



IOSUD – UNIVERSITATEA „DUNĂREA DE JOS” DIN GALAȚI

Școala Doctorală de Inginerie Mecanică și Industrială

Proiect cofinanțat din Fondul Social European Operațional Capital Uman 2014-2020

TEZĂ DE DOCTORAT

REZUMAT

INSTRUMENTE MODERNE DE DEPISTARE A MELANOMULUI CUTANAT – Aplicație SelfChecker pentru analiza nevilor și melanoamelor prin intermediul imaginilor digitale

**Doctorand,
Ing. Felicia - Anișoara MICHIȘ (DAMIAN)
Conducător științific,
Prof. dr. ing. fiz. Luminița MORARU**

**Lucrare realizată în cadrul proiectului
„Program pentru creșterea performanței și inovării în cercetarea doctorală și
postdoctorală de excelență - PROINVENT”
Contract nr: 62487/03.06.2022 POCU/993/6/13 - Cod SMIS: 153299**

**Seria I 4: Inginerie industrială Nr. 89
GALAȚI
2023**



Parteneri:





UNIUNEA EUROPEANĂ



„Program pentru creșterea performanței și inovării în cercetarea doctorală și postdoctorală de excelență - PROINVENT”

IOSUD – UNIVERSITATEA „DUNĂREA DE JOS” DIN GALAȚI

Școala Doctorală de Inginerie Mecanică și Industrială



TEZĂ DE DOCTORAT

REZUMAT

INSTRUMENTE MODERNE DE DEPISTARE A MELANOMULUI CUTANAT –

Aplicație SelfChecker pentru analiza nevilor și melanoamelor prin intermediul imaginilor digitale

Doctorand,

Ing. Felicia - Anișoara MICHIȘ (DAMIAN)

Președinte,

Conducător științific,

Referenți științifici

Prof. univ. dr. ing. Cătălin FETECĂU

Universitatea „Dunărea de Jos” din Galați

Prof. univ. dr. ing. fiz. Luminița MORARU

Universitatea „Dunărea de Jos” din Galați

Prof. univ. dr. ing. Neculai Eugen SEGHE DIN

Universitatea Tehnică „Gheorghe Asachi” din Iași

Prof. univ. dr. ing. Cristian Doicin

Universitatea Politehnică din București

Prof. univ. dr. ing. Cătălina ITICESCU

Universitatea „Dunărea de Jos” din Galați

Seria I 4: Inginerie industrială Nr. 89

GALAȚI

2023



Parteneri:



Seriile tezelor de doctorat susținute public în UDJG începând cu 1 octombrie 2013 sunt:

Domeniul fundamental ȘTIINȚE INGINEREȘTI

- Seria I 1: **Biotehnologii**
- Seria I 2: **Calculatoare și tehnologia informației**
- Seria I 3: **Inginerie electrică**
- Seria I 4: **Inginerie industrială**
- Seria I 5: **Ingineria materialelor**
- Seria I 6: **Inginerie mecanică**
- Seria I 7: **Ingineria produselor alimentare**
- Seria I 8: **Ingineria sistemelor**
- Seria I 9: **Inginerie și management în agricultură și dezvoltare rurală**

Domeniul fundamental ȘTIINȚE SOCIALE

- Seria E 1: **Economie**
- Seria E 2: **Management**
- Seria E 3: **Marketing**
- Seria SSEF: **Știința sportului și educației fizice**
- Seria SJ: **Drept**

Domeniul fundamental ȘTIINȚE UMANISTE

- Seria U 1: **Filologie - Engleză**
- Seria U 2: **Filologie - Română**
- Seria U 3: **Istorie**
- Seria U 4: **Filologie – Franceză**

Domeniul fundamental MATEMATICĂ ȘI ȘTIINȚE ALE NATURII

- Seria C : **Chimie**

Domeniul fundamental ȘTIINȚE BIOMEDICALE

- Seria M : **Medicină**
- Seria F : **Farmacie**

CUVÂNT ÎNAINTE

O dată cu finalizarea acestei etape din viața mea, doresc să doresc să le mulțumesc celor care m-au ghidat și mi-au acordat suportul în realizarea prezentei lucrări.

Pentru realizarea tezei de doctorat a fost necesar parcurgerea programului de doctorat prin asigurarea unui parcurs științific coerent ce presupune realizarea și susținerea rapoartelor de cercetare, aprofundarea studiului și diseminarea rezultatelor prin publicarea de lucrări științifice.

Progresul realizat are la bază efortul colectiv nu o realizare individuală. Astfel că îmi exprim recunoștința față de doamna prof. dr. ing. fiz. Luminița Moraru, coordonatorul științific al tezei mele de doctorat, care a reușit să formeze în jurul său o echipă academică cu o viziune plină de profesionalism și umanism pentru formarea viitorilor cercetători și cadre didactice.

