor proiectate în spațiul KL redus. Vectorul respectiv va fi clasificat în clasa al cărei centru este mai aproape.

Rezultate obținute





Imagine originală



Imagine segmentată

Legendă:

Magenta = hemangiom; Galben = piele;

Cyan = piele ca hemangiom; Roșu = obiecte roșii non-hemangiom

Se poate observa că pixelii de hemangiom sunt greșit catalogați ca făcând parte din clasa obiectelor roșii (de non-hemangiom).

F. Utilizarea rețelei MLP pentru detecția hemangiomului

MLP = MultiLayer Perceptron (Rețea Perceptron Multistrat)


MLP este o rețea **supervizată** (lotul de antrenare este etichetat; fiecărui vector din lotul de antrenare îi este asociată o clasă).

Baza de date. S-au folosit 4 clase, aceleași ca și la metoda SOM descrisă ulterior. Vectorii folosiți pentru antrenare se obțin din cropuri de dimensiune $n \cdot n \cdot 3$ ($n = 11$).

Antrenare rețea MLP

- Rețeaua va avea pe stratul de intrare un număr de neuroni egal cu numărul elementelor din vectorul de intrare ($3 \cdot n^2$ pentru crop RGB. Pentru $n = 11 \rightarrow 363$ neuroni pe stratul de intrare).
- Odată cu vectorul de intrare i se transmite rețelei și clasa din care face parte cropul respectiv. Deoarece s-au utilizat 4 clase, în stratul de ieșire sunt 4 neuroni, care pot avea valorile 0 sau 1. *Exemplu:* dacă la intrarea rețelei se aduce un crop din *clasa 1*, atunci vectorul asociat ieșirii (cu alte cuvinte, vectorul de ieșire ideal pentru *clasa 1*) este $[1, 0, 0, 0]$. Dacă la intrarea rețelei se aduce un crop din *clasa 3*, atunci vectorul asociat ieșirii este $[0, 0, 1, 0]$ etc.
- Concluzionând, dacă antrenez rețeaua MLP cu cropuri RGB din K clase, fiecare clasă având N cropuri de dimensiune $n \cdot n$ pixeli, atunci va rezulta un set de vectori de antrenare format dintr-o matrice de $3 \cdot n^2$ linii și $K \cdot N$ coloane iar pentru ieșire va rezulta o matrice cu K linii și $K \cdot N$ coloane.

În figura de mai jos este reprezentată schematic rețeaua MLP implementată.



Arhitectura rețelei MLP utilizată

SEGMENTARE imagine test

Segmentarea unei imagini de test s-a realizat astfel:


- s-a realizat pentru imaginea de test transformarea de consistență a culorii (numim această imagine *imag_TCC*)
- s-a realizat trecerea din spațial RGB în spațiul *CIE Lab* a imaginii *imag_TCC*
- valorile din planul *a* au fost aduse printr-o transformare liniară în intervalul $[0, 255]$ și s-a realizat segmentare pe planul *a* cu *prag* = 130

- pentru $x = 1$ la numărul de linii
 - pentru $y = 1$ la numărul de coloane
 - dacă $a(x,y) > \text{prag}$ / a reprezintă planul a din *CIELab* atunci pentru pixelul de coordonate (x,y) din imaginea *imag_TCC* se consideră cropul RGB de dimensiune $n \cdot n$ care este centrat în pixelul curent. Acel crop este transformat într-un vector de dimensiune $3 \cdot n^2$ și se aduce la intrarea rețelei. La ieșirea rețelei se va obține un vector cu K elemente (unde K reprezintă numărul de clase, în cazul de față $K = 4$). În mod ideal se obține un vector cu $(K-1)$ zerouri și o valoare de 1. Poziția pe care se obține valoarea 1 reprezintă clasa în care va fi clasificat pixelul curent (în mod real se obțin $(K-1)$ valori foarte mici și o valoare foarte mare, apropiată de 1).

Rezultate obținute



Imagine originală



Imagine segmentată (verde = hemangiom)

După cum se poate observa din imaginile de mai sus, o parte dintre pixelii din clasele *Obiecte Roșii* și *Piele_Like_Hema* au fost clasificați greșit în clasa *Hemangiom*.

Utilizarea rețelei SOM pentru detecția obiectelor asemănătoare hemangiomului

În multe dintre imaginile analizate cu scopul detecției hemangiomului apar și obiecte de culoare asemănătoare hemangiomului precum unghiile vopsite în roșu, materiale textile roșii etc. Acest gen de obiecte îngreunează detecția corectă a hemangiomului, ducând la multe detecții false. De aceea s-a încercat detecția acestor pixeli utilizând o rețea SOM. Odată eliminați acești pixeli din imagine, șansele de detecție corectă a hemangiomului cresc.

Despre rețeaua SOM (Self-Organizing Map; Rețea cu auto-organizare)

SOM este o rețea **nesupervizată** (vectorii din lotul de antrenare nu trebuie să fie etichetați pentru a putea antrena rețeaua!). Însă pentru a putea decide corespondența dintre neuronii din stratul de ieșire și clase, varianta de SOM utilizată are nevoie de etichetarea vectorilor din lotul de antrenare. Cu alte cuvinte, **varianta de SOM utilizată este nesupervizată atunci când se antrenează rețeaua dar este supervizată după procesul de antrenare când trebuie ca fiecărui neuron din stratul de ieșire să i se atribuie o clasă.**

Antrenarea rețelei SOM pentru problema dată

- Se antrenează rețeaua cu cropuri de $n \cdot n$ pixeli ($n = 11$). Imaginea este transformată într-un vector linie cu $3 \cdot n^2$ elemente, deoarece este crop RGB.
- Rețeaua va avea pe stratul de intrare un număr de neuroni egal cu numărul elementelor din vectorul de intrare ($3 \cdot n^2$ pentru crop RGB).
- Rețeaua se auto-organizează (nesupervizat) în funcție de vectorii din lotul de antrenare. În urma antrenării, fiecare neuron din stratul de ieșire are asociat un vector de ponderi de dimensiune $3 \cdot n^2$.