Îmi exprim recunoștința față de doamna prof. dr. ing. fiz. Luminița Moraru căreia îi mulțumesc pentru încrederea acordată, pentru sfaturile de îndrumare și încurajare și pentru rigurozitatea manifestată de-a lungul perioadei de parcurgere a programului de doctorat.

În egală măsură, doresc să îi mulțumesc doamnei conf. dr. Simona Moldovanu, pentru răbdarea, profesionalismul și pentru sprijinul personal care au contribuit la definitivarea acestei teze.

Sunt onorată de faptul că am cunoscut un colectiv de cadre didactice de excepție, în cadrul Facultății de Științe și Mediu, care m-au primit cu multă căldură și înțelegere. Le mulțumesc doamnelor prof. univ. dr. Camelia Frigioiu și conf. dr. Mihaela Carmen Baroni(postmortem), pentru că m-au integrat în preocupările didactice din cadrul departamentului de matematică-informatică și le mulțumesc pentru sprijinul acordat pe toată durata prezentei cercetări.

Doresc să-i mulțumesc kolegei mele ing. Lenuța Pană care m-a susținut pe parcursul anilor de studii doctorale.

Îmi exprim recunoștința familiei mele, fără sprijinul căreia, nu aș fi reușit să finalizez această teză și nu aș fi găsit forța necesară să depășesc toate obstacolele întâmpinate pe parcursul anilor de studii doctorale.

Galați, 2023

Ing. Felicia-Anișoara MICHIȘ (DAMIAN)

Prezentul rezumat conține o sinteză a celor mai elocvente rezultate experimentale obținute în urma cercetărilor teoretice și practice.

Indicatorii capitolelor, subcapitolelor, figurile, tabelele și referințele bibliografice sunt identici cu cei ai tezei de doctorat.

CUPRINS	Pag. teză	Pag. rezumat
Cuvânt înainte	III	III
Cuprins	V	V
Content	IX	
Rezumat	XIII	
Abstract	XV	
Listă figuri	XVII	
Listă Tabele	XIX	
Abrevieri	XXI	
Introducere	XXIII	VIII
1. Motivația alegerii temei de cercetare	XXIV	VIII
2. Importanța cercetării	XXIV	IX
3. Obiectivele tezei	XXV	IX
4. Diseminarea rezultatelor cercetării	XXV	X
5. Structura lucrării științifice	XXV	
Introducere (în limba engleză)	XXVII	
Capitolul 1		
Stadiul actual al cercetării privind metodele de caracterizare microstructurală și morfologică a imaginilor dermatoscopice digitale	1	1
1.1 Analiza statisticilor privind evoluția melanoamelor	1	
1.2 Seturi de date	2	
1.3 Achiziția imaginilor	3	
1.4 Caracteristicile imaginilor dermatoscopice	4	
1.4.1 Metode de examinare a leziunilor cutanate	4	
1.4.2 Caracteristicile imaginilor	6	
1.5 Preprocesarea imaginilor	8	
1.6 Segmentarea imaginilor	10	
1.7 Clasificarea leziunilor cutanate	11	
1.7.1 Instrumente de inteligență artificială	11	
1.7.2 Aplicații pentru telefoanele mobile	12	
1.8 Concluzii parțiale	15	
Capitolul 2		
Metode și modele matematice utilizate în analiza imaginilor dermatoscopice digitale	17	2
2.1 Metode de procesare a imaginilor dermatoscopice digitale	17	2
2.1.1 Caracteristici geometrice	17	
2.1.2 Caracteristici de culoare	19	
2.1.3 Alegerea unui spațiu de culoare	19	
2.1.4 Cuantizarea componentelor de culoare evaluând histograma relativă a culorii pentru a defini culorile leziunii	22	
2.1.5 Descrierea culorilor prin extragerea parametrilor din diferite canale de culoare	22	
2.1.6 Descrierea culorilor cuantizate prin extragerea parametrilor statistici din diferite canale de culoare prin metode statistice	23	
2.1.7 Analiza imaginilor în domeniul de frecvență	23	
2.1.8 Momentele Hu	24	