Baza de date utilizată

Lotul vectorilor de antrenare conține 4 clase, astfel:

- clasa **Hemangiom**. Din 58 cropuri de hemangiom de diverse dimensiuni au fost selectate 1658 cropuri de dimensiune 11 x 11 pixeli în spațiul RGB.
- clasa **Piele**. Din 104 cropuri de piele de diverse dimensiuni au fost selectate 1566 cropuri de dimensiune 11 x 11 pixeli în spațiul RGB.
- clasa **Piele_like_Hema**. Din 44 cropuri de piele care seamănă cu hemangiom (zone de piele mai roșiatice) au fost selectate 1445 cropuri de dimensiune 11 x 11 pixeli în spațiul RGB.
- clasa **Obiecte_Roșii**. Din 22 cropuri de diverse dimensiuni care conțin obiecte roșii (este vorba despre acele obiecte care seamănă la culoare cu hemangiomul, precum: unghii vopsite cu oă roșie, îmbrăcăminte roșie etc) au fost selectate 1715 cropuri de dimensiune 11 x 11 pixeli în spațiul RGB.

Au rezultat în final **6384 de cropuri** de dimensiune 11 x 11 x 3.

Rețea SOM utilizată

- S-a folosit o rețea SOM hexagonală de **10 x 10 neuroni** pe stratul de ieșire.
- Deoarece cropurile au fost de dimensiune 11 x 11 x 3, rețeaua SOM are **363 neuroni în stratul de intrare**


După etapa nesupervizată de antrenare, urmează etapa supervizată de atribuire a unei clase fiecărui neuron din stratul de ieșire

- După etapa de antrenare, pentru fiecare clasă în parte, se aduc la intrarea rețelei vectorii din lotul de antrenare. Se calculează apoi distanța euclidiană dintre vectorii de antrenare și setul de ponderi asociat fiecărui neuron din stratul de ieșire. Se declară câștigător neuronul pentru care se obține distanța euclidiană minimă. După ce se trec prin rețea toți vectorii din lotul de antrenare dintr-o clasă, în final va rezulta o hartă unde în fiecare celulă se specifică câți vectori din lotul de antrenare au un anumit neuron câștigător.

Vor rezulta în cazul de față 4 hărți, câte una pentru fiecare clasă. În fiecare hartă se specifică pentru fiecare neuron din stratul de ieșire câți vectori de antrenare au fost alocați.

Exemplu: În figurile de mai jos:

- neuronul de coordonate (0,0) este câștigător pentru 44 vectori din clasa *Piele* și pentru 63 vectori din clasa *Piele_like_Hema*;
- neuronul de coordonate (1,0) este câștigător pentru 68 vectori din clasa *Piele* și pentru 0 vectori din celelalte clase;



Se poate observa că există o destul de bună separare a vectorilor din clasa *Obiecte Roșii* de restul vectorilor din celelalte clase. **De aceea am folosit rețeaua SOM pentru a detecta pixelii problematici care seamănă cu hemangiomul.**

Pasul final al etapei de antrenare a fost acela de normare a hărților pentru fiecare clasă.

$$n_perc_{(x,y)}^{(k)} = \frac{n_{(x,y)}^{(k)}}{\sum_{i=0}^9 \sum_{j=0}^9 n_{(i,j)}^{(k)}}$$

- $n_{(x,y)}^{(k)}$ reprezintă numărul vectorilor din clasa k care au câștigător neuronul de coordonate (x, y)
- $n_perc_{(x,y)}^{(k)}$ reprezintă procentul vectorilor din clasa k care au câștigător neuronul de coordonate (x, y)

După această etapă, fiecărui neuron din stratul de ieșire al rețelei SOM i se va asocia clasa din care fac parte procentual cei mai mulți vectori.

1	1	1	1	1	1	1	2	2	3
1	1	3	3	1	3	1	1	2	4
2	1	2	3	2	2	3	3	1	4
2	1	3	2	3	3	3	2	1	4
2	2	2	2	3	3	3	1	3	4
2	2	3	3	1	1	1	1	1	4
4	2	3	1	1	1	1	1	4	4
4	4	1	2	4	1	1	3	1	4
2	2	2	3	3	1	1	1	1	4
3	2	2	2	2	1	2	1	4	4

1 = clasa **Hemangiom**

2 = clasa **Piele**

3 = clasa **Piele_like_Hema**

4 = clasa **Obiecte_Roșii (non-hemangiom)**

În cazul de față, neuronului de coordonate $(0,0)$ i se va asocia clasa *Piele_like_Hema*, neuronului de coordonate $(1,0)$ i se va asocia clasa *Piele* etc.

SEGMENTARE imagine test


Segmentarea unei imagini de test s-a realizat astfel:

- s-a realizat pentru imaginea de test transformarea de consistență a culorii (numim această imagine *imag_TCC*)
 - s-a realizat trecerea din spațial RGB în spațiul *CIELab* a imaginii *imag_TCC*
 - valorile din planul a au fost aduse printr-o transformare liniară în intervalul $[0, 255]$ și s-a realizat segmentare pe planul a cu $prag = 130$
 - pentru $x = 1$ la numărul de linii
 - pentru $y = 1$ la numărul de coloane
 - dacă $a(x,y) > prag$ // a reprezintă planul a din *CIELab*
- atunci pentru pixelul de coordonate (x,y) din imaginea *imag_TCC* se consideră cropul RGB de dimensiune $n \cdot n$ care este centrat în pixelul curent. Acel crop este transformat într-un vector de dimensiune $3 \cdot n^2$ și se aduce la intrarea rețelei. Calculez apoi distanța euclidiană dintre vectorul de test și setul de ponderi asociat fiecărui neuron din stratul de ieșire. Neuronul pentru care obțin distanța minimă este declarat câștigător iar

pixelul pentru care s-a calculat acea distanță va fi clasificat în clasa alocată acelui neuron.

Rezultate obținute

În imaginile de mai jos sunt câteva exemple de detecție a obiectelor roșii (non-hemangiom).



Imagine originală

Imagine segmentată

Legendă:

Pixeli albi și roșii = pixeli obținuți în urma segmentării pe planul a

Pixeli roșii = pixeli considerați obiecte roșii non-hemangiom

III. EXTRAGERE DE TRĂSĂTURI

A. Operatorul Local Binary Pattern

Clasificarea texturilor este un domeniu important de cercetare în perspectiva computerizată și recunoașterea tiparelor. Textura bazată pe descrieri a fost utilizată ca obiect, scene și clasificări. Nenumărate abordări pot fi găsite în literatura de specialitate pe baza băncilor de filtrare, statistici co-apariție (Haralick, 1979), la scară locală (Ojala et al., 2002) și mai recent pe setarea de puncte cheie (Ling and Soatto, 2007) și nenumărate scheme fractalice (Xu et al., 2009). Dintre acestea, algoritmul binar local (LBP) (Ojala et al., 2002) a câștigat popularitate datorită simplității de calcul și bunelor performanțe. Originalul algoritmul binar local (LBP) invariază de la scara de gri monoton schimbându-se când este calculat să ia diferența dintre intensitatea pixelilor.

În această etapă, una dintre metodele aplicate pentru caracterizarea regiunilor de hemangiom constă în utilizarea modelului LBP – Local Binary Pattern.

Algoritmul propus


Pe scurt, metoda presupune următorii pași:

- pentru fiecare pixel din imagine se compară pixelul cu cei 8 vecini ai săi (în ordinea sensului acelor de ceasornic)
- dacă valoarea pixelului considerat > valoarea pixelului din vecinătate → codul 1
- dacă valoarea pixelului considerat < valoarea pixelului din vecinătate → codul 0
- convertim șirul de 8 biți în zecimal → codul LBP pentru pixelul considerat.
- calculul histogramei normalizate a codurilor rezultate pentru fiecare pixel din imagine

Pentru aplicarea operatorului, am selectat manual 1500 de cropuri de hemangiom, respectiv 1500 cropuri de regiuni non-hemangiom.

Mai jos am evidențiat câteva rezultate obținute pentru operatorul LBP pentru zone de hemangiom, respectiv non-hemangiom.

Rezultate



În *Anexa 2* pot fi vizualizate rezultatele a 100 de cropuri de hemangiom/ ne-hemangiom încadrate într-o stivă.

Referințe

- [1] - Arjan Gijsenij, Rui Lu și Theo Gevers, "Color Constancy for Multiple Light Sources", IEEE TRANSACTION ON IMAGE PROCESSING, VOL. 21, NO. 2, August 2011, pp. 697-707.
- [2] J. van de Weijer, T. Gevers, and A. Gijsenij, "Edge-based color constancy", *IEEE Transactions on Image Processing*, vol. 16, no. 9, pp. 2207–2214.

B. Histograma gradientilor orientați HOG

Pentru delimitarea pixelilor de hemangiom de cei de piele și de textile roșii s-a încercat separarea pe baza histogramei gradientilor orientați (HOG).





Deoarece forma hemangiomului diferă de la caz la caz, forma hemangiomului nu oferă informație relevantă. Pe de altă parte, toată suprafața hemangiomului este o textură relativ uniformă. Din aceste motive, pentru calcularea HOG pe hemangiom/piele/textile s-au ales cropuri care sunt decupate din interiorul zonelor de hemangiom/piele/textile fără a prinde informație din exteriorul lor.

Pentru fiecare crop (de hemangiom/piele/textile roșii), în fiecare pixel s-a decis dacă pixelul e în zona uniformă și, în caz contrar, s-a calculat direcția gradientului său. S-au folosit 8 direcții: 0° , 45° , 90° , 135° , 180° , 225° , 270° , 315° . S-a calculat gradientul corespunzător fiecărei măști și s-a ales direcția corespunzătoare gradientului de valoare maximă. Dacă valoarea maximă este mai mică decât un prag ales, se consideră că pixelul este într-o zonă uniformă. Calculul gradientilor s-a făcut utilizând măști Prewitt.

Apoi s-a făcut histograma corespunzătoare direcțiilor de gradient obținute. Deci histograma gradientilor orientați are, astfel, 9 valori (8 valori corespunzătoare celor 8 direcții și o valoare corespunzătoare situației în care pixelul a fost într-o zonă uniformă). Pentru fiecare crop s-a făcut HOG pe planurile L , a și b și s-au concatenat cele 3 histogramme. S-a obținut astfel ca descriptor un vector cu 27 de componente.