2.1.9 Undele Haar	25	
2.1.10 Transformata Wavelet Discretă (DWT)	26	
2.1.11 Funcția sensibilă la contrast (CSF)	26	
2.1.12 Funcția de vizibilitate a zgomotului (NVF)	27	
2.1.13 Caracteristici de ordinul I	28	
2.2 Metode de segmentare	28	2
2.2.1 Segmentarea bazată pe operatori morfologici	28	2
2.2.2 Segmentarea bazată pe histogramă	29	2
2.2.3 Metoda Otsu	30	
2.3 Algoritmi de clusterizare	31	3
2.3.1 Metoda K-means	32	3
2.3.2 Metoda Fuzzy C-means	33	3
2.4 Metode de validare a modelele propuse	34	3
2.4.1 Curba ROC (Receiver Operating Characteristics)	34	3
2.4.2 Metoda validării încrucișate (CV)	35	3
2.4.3 Indexul de dispersie (ID)	35	3
2.5 Instrumente pentru clasificarea leziunilor cutanate	35	4
2.5.1 Rețelele neuronale artificiale (ANN)	35	4
2.5.2 Clasificatorul de tip rețea neuronală cu funcție de bază radială (RBFNN)	36	4
2.5.3 Clasificatorul kNN cu validare încrucișată	37	5
2.5.4 Algoritm de clasificare Random Forest (RF)	38	5
2.6 Concluzii parțiale	38	
Capitolul 3		
Contribuții personale privind extragerea și selectarea caracteristicilor relevante specifice leziunilor cutanate	39	7
3.1 Analizarea leziunilor cutanate cu caracteristici semnificative	40	7
3.2 Studiul asimetriei leziunilor cutanate utilizând rețelele neuronale artificiale	44	9
3.3 Compararea măsurilor metrice de distanță pentru diferențierea leziunilor cutanate	49	12
3.4 Selectarea caracteristicilor relevante din imaginile non-dermatoscopice în vederea clasificării nevilor vs. melanoame	52	14
3.5 Influența spațiului de culoare asupra clasificării leziunilor cutanate folosind caracteristici statistice	56	
3.6 Algoritm de watermarking invizibil aplicat imaginilor dermatoscopice descompuse cu transformata wavelet discretă	60	
3.7 Concluzii parțiale	63	
Capitolul 4		
Contribuții personale privind clasificarea leziunilor cutanate bazate pe clustere de culoare	65	18
4.1 Analiza leziunilor cutane cu algoritm de selectare a caracteristicilor geometrice	65	
4.2 Analiza histogramei de culoare pentru diferențierea leziunilor cutanate	68	18
4.3 Clasificare clusterilor de culoare cu algoritmul kNN	71	
4.4 Clasificarea leziunilor cutanate pe baza dimensiunilor fractale de suprafață și a caracteristicilor statistice ale grupului de culori folosind un ansamblu de tehnici de învățare automată	74	20
4.5 Clasificarea leziunilor cutanate utilizând algoritmul Random Forest (RF)	81	26

4.6 Concluzii parțiale	84	
Capitolul 5		
Contribuții personale privind implementarea sistemului expert		
„Skin Lesions”	85	30
5.1 Cerințe pentru dezvoltarea unei aplicații	85	30
5.2 Tehnica propusă	89	31
5.3 Descrierea aplicației	90	31
5.4 Contribuții originale	94	35
5.5 Concluzii parțiale	98	
Capitolul 6		
Concluzii generale și direcții viitoare de cercetare	99	38
Lista lucrărilor publicate	101	40
Bibliografie	107	45
Anexe	127	

Introducere

Cercetările clinice și cele statistice au confirmat că melanomul este cea mai periculoasă formă de manifestare a cancerului de piele care evoluează rapid provocând, la nivel mondial, în rândul populației, o mortalitate ridicată. Ca urmare a incidenței crescute a melanomului, se impune dezvoltarea unor abordări noi care să diferențieze precis și corect leziunile cutanate.

Tema propusă prin această teză de doctorat este una de un real interes deoarece aplicațiile SelfChecker pentru analiza leziunilor cutanate oferă o abordare tehnologică modernă pentru a ajuta oamenii cu leziuni cutanate suspecte să decidă dacă trebuie să caute asistență medicală suplimentară.

Prezenta teză de doctorat vizează dezvoltarea unui sistem expert „**Skin Lesions**” pentru analiza leziunilor cutanate prin intermediul imaginilor digitate. În vederea atingerii scopului tezei de doctorat, au fost parcurse următoarele etape:

- analiza literaturii de specialitate privind utilizarea metodelor de procesare și interpretare automată a informației din imaginile dermatoscopice digitale;
- achiziția imaginilor leziunilor cutanate realizată cu un dispozitiv mobil capabil să genereze la ieșirea acestuia o imagine digitală;
- selecția și descrierea caracteristicilor folosite pentru investigarea informației utile conținută în imagini;
- preprocesarea imaginilor digitale bazată pe algoritmi de îmbunătățire, îndepărtarea artefactelor și extragerea zonelor de interes bazată pe algoritmi de filtrare liniari, neliniari, wavelets sau transformări Fourier;
- segmentarea imaginilor;
- operațiile de descriere, recunoaștere, selecție și clasificare ale caracteristicilor obiectelor extrase în procesul de segmentare;
- analiza datelor experimentale și interpretarea operațiilor enumerate realizate cu diferite metrici de calitate sau cu metode statistice avansate;
- implementarea de metode inovative de diagnoză bazate pe clustere de culoare;
- securizarea imaginilor digitale;
- implementarea sistemului expert „**Skin Lesions**” ca aplicație de îngrijire a sănătății pentru telefon mobil ce identifică dacă o leziune cutanată poate fi un motiv de îngrijorare și afișează o alertă.