Calculând pentru toate cropurile de hemangiom s-a obținut o matrice cu HOG. Similar pentru cropurile de piele și pentru cele de textile roșii. Cele 4 matrice vizualizate ca imagini:

Rezultate. Cele 4 matrice vizualizate ca imagini.







Aceste matrice au fost folosite pentru antrenarea unei rețele SOM.

Anexe


Anexa 1. Rezultatele antrenării rețelei SOM cu descriptorii HOG și GrSD

1.a. Rezultatele antrenării rețelei SOM cu descriptorii HOG




Se observă că neuronii câștigători pentru clasa *hemangiom* sunt cei din partea stângă și cei din partea dreaptă sus. Cei din partea stângă au scor mare pentru hemangiom și deloc sau foarte mic pentru celelalte clase. Cei din partea dreaptă sus par și ei a separa bine hemangiomul de celelalte clase.

1.b. Rezultatul antrenării cu GrSD (Gradient Structure Descriptor)




1.c. Rezultatul antrenării cu HOG și GrSD




Anexa 2. Extragere de trăsături cu operatorul LBP


2.1. Cropuri de *hemangiom*



Cropuri hemangiom




Codurile LBP rezultate




Histogramele aferente


2.2. Cropuri de *ne-hemangiom*



Cropuri ne-hemangiom



Codurile LBP rezultate



Histogramele aferente

Raport de cercetare Universitatea Valahia Târgoviște (P2)

Echipa UVT de tineri s-a concentrat pe:

- Construirea unui sistem CBIR (*Content Based Image Retrieval*) prototip pentru căutarea imaginilor pe baza trăsăturilor
- Optimizarea căutării pe bază de trăsături în baze de date relaționale SQL

Pentru creșterea preciziei interpretării evoluției hemangiomului, medicii au nevoie de o creștere a preciziei a sistemelor de identificare a imaginilor medicale similare pe bază de conținut [1]. De asemenea, un sistem CBIR performant poate ajuta medicul în procesul de interpretare al evoluției hemangiomului de piele și punerea în evidență a noi tipuri de hemangiom. Literatura sistemelor CBIR este foarte diversă, unele sisteme CBIR propuse în literatura de specialitate fiind propuse pentru căutarea imaginilor de orice tip [2], iar alte sisteme CBIR sunt specializate pe aplicații, cum ar fi imaginile medicale[3].

Din punct de vedere al utilizatorului, sistemele CBIR îi permit acestuia să caute imagini similare pe baza conținutului vizual al imaginii. Modul de funcționare este următorul: utilizatorul introduce ca dată de intrare o imagine, iar sistemul CBIR își interoghează baza de date de imagini pe baza trăsăturilor extrase din imaginea de intrare și returnează cele mai bune potriviri cu imaginea de intrare pe baza unei distanțe. Imaginea de interogare poate fi imaginea întreagă, o parte din imaginea întreagă sau o imagine extrasă dintr-o regiune de interes (*image ROI-Region of Interest*). În cazul imaginilor medicale cu hemangiom, baza de imagini a sistemului CBIR va fi formată din două tipuri de imagini: imaginea cu hemangiom inițială și zona (sau zonele) de interes extrase din imaginea inițială. Căutarea va fi efectuată doar pe baza imaginilor de interes.




Figura 1. a) Imaginea Originala; b) Imagine ROI

Arhitectura informatică a sistemului CBIR

Performanțele sistemelor CBIR depind de tehnologia informatică folosită. În trecut, din motive de performanță, sistemele CBIR erau aplicații Desktop sau foloseau tehnologii Web proprietare (Java Applet, Adobe Flash etc.) pentru partea de *client*, care în ultima vreme au creat numeroase incidente de securitate. Din acest motiv, pentru a reduce complexitatea și numărul de vulnerabilități de securitate sunt recomandate următoarele tehnologii informatice pentru partea de client: HTML5, CSS și JavaScript. Tehnologiile HTML5 și CSS pot fi folosite pentru crearea design-ului interfeței grafice a sistemului CBIR, iar pentru interacțiunea cu utilizatorul și server-ul Web va fi utilizat limbajul JavaScript. Interogarea bazei de date cu trăsături din imaginile medicale se va face prin intermediul server-ului Web. Din motive de performanță imaginile medicale nu vor fi salvate în baza de date și vor fi salvate pe un suport de memorie externă, iar în baza de date va fi memorată calea către imagini. Din punct de vedere informatic avem o arhitectură 3-tier care asigură o securitate și o performanță mai bună decât arhitecturile clasice 2-tier (arhitecturi client-server).

În implementarea sistemului CBIR prototip a fost ales server-ul Web Apache pentru executarea scripturilor PHP, iar baza de date relațională pentru memorarea trăsăturilor este MySQL. Interfața WEB pentru client a fost realizată în HTML5 și CSS, iar pentru interacțiunea cu utilizatorul și calculul

trăsăturilor din imaginea a fost folosit limbajul JavaScript. La nivel client, browser-ele Web au devenit mai performante în execuția scripturilor JavaScript ceea ce permite prelucrări de imagini pe partea de client. Avantajul extragerii trăsăturilor din imaginea de interogare pe partea de client a permis creșterea performanțelor sistemelor CBIR.