În cadrul acestei lucrări, am analizat literatura de specialitate privind procesarea și evaluarea imaginilor dermatoscopice digitale și am dezvoltat metode originale de procesare care au fost utilizate la crearea sistemului expert „**Skin Lesions**”.

1. Motivația alegerii temei de cercetare

Având în vedere că dispozitivele mobile sunt folosite de miliarde de oameni din toată lumea și sunt echipate cu senzori de imagine de înaltă rezoluție și procesoare puternice este posibilă proiectarea de noi sisteme expert. Funcțiile dispozitivelor mobile combinate cu algoritmi avansați de procesare a imaginilor digitale, pot oferi soluții de monitorizare a sănătății și de urmărire a evoluției anumitor parametri.

Sistemul expert „**Skin Lesions**” realizat utilizează algoritmi proprii, care pot fi utilizați și în scopuri educaționale, ca o oportunitate e-Learning pentru studenți. Consider că rezultatele științifice obținute constituie puncte de reper, pentru viitoarele cercetări din domeniul medical și domeniul industrial. La sfârșitul celor 5 ani de studiu am implementat un sistem expert de evaluare obiectivă a caracteristicilor leziunilor cutanate.

2. Importanța cercetării

Plecând de la tema tezei de doctorat am propus o serie de algoritmi originali a căror eficiență în diferențierea leziunilor cutanate a fost validată experimental. Pentru aceasta, pe parcursul realizării tezei științifice, am urmat pas cu pas întregul proces privind procesarea imaginilor dermatoscopice digitale. Am avut în vedere și faptul că funcțiile unui telefon mobil combinate cu algoritmi avansați de procesare a imaginilor digitale, oferă soluții de monitorizare a și de urmărire a evoluției anumitor parametri a leziunilor cutanate. Astfel au fost dezvoltați și implementați în sistemul expert propus algoritmi eficienți pentru:

- analiza melanoamelor și nevilor cu ajutorul caracteristicilor geometrice și a caracteristicilor de ordinul I;
- influența spațiului de culoare asupra clasificării leziunilor cutanate folosind caracteristicile acestora care pot furniza informații utile despre structura acestora;
- selectarea caracteristicilor relevante din imaginile în vederea clasificărilor nevilor vs. melanoame;
- analiza histogramei în vederea investigării și clasificării leziunilor cutanate;
- clasificarea leziunilor cutanate cu ajutorul algoritmului k-NN și pe baza dimensiunilor fractale 2D;
- determinarea conturilor leziunilor;
- realizarea și implementarea sistemului expert „**Skin Lesions**”.

Pentru prelucrarea imaginilor digitale și pentru obținerea rezultatelor experimentale am utilizat mediul Matlab 2017a cu librăriile: Graphical User Interface, Image Processing Toolbox, Wavelets, nntool. Pentru analiza parametrii caracteristici am utilizat pachetul software statistic MedCalc conceput pentru aplicații statistice în medicina de laborator. Pentru realizarea sistemului expert „**Skin Lesions**” am ales platforma Android deoarece este un sistem de operare foarte popular. Prin publicarea de articole și prin prezentări în cadrul conferințelor științifice de specialitate a rezultatelor obținute în perioada cercetării doctorale, am validat datele experimentale obținute.

3. Obiectivele tezei

Scopul cercetării este dezvoltarea unei aplicații SelfChecker orientată spre pacient pentru analiza leziunilor cutanate din imaginile digitale utilizând dispozitive mobile.

Obiectivul general al tezei este realizarea unui sistem expert „**Skin Lesions**” de analiză automată a imaginilor achiziționate cu un dispozitiv mobil care să afișeze o alertă dacă o leziune cutanată poate fi un motiv de îngrijorare.

În conformitate cu obiectivul general al tezei de doctorat „INSTRUMENTE MODERNE DE DEPISTARE A MELANOMULUI CUTANAT - Aplicație SelfChecker pentru analiza nevilor și melanoamelor prin intermediul imaginilor digitale” și a referatelor științifice susținute în perioada stagiului de pregătire, au fost propuse și atinse următoarele obiective specifice:

- îmbunătățirea tehnicilor de detectare și clasificare a melanomului;
- utilizarea dispozitivelor mobile în sistemele medicale și dezvoltarea diagnosticului asistat de computer (CAD);
- îmbunătățirea metodelor de procesare a imaginii pentru extragerea caracteristicilor melanomului.