Trăsături texturale analizate

Trăsăturile extrase dintr-o imagine texturată reprezintă descriptorul texturii. Pentru sistemul CBIR web propus a fost investigată crearea descriptorului texturii pornind de la folosirea trăsăturilor extrase din matricea de coocurență medie GLCM (Gray Level Cooccurrence Mean)[4-5]. Vom nota cu $C_m(d)$ matricea de coocurență pentru direcția i calculată pentru pixelii cu distanța d . Matricea de coocurență medie este următoarea:

$$C_m(d) = \frac{1}{8} \sum_{i=1}^8 C_i(d)$$

Următoarele trăsături au fost calculate din matricea $C_m(d)$ pentru construirea descriptorului texturii:
Energie:

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

Entropie:

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

Contrast:

$$Con(d) = (i - j)^2 \sum_i \sum_j C_m(d)(i, j)$$

Omogenitate:

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

Varianță:

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

unde:

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

este media aritmetică a matricei de coocurență medie. Pentru calcul similarității între două imagini I_1 și I_2 s-a utilizat următoarea distanță Euclidiană:

$$D(I_1, I_2) = \sqrt{(Ene_1 - Ene_2)^2 + (Ent_1 - Ent_2)^2 + (Con_1 - Con_2)^2 + (Omo_1 - Omo_2)^2 + (Var_1 - Var_2)^2}$$

Un element original al sistemului CBIR propus este că distanța Euclidiană nu este calculată de server-ul Web Apache și de către server-ul de baza de date MySQL. Această soluție permite server-ului WEB să proceseze mai multe interogări utilizatori, deoarece limbajul PHP fiind un limbaj interpretat este mai lent. Interogarea SQL poate fi compilată într-o procedură stocată și apelată de server-ul web Apache sau orice altă aplicație care permite conectarea la MySQL. Șablonul de proiectare SQL pentru interogare este următorul:

```
select F.ImageID,
       concat("http://webadress/", G.Path, G.ImageName) as LinkName,
       G.ImageName as ImageName
from (
       select distinct E.id1 as ImageID
       from (
               select A.imageid id1, A.dist1,
```

```

from (
    select @i1:=@i1+1 as iter1,
           imd.imgid,
           pow('.$Ent1.'-imd.Ent,2) as Dist1
    from imagini_data imd
    join (SELECT @i1:=0) foo
    order by Dist1
    limit 0,15
) A
) E
) F left join imagini G on F.ImgID=G.ImgID


```

Mai multe detalii despre aceste cercetari vor fi publicate in volumul unei conferinte internationale in 2016.


Echipa de cercetatori cu experienta s-a axat pe studierea si aplicarea unor metode de pre-procesare a imaginilor cu hemangioame, alinierea lor, fuzionarea mai multor surse de imagini. Din nefericire conditiile de achizitie ale imaginilor clinice au fost foarte variate mai ales in ce priveste pozitionarea pacientului, iluminarea diferita, folosirea altor parametri de achizitie in zile diferite etc. S-a inceput cu investigarea unor metode de reducere a zgomotului si a unor tehnici de imbunatatirea a contrastului in regiunile relevante selectate anterior.

Un alt factor important ce poate conduce la rezultate îmbunătățite ale segmentării este lucrul cu imagini de calitate înaltă cu contrast bun [6]. S-a propus o metoda bazata pe o modelare a histogramei imaginilor si modelarea acesteia ca un semnal uni-dimensional [7]. Folosind o analogie cu analiza prin predictie liniara a unui semnal vocal sonor, s-a facut o modelare LP a histogramei. Concentrarile in histograma corespund unor imagini prea luminate, prea intunecate sau cu culori dominate. S-a folosit un ordin de predictie mai mic si s-a aplicat o transformata inversa modelului histogramei modificate. S-a obtinut astfel un curba neliniara care a fost folosita pentru imbunatatirea imaginii originale. Metoda propusa impune utilizarea unui modul FFT precum si a unui modulul de predictie liniara. S-a aratat in [7] ca metoda propusa obtine rezultate comparabile cu alte metode de imbunatatire a imaginilor prin cateva masuratori obiective. S-au evidentiat unele neajunsuri care apar atunci cad histograma imaginilor este rara sau puternic diferita de modelul LP al semnalului vocal sonor. S-a propus o filtrare a valorilor histogramei folosind o medie a iesirilor a doua filtre IIR actionand pe directii opuse pe semnalul 1D [7].

Totodata s-a extins aceasta metoda pentru fisiere video. S-a observat ca nu se schimba foarte mult coeficientii LP de la un cadru la altul. S-a propus astfel folosirea metodei iterative Gauss-Seidel pentru actualizarea acestor coeficient si s-a aratat ca acest pas duce la o reducere semnificativa a complexitatii acestei parti. Se folosesc ca aproximare initiala coeficientii de predictie liniara ai cadrului precedent [7].



a)



b)

Figura 2. a) Norma erorii dintre coeficientii LP calculati in cadre diferite ale fisierului video; b) Norma erorii dintre coeficientii LP exacti si cei aproximati cu o iteratie Gauss-Seidel [7]

Mai multe detalii pot fi gasite in articolul publicat in volumul ICCE 2015.

Amplificarea schimbarilor subtile din fisiere video

S-a incercat utilizarea secvențelor video cu hemangioame și amplificarea schimbărilor subtile de culoare. O prima operatie a reprezentat-o alegerea momentului oportun in selectarea cadrelor video cu regiuni relevante corespunzatoare unor perioade cum ar fi „copilul se misca” sau „copilul nu se misca”. S-a investigat folosirea unor algoritmi de amplificare euleriana [8] pe zone de piele curata precum si pe zona hemangioamelor. Amplificarea schimbărilor în imagini video din [8] s-a dovedit încununată de succes in redarea în mod vizibil a schimbările de culoare ale feței care nu se văd cu ochiul liber și care sunt produse de fluxul sangvin.