4. Diseminarea rezultatelor cercetării

Rezultatele obținute în urma cercetărilor din cadrul stagiului doctoral s-au materializat în 13 de lucrări științifice (indexate în bazele de date ISI Web of Knowledge (Clarivate) și Scopus, IEEE Xplore și BDI/B+ indexate în baza de date EBSCO). Dintre acestea 2 lucrări au fost publicate în reviste cotate ISI, 3 lucrări au fost publicate în volume ISI Proceedings, 3 lucrări au fost publicate în volume ale conferințelor internaționale și 3 lucrări au fost publicate în reviste cotate BDI.

Gradul de noutate a prezentei tezei de doctorat constă în modul de abordare evolutiv, procesual, ce are la bază cele mai noi informații, fundamente teoretice, principii și metode ce susțin procesul de analiză a leziunilor cutanate. Metodele propusă în capitolele 3, 4 și 5 pot fi apreciate ca metode noi de diferențiere a leziunilor cutanate, ca de altfel și sistemul expert materializat prin aplicația „Skin Lesions”. Problematika tezei a fost structurată astfel încât noutatea științifică obținută în urma procesului de cercetare și valoarea practică a lucrării se evidențiază în mai multe elemente prezentate în capitolul final.

Capitolul 1

Stadiul actual al cercetării privind metodele de caracterizare microstructurală și morfologică a imaginilor dermatoscopice digitale

Scopul acestui capitol: analiza literaturii științifice privind metodele de caracterizare microstructurală și morfologică a imaginilor dermatoscopice digitale.

Aportul adus, plecând de la studierea algoritmilor raportați în diferite lucrări științifice de specialitate, s-a concretizat prin realizarea de algoritmi proprii care pot diferenția rapid și eficient leziunile cutanate ce au fost implementați în sistemul expert „**Skin Lesions**”.

Sinteza acestui capitol este alcătuit din prezentarea teoretică a următoarelor:

- Analiza statisticilor privind evoluția melanoamelor ce arată că melanomul este unul dintre cele mai periculoase tipuri de cancer de piele în ceea ce privește rata de deces. Probabilitatea decesului crește atunci când leziunea cutanată este diagnosticată cu întârziere.

Pentru dezvoltarea sistemului expert propus un pas important este recunoașterea leziunilor cutanate având la dispoziție seturi de date dedicate disponibile online și gratuite, cum ar fi: MedNode, arhiva ISIC, Ph2, 7-POINT. Sunt și seturi de date plătite ca Dermofit, atlasul interactiv de dermatoscopie.

În literatura științifică sunt adoptate metode de examinare care includ tehnici fiabile și standardizate ce permit îmbunătățirea ratei de detecție timpurie a melanomului. Aceste metode susțin procesul de autoexaminare a leziunilor cutanate: analiza structurală [36], metoda ABCDE [37], lista de verificare cu 7 puncte [38], sau metodele Menzies [39], CASH [40], Chaos and Clues [41] și BLINCK [42].

- Pentru implementarea sistemului expert propus am ales metoda ABCD deoarece aceasta este compatibilă cu implementarea informatică a aplicației SelfChecker în mediul de programare Matlab. În acest sens, sunt evaluate caracteristicile leziunilor cutanate care ne ajută să dezvoltăm sisteme de sprijin capabile să semnaleze gravitatea situației și să ne determine să consultăm un medic specialist.

- Acronimul ABCD se referă la patru parametri: asimetrie, neregularitatea conturului (granița), variația culorii și diametru leziunii cutanate mai mare de 6 mm. Acești parametri oferă mijloace simple pentru evaluarea leziunilor cutanate.

- Cercetările analizate în domeniul procesării imaginilor arată că domeniul are nevoie în continuare de idei novatoare, atât în ceea ce privește soluțiile software de prelucrate ale imaginilor dar și cele hardware care să achiziționeze imagini dermatoscopice digitale fără defecte, artefacte sau zgomot.

- Aplicațiile pentru telefoane mobile pentru diagnosticarea precoce a melanoamelor au o structură grafică prietenoasă și sunt ușor de utilizat pentru a veni în sprijinul persoanele cu leziuni cutanate în decizia de a solicita sau nu asistență medicală suplimentară: aplicația **DermLite** [116], aplicația **Skin Cancer App - MySkinPal - Map your skin moles** [118], aplicația **MoleScope** [119], aplicația **ApreSkin you** [120], aplicația **Derma Analytics**, aplicația **Miiskin** [122], aplicația „**APD Skin Monitoring**” [123], aplicația **SkinVision** [124], aplicația „**SkinMD**” [127], aplicația „**eSkin**” [112], etc.

- Metoda de prag a imaginii Otsu [85] se bazează pe maximizarea varianței imaginii fiind o metodă frecvent utilizată pentru segmentarea leziunilor cutanate. În toate tehnicile de prag fix, este selectată o valoare cutoff pe baza căreia imaginea este convertită de la scara gri la binară.

- Clasificarea leziunilor cutanate la implementarea sistemului expert „Skin Lesions” se face utilizând scorul total al dermoscopiei – TDS.

Capitolul 2

Metode și modele matematice utilizate în analiza imaginilor dermatoscopice digitale

Analiza imaginilor se poate realiza cu metode și modele matematice care au rolul de a simplifica imaginea, pornind de la structuri complexe, în elemente simple. Metodele și modelele matematice corelează obiectele de interes din imagini cu forme geometrice regulate sau neregulate.

Sinteza acestui capitol este acătuită din prezentarea teoretică a principiilor și descrierile matematice ale anumitor metode și modele de procesare a imaginilor dermatoscopice digitale, descrieri ale metodelor de segmentare bazate pe contururi, histogramă și regiuni, metode de clusterizare dar și metode de validare a datelor.

2.1 Metode de procesare a imaginilor dermatoscopice digitale

Caracteristicile utilizate cu succes în evidențierea informației din imaginile medicale sunt:

- caracteristici geometrice precum asimetria, compacitatea, circularitatea, excentricitatea;
- caracteristici de culoare;
- caracteristici de ordinul întâi precum skewness, kurtosis.

2.2 Metode de segmentare

Având în vedere că un pas important în analiza imaginilor este evidențierea anumitor obiecte sau regiuni de interes (ROI) din imagine se utilizează metode de segmentare a zonelor de interes prin determinarea frontierelor obiectelor analizate. Astfel se poate utiliza:

2.2.1 Segmentarea bazată pe operatori morfologici

Principiul operatorilor morfologici folosiți pentru extragerea conturilor se bazează pe măsurarea diferențelor dintre valorile extreme (minim și maxim) ale vecinătății punctului curent; dacă diferența dintre aceste valori este suficient de mare înseamnă că punctul curent este un punct de contur, aflându-se într-o zona de tranziție a valorilor pixelilor.

2.2.2 Segmentarea bazată pe histogramă

Parcursarea histogramei pixel cu pixel impune un control al nivelurilor de gri astfel încât funcția histogramă, ce este o funcție de probabilitate, va îndeplini condiția [162]:

$$\sum_{i=0}^{L-1} h(i) = 1 \quad (2.62)$$

unde L este numărul de niveluri de gri ale unei imagini.

Histograma de culoare este o metodă de descriere a conținutului de culoare al unei imagini și cuantifică numărul de apariții al fiecărei culori dintr-o imagine [163]. Pentru o imagine RGB dată, fie L nivelurile de intensitate din intervalul $[0, 1, 2, \dots, L-1]$. Distribuția probabilității poate fi definită ca:

$$p_i^C = \frac{h_i^C}{N}, \sum_{i=0}^{L-1} p_i^C = 1 \quad (2.63)$$

unde i este un nivel specific de intensitate în intervalul $\{0 \leq i \leq L-1\}$ pentru componenta de culoare $C = \{R, G, B\}$, N este numărul total de pixeli din imagine și h_i^C este numărul de pixeli pentru nivelul de intensitate i din componenta C [164].

2.3 Algoritmi de clusterizare

Clusterizarea imaginilor folosește algoritmi de clasificare care grupează pixelii similari din imagine în clustere [167]. Împărțirea pixelilor în clustere se bazează pe principiul minimizării similitudinii intra-cluster și maximizării diferențelor dintre clase [168].

2.3.1 Metoda K-means

Metoda K-means [172] presupune gruparea obiectelor dintr-un set de date în mai multe clustere, fiecare cluster conținând un set de obiecte dintr-o anumită categorie.

2.3.2 Metoda Fuzzy C-means

Metoda Fuzzy C-means [173] este o tehnică de clusterizare care permite unui element din setul de date să aparțină, cu un anumit grad de apartenență, uneia sau mai multor grupe. În analiza non-fuzzy, sau hard clustering, informația este divizată în clustere unde fiecare entitate aparține unui singur cluster [174]. Asocierea unui obiect cu un cluster se face cu ajutorul gradelor de apartenență:

2.4 Metode de validare a modelele propuse

Validarea metodei propuse este o etapă obligatorie în analiza imaginilor. Acesta constă în verificarea acurateții metodei și se poate realiza folosind diferite metode:

2.4.1 Curba ROC (Receiver Operating Characteristics)

Curba ROC [175] este o curbă bidimensională care reprezintă graficul sensibilității (pe axa Ox) vs. rata fals pozitivilor (axa Oy), respectiv specificitatea, unde:

$$\text{Sensibilitatea} = TP/(TP+FN),$$

$$\text{Specificitatea} = TN/(TN+FP),$$

TP – Predicție pozitivă, răspuns pozitiv, TN – Predicție negativă, răspuns negativ, FP – Predicție pozitivă, răspuns negativ, FN – predicție negativă, răspuns pozitiv. Curba ROC este un test util care verifică cu ajutorul ariei de sub curbă (AUC) cât de eficientă este o caracteristică (cu cât aria de sub curbă este mai mare cu atât testul are o acuratețe mai mare, o arie de 1 reprezintă o caracteristică perfectă iar dacă $AUC < 0.6$ caracteristica devine irelevantă) [176].