S-a folosit un algoritm de identificare a regiunilor cu piele apropiate de cele cu hemangioame [9]. S-au fuzionat cadrele filtrate temporal și descompuse spațial pentru a revela informația ascunsă. Ca și în [8] se poate vizualiza fluxul sangvin și mișcările minuscule induse de acesta în timp ce umple vasele de sânge ale hemangiomului. Se pare ca aceste schimbări amplificate oferă o informație adițională pe lângă cele de formă și aspect ale hemangioamelor. Totusi o problema majora o reprezinta zgomotul amplificat si artefactele de culoare cauzate de tremurul mainii persoanei care a filmat pacientul. Prin urmare, investigarea unor metode de reducere a zgomotului si selectia corecta a parametrilor metodei de amplificare euleriana va fi continuata in 2016.

Deasemenea s-a investigat posibilitatea detectarii unor miscari subtile ale vaselor capilare invadate de sange folosind transformata Riesz si o metoda de extragere a miscarii bazata pe faza din fisiere video descrisa in [10].


Rezultatele acestor cercetari sunt promitatoare si vor fi publicate in 2016.

Alinierea de imagini

Aplicarea directa a metodelor de aliniere de imagini bazate pe intensitati propuse anterior [11]-[14] s-a dovedit dificila. S-a investigat combinarea metodelor de proiectie integrala cu DTW (Dynamic Time Warping) [16]. Deformarea dinamica a timpului se bazeaza pe șabloane și potrivire cu programare dinamica pentru măsurarea similitudinii dintre serii de timp. Acest model s-a folosit cu success si in alta aplicatie de prelucrare de imagini [15]. In acest caz s-au adaptat tehnicile anterioare pentru zoom [11], rotatii [12], transformari radiale [14] si s-au combinat cu DDTW [17]. S-au obtinut rezultate mai bune decat in cazul aplicarii metodei celor mai mici patrate [18] respectiv cu transformata Radon [24]. Un exemplu sintetic pentru cazul rotirii este aratat in Figura 3.

Deasemenea s-a incercat alinierea in doi pasi: o prima aliniere folosind vectorii integrali de proiectie urmata de o aliniere folosind o deformare dinamica a timpului. Acesta idee functioneaza bine pe cazuri cu translatare/rotatii/scalari controlate dar a condus in mod satisfactor si la erori mai mici de aliniere pe cazul imaginilor reale cu regiuni relevante de hemangioame relativ asemanatoare. S-a observat ca erorile scad in cazul considerarii de jumatați de vectori de proiectie integrala precum si daca se elimina singularitatile de deformare. Folosirea DDTW conduce la o robustete marita fata de diverse artefacte, variatii de iluminare, blurare etc. Totusi, sunt necesare mai multe studii pentru a determina limitele de utilizare ale metodelor bazate pe vectorii de proiectie integrala.

Rezultatele cercetarilor in domeniul alinierii bazate pe vectorii de proiectie integrala, precum si cu o noua metoda bazata pe LPB (Local Binary Pattern) sunt incurajatoare si vor fi publicate in 2016.



a) b)
Figura 3. a) Vectorii gradientilor proiectiilor integrale pentru unghiuri diferite; b) Deformarea calculata dintre vectorii de proiectie liniara

S-a studiat alinierea spatiala prin stabilirea unei corespondente intre doua imagini precum si alinierea intr-un sistem de coordonate comun. Deasemenea s-a incercat o aliniere temporala condusa de modificarile de forma ale hemangiomului punand in corespondenta traiectoriile de progresie. Si in acest caz s-a incercat folosirea unei deformari ne-liniare monotone care sa minimizeze un cost masurand disimilaritatea dintre trasaturile hemangioamelor. Totusi investigatiile privind functia de cost optima vor continua in 2016. O alta idee investigata presupune estimarea unei evolutii medii de progresie a hemangiomului printr-o analiza statistica si o vizualizare a schimbarilor care apar in timp [18]. Folosirea unor metrice diferite [19] care nu presupun o corespondenta exacta ar putea fi deasemenea explorata.

Procesul de aliniere ar putea fi ajutat in cazul disponibilitatii unor puncte cheie [21]. S-a investigat o metoda [21] ce gaseste punctele cheie in doua imagini iar corespondenta lor se face folosind metoda SIFT [22]. Homografia intre doua imagini este determinata folosind RANSAC. S-a observat ca exista o scadere a performantelor metodei de aliniere in cazul unor diferente mari ale formei hemangioamelor. Deasemenea s-a observat ca distributia neregulata a potrivirilor conduce la erori de aliniere locale. Acestea sunt cauzate de regiuni nereprezentate bine de potrivirile gasite de algoritm. Aceste investigatii vor fi continuate anul viitor.




Figura 4. Potrivire cu metoda prezentata mai sus

Fuziunea de imagini

Prin fuzionarea de imagini se doreste sa se combine informatiile complementare continute in mai multe imagini pentru a produce o imagine cu o calitate superioara. S-a incercat combinarea informatiilor la nivel de pixel. S-au investigat mai multe metode cunoscute de descompunere piramidala [25] (laplaciana [26], FSD, contrast, gradient, raport etc). Deasemenea s-au incercat si metode liniare (superpozitie liniara, sau superpozitie ponderata PCA) precum si metode neliniare bazate pe valoarea minima sau maxima [27]. Rezultate preliminare indica performante mai bune ale metodelor bazate pe DCT sau pe Wavelet. Metricile de evaluare au fost PSNR, SSIM, frecventele spatiale si indexul de calitate a fuziunii. Investigatiile in fuziunea imaginilor vor fi continuate anul viitor.

Bibliografie

1. Camille Kurtz, Christopher F. Beaulieu, Sandy Napel, Daniel L. Rubin, A hierarchical knowledge-based approach for retrieving similar medical images described with semantic annotations, *Journal of Biomedical Informatics*, Vol. 49, pp. 227-244, 2014
2. Wang S, Summers RM. Machine learning and radiology, *Med. Image Anal.*, Vol. 16, No. 5, 2012
3. Akgül CB, Rubin DL, Napel S, Beaulieu CF, Greenspan H, Acar B, Content-based image retrieval in radiology: current status and future directions, *J. Digit. Imaging*, 2011
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. Sebastian Zambanini, Georg Langs, Robert Sablatnig, "Segmentation and Surveying of Cutaneous Hemangiomas", in *Proceedings of Computer Vision Winter Workshop CVWW 2005*, pp.103-112

7. Albu F., „Linear prediction based image enhancement method”, Proc. of IEEE International Conference on Consumer Electronics 2015, pp. 496-499, Sept. 2015.
8. Michael Rubinstein, Eugene Shih, John Guttag, Frédo Durand, William T. Freeman, "Eulerian video magnification for revealing subtle changes in the world", ACM Trans. Graph. (Proceedings SIGGRAPH 2012), 31(4), 2012
9. Vezhnevets, Vladimir, Vassili Sazonov, and Alla Andreeva. "A survey on pixel-based skin color detection techniques." *Proc. Graphicon*. Vol. 3. 2003.
10. Wadhwa, Neal, et al. "Phase-based video motion processing." *ACM Transactions on Graphics (TOG)* 32.4, 80, 2013.
11. Albu F., "Registration of Differently Scaled Images", US Patent 20130070126, 2013
12. Albu F, Murray L., Stec P., Raducan I., "Fast Rotation Estimation", US Patent 13028203, 2011
13. 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
14. Albu, F. Corcoran P., "Transformed Integral Projection Method for Global Alignment of Second Order Radially Distorted Images", in Proc. of IEEE SPA 2014 conference, September 2014, pp. 42-47.
15. Albu, F. Hagiescu D. and Puica M.A., "Quality evaluation approaches of the first grade children's handwriting", The 10th International Scientific Conference eLearning and software for Education Bucharest, April 24-25, 2014, pp. 17-23
16. Konstadinova E., Boeva V., Boneva L., and Tsiporkova E., An Integrative DTW-based imputation method for gene expression time series data. *IEEE Conf. of Intelligent Systems 2012*: 258-263.
17. 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
18. M. Veldandi, S. Ukil, K.G. Rao, Video stabilization by estimation of similarity transform from integral projection, Proc. of ICIP 2013, pp. 785-789.
19. S. Durrleman, X. Pennec, A. Trounev, J. Braga, G. Gerig, and N. Ayache, "Toward a comprehensive framework for the spatiotemporal statistical analysis of longitudinal shape data," Int. J. Comput. Vis., vol. 103(1), pp. 22-59, 2013.
20. M. Vaillant and J. Glaunes, "Surface matching via currents," in Proc. Inform. Process. Med. Imag. (IPMI), 2005.
21. Sebastian Zambanini, Georg Langs, Robert Sablatnig, and Harald 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), pages 121-128, 2007
22. D. G. Lowe, „Distinctive image features from scale-invariant keypoints”, IJCV, 60(2):91-110, 2004.
23. M.A. Fischler and R.C. Bolles, "Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography", Communications of the ACM, 24(6):381-395, 1981
24. F. Hjouj and D. W. Kammler, "Identification of Reflected, Scaled, Translated, and Rotated Objects from their Radon Projections", IEEE Transactions on Image Processing, vol. 17, no. 3, pp. 301-310, March 2008.
25. P.J. Burt - "The pyramid as a structure for efficient computation", in: A. Rosenfeld (Ed.), Multiresolution Image Processing and Analysis, Springer-Verlag, Berlin, pp. 6-35, 1984
26. P.J. Burt, E.H. Adelson, "The laplacian pyramid as a compact image code", IEEE Transaction on Communications, vol. 31, pp. 532-540, 1983.
27. <http://www.metapix.de/short.htm>

Raport de activitate Medical Technologies and Research (P3)

În cadrul proiectului HEMACAD, Medical Technologies & Research 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:

CONFERINȚA NAȚIONALĂ DE CHIRURGIE 14-17 OCTOMBRIE 2015.

CONFERINȚA NAȚIONALĂ DE MEDICINA FAMILIEI 21-24 OCTOMBRIE 2015.

CONFERINȚA NAȚIONALĂ DE FARMACIE 11-14 NOIEMBRIE 2015.

CONFERINȚA NAȚIONALĂ DE MICROBIOLOGIE ȘI EPIDEMIOLOGIE 12-14 NOIEMBRIE 2015.

Pe parcursul conferințelor au fost distribuite broșuri către medicii de familie, chirurghi, etc care au completat comunicările despre inițierea și scopul proiectului efectuate în mai multe clinici de neonatologie și pediatrie din București și din alte centre universitare din țară.