O altă interpretare statistică a curbei ROC care permite determinarea punctului maxim de cut-off este Indicele Youden (J) care este definit ca [177]:

$$J = \text{maxim} (\text{Sensibilitate} + \text{Specificitate} - 1).$$

Valorile J inferioare indică faptul că, caracteristica analizată nu are nicio relevanță pentru studiul propus [178].

2.4.2 Metoda validării încrucișate (CV).

Algoritmul de evaluarea a datelor prin metoda validării încrucișate presupune existența a n seturi de date structurate astfel, $n - 1$ seturi sunt folosite pentru antrenare și al n -lea set pentru testare. Algoritmul se repetă de k ori, (de obicei, $k = 10$). La fiecare pas, se evaluează efectul adăugării sau eliminării unui element relevant pentru clasificare. Când această operație nu mai produce nici o îmbunătățire a rezultatelor atunci algoritmul se oprește [179].

2.4.3 Indexul de dispersie (ID)

Această metodă cuantifică dacă un set de date este grupat sau dispersat în comparație cu un model statistic standard:

Dacă $ID = 0$ pentru datele respective nu există dispersie, dacă $ID \in (0,1)$ datele sunt sub-dispersate iar dacă $ID > 1$ datele sunt dispersate.

Indexul de dispersie se calculează după formula [180]:

$$ID = \frac{\sigma^2}{\mu} \quad (2.89)$$

2.5 Instrumente pentru clasificarea leziunilor cutanate

Sistemele de clasificare CAD necesită algoritmi dedicați de procesare a imaginii pentru a oferi descrieri matematice ale leziunilor cutanate suspecte.

2.5.1 Rețelele neuronale artificiale (ANN)

Rețelele neuronale artificiale constau dintr-un set de noduri legate care colaborează pentru a rezolva probleme. ANN constau dintr-un nivel de intrare, un nivel de ieșire și un nivel ascuns. Nodurile de intrare preiau informații sub formă numerică. Informațiile sunt prezentate ca valori de activare, unde fiecărui nod i se atribuie un număr, astfel încât, cu cât este mai mare numărul, cu atât este mai mare activarea. În cazul unei rețele de tip feed-forward, informațiile sunt transmise înainte în întreaga rețea [182]. Valoarea de activare este transmisă de la nod la nod, dar ponderată într-un anumit mod. Valorile de activare sunt revizuite la fiecare nod. Activarea circulă prin rețea, prin niveluri ascunse, până ajunge la nodurile de ieșire. Diferența dintre valoarea prezisă și valoarea reală (eroare) va fi propagată înapoi în întreaga rețea. Funcția de transfer convertește semnalele de intrare în semnale de ieșire, se folosește funcția de transfer sigmoid [183]. Fiecare rețea de formare este o pereche de formă $\{\bar{X}, \bar{Y}\}$, unde X este un vector care cuprinde valorile datelor de intrare și Y este un vector al valorilor țintă (valorile dorite).

Pentru a evalua performanța metodei propuse, sunt calculate din matricea de confuzie următoarele metrici [184].

$$\text{Sensitivitatea}(SE) = \frac{TP}{TP + FN} \quad (2.90)$$

$$\text{Specificitate}(SP) = \frac{TN}{TN + FP} \quad (2.91)$$

$$\text{Acuratețea}(ACC) = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.92)$$

$$\text{Precizia}(P) = \frac{TP}{TP + FP} \quad (2.93)$$

$$\text{Coeficient Dice}(D) = \frac{2TP}{2TP + FP + FN} \quad (2.94)$$

$$\text{Indicele Jaccard}(JAC) = \frac{TP}{TP + FN + FP} \quad (2.95)$$

unde TP este adevărat pozitiv, FP fals pozitiv, TN negativ adevărat și FN fals negativ.

Cea mai simplă și totuși cea mai frecvent utilizată funcție de eroare, al cărei scop este de a estima performanța rețelelor neuronale este eroarea pătrată medie (MSE) [185].

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.96)$$

unde n este numărul de variabile, Y este vectorul variabilelor

2.5.2 Clasificatorul de tip rețea neuronală cu funcție de bază radială (RBFNN)

Rețeaua neuronală RBF este o arhitectură de rețea neuronală de tip feed forward cu trei straturi. Fiecare nod ascuns pune în acțiune o funcție de activare neliniară, care este o funcție

radial simetrică. Funcția de bază radială este centrată pe un vector din spațiul de caracteristici și răspunsul său variază monoton cu distanța de la punctul central. RBFNN poate fi formulat ca minimizarea funcției MSE. Un punct critic pentru implementarea unei rețele RBF constă în stabilirea centrelor RBF și determinarea ponderilor. Odată ce centrele RBF și neliniaritățile din stratul ascuns sunt determinate, ponderile sunt calculate pe baza regresiei liniare a ieșirilor stratului ascuns la ieșirile dorite sau valorile țintă. Clasificatorul RBFNN este antrenat și validat folosind validarea încrucișată pentru a consolida capacitățile modelului predictiv [188]. Această abordare separă seturile de date în grupuri de instruire și testare și evită supraadaptarea netă.

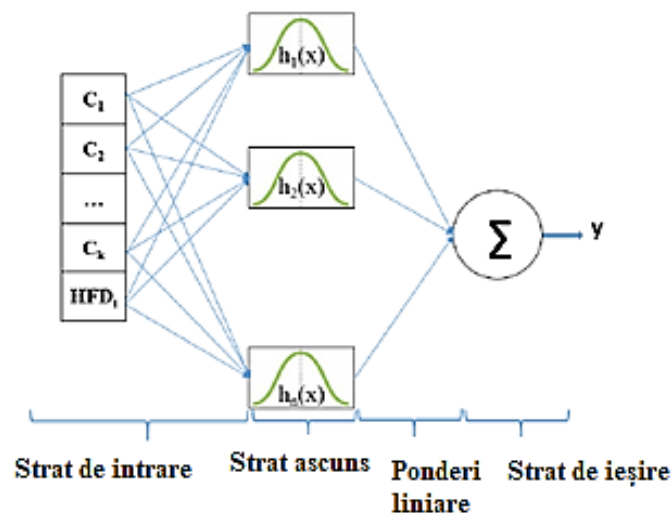


Figura 2.4 Structura unui clasificator RBFNN [187]

2.5.3 Clasificatorul kNN cu validare încrucișată

kNN este un algoritm de învățare automată care presupune că eșantioanele fiecărui grup sunt predominant înconjurate de eșantioane din același grup [189]. Etapa de antrenament păstrează caracteristicile și eticheta de clasă a mostrelor de antrenament. Apoi, kNN clasifică noi instanțe pe baza unei operații de similaritate. Distanța euclidiană este cea mai frecvent utilizată măsură de similitudine. Când este disponibil doar un set de date mic, tehnica de validare încrucișată este o soluție alternativă la tehnica de augmentare. În plus, costul de eșantionare este scăzut. kNN-CV cu un algoritm de validare încrucișată de 5 ori utilizează un subset de date pentru validare, dar încă folosește toate datele pentru faza de testare. Datele de intrare sunt împărțite în cinci subseturi. Algoritmul este antrenat pe patru subseturi și testat pe un singur subset de date. Apoi, acest proces este repetat iterativ până când fiecare subset de date devine un subset de testare și toate datele sunt evaluate. Complexitatea timpului de antrenament este $O(d \times n \times \log n)$, unde numărul de eșantioane din setul de date de antrenament este notat generic cu n și dimensionalitatea datelor cu d . Complexitatea este medie. Pentru validarea încrucișată de 5 ori kNN, repetăm calculele și creștem complexitatea timpului. Acest timp de calcul relativ mai mare ar putea fi interpretat ca o limitare a algoritmului kNN-CV. Totuși, acest dezavantaj este compensat de reducerea influenței supraadaptării. Mai mult, estimare corectă a erorii de test este principalul său avantaj. De asemenea, oferă un nivel bun de precizie pentru model [189].

2.5.4 Algoritmul de clasificare Random Forest (RF)

RF este un algoritm ce creează arbori de decizie pe seturi de date și apoi se obține predicția pentru fiecare dintre ele și în final selectează cea mai bună soluție [190].

Breiman [191] a descris matematic RF ca fiind un clasificator bazat pe o familie de clasificatori $h(x | \Theta_1), \dots, h(x | \Theta_k)$ bazat pe un arbore de clasificare cu parametri Θ_k ales aleatoriu dintr-un vector aleator model Θ

Pentru clasamentul final $f(x)$ (care combină clasificatoarele $\{h_k(x)\}$), fiecare copac votează pentru cea mai populară clasă la intrare X , iar clasa cu cele mai multe voturi câștigă. Date specifice $D = \{(x_i, y_i)\}_{i=1}^n$: antrenăm a familie de clasificatori $h_k(x)$.

Fiecare clasificator $h_k(x) \equiv h(x | \Theta_k)$ este în cazul nostru un predictor n , $y = \pm 1$ = rezultatul asociat cu intrarea x .

Modelul Random Forest este utilizat în problemele de învățare