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

În conformitate cu **informațiile stranse de la medici**, în majoritatea cazurilor aceștia recomandă:

- Îndepărtarea hemangioamelor cu ajutorul laserului după ce hemangiomul a atins dimensiunile minimale.
- Cauterizarea cu laser dacă hemangiomul sângerează, dacă pe suprafața acestuia apare o rană sau dacă hemangiomul provoacă dureri.
- Cauterizarea cu ajutorul laserului deoarece acesta accelerează vindecarea leziunilor ce se formează la suprafața hemangioamelor, reduce durerile în regiunea cu hemangioame și accelerează micșorarea acestora.
- Medicul recomandă cauterizarea hemangioamelor cu laser, dacă acestea se situează pe degetele, pleoapele, buzele, urechile sau fața copilului.
- Medicul recomandă proceduri de cauterizare o dată la 2-4 săptămâni, până ce hemangiomul dispare cu totul.
- Medicul recomandă îndepărtarea hemangiomului dacă acesta sângerează deseori, dacă pe suprafața sa apare o rană sau dacă hemangiomul nu dispare după ce copilul împlinește 5-6 ani.

În ceea ce-i privește pe **pacienți** sau părinții copiilor tratați cu laser aceștia consideră ca:

- Laserul este solutia cea mai potrivita pentru îndepărtarea urmelor pe care le lasă hemangiomul pe piele.
- Indepartarea hemangiomului este absolut necesara daca acesta împiedică dezvoltarea normală a copilului (de exemplu, dacă se formează în regiunea ochilor, gurii, căilor respiratorii).

Efectele laserului asupra tesuturilor bogat/excesiv vascularizate

Pe o leziune vasculara, laserul emite pulsuri luminoase care sunt absorbite de catre hemoglobina din sange si sunt transformate in caldura . Aceasta este preluata, apoi, de catre peretii vasculari producand inchiderea vaselor. Sunt necesare mai multe sedinte la interval de cateva saptamani pana la vindecarea definitiva a leziunii.

Laserul este eficace în reducerea pigmentării și a altor leziuni vasculare. Laserul este, de asemenea, eficient în eliminarea vasele mici, care sunt lăsate în urmă, după ce un hemangiom a involuat.

Caracteristicile laserului si proprietățile terapeutice

Terapia cu laser este utilizata pentru a trata hemangioamele superficiale și hemangioamele ulcerate. Această metodă de tratament s-a dovedit a fi eficace în tratarea hemangioamelor in fază incipientă de creștere, pentru a ajuta la vindecarea ulceratiilor și a îmbunătăți aspectul vaselor de sange rezidual după involuție.

Există unele reacții adverse cunoscute ale terapiei cu laser. Terapia cu laser poate duce la hipopigmentare a zonei tratate. Aceasta poate provoca încălzirea pielii care poate provoca cicatrici.

Caracteristicile laserului achizitionat prin proiect sunt dupa cum urmeaza:

Tip Laser: Dioda Laser

Lungime de unda: 940nm

Gama tratament:

- leziuni vasculare, vene spider, vene faciale, excizia telangiectaziilor si ale hemangioamelor superficiale, etc

Putere: 50 Watt

Mod de lucru: CW

Laser conduct: Fiber conduct

Indicator: Diode laser 3mW 650nm

Sistem de racire: Racire intensa

Material corp: ABS

Dimensiuni: 337(W) x 495(L) x 297 (H) mm

Voltaj: AC 220V/110V 50/60HZ 5A/10A

Dupa instalarea laserului vom promova in randul pacientilor din spitalele din Municipiul Bucuresti, etc, in randul medicilor de familie, precum si in clinicile de neonatologie si pediatrie disponibilitatea laserului in vederea efectuarii de tratamente la copii cu hemangioame.

Concluzii

Toate obiective propuse in cadrul etapei au fost indeplinite.

Diseminare

Rezultatele obtinute au fost publicate in urmatoarele articole:

- Automatic Segmentation of Infantile Hemangiomas, A. Sultana, M. Zamfir, M. Ciuc, S. Oprisescu, M. Popescu, 12-th International Symposium on Signals, Circuits and Systems (ISSCS), Iasi, Romania, 2015.
- Automatic Segmentation of Infantile Hemangiomas Within an Optimally Chosen Color Space, S. Oprisescu, M. Ciuc, A. Sultana, I. Vasile, International Conference on e-Health and Bioengineering, (EHB 2015), Iasi, Romania, 2015.
- Automatic Evaluation of Hemangiomas for Follow-up Monitoring, A. Sultana, S. Oprisescu, M. Ciuc, International Conference on e-Health and Bioengineering, (EHB 2015), Iasi, Romania, 2015.
- Linear Prediction based Image Enhancement Method, F. Albu, Proc. of IEEE International Conference on Consumer Electronics 2015, Berlin, Germany, pp. 496-499, Sept. 2015.
- Dumitrache, I.; Sultana, A.-E.; Dogaru, R., "Feature Extraction from the Contour of Skin Lesions Using Box Counting Principle," in Control Systems and Computer Science (CSCS), 2015 20th International Conference on , vol., no., pp.548-553, 27-29 May 2015.
- Proposal for future diagnosis and management of vascular tumors by using automatic software for image processing and statistic prediction, M. D. Popescu, L. Draghici, I. Secheli, M. Secheli, M. Codrescu, I. Draghici, Journal of Medicine and Life, pp. 44-48, vol. 8, issue 1, January - March 2015
- Diagnosis and treatment of the cutaneous and subcutaneous infantile hemangioma - experience of the Surgical Department of M.S. Curie Hospital Bucharest , M. Popescu, A. Raicu, L. Draghici, I. Secheli, M. Secheli, I. Draghici, 7th Congress of the Romanian Society for Pediatric Surgery, 29-31 Oct. 2015, Bucharest (*prezentare la conferinta*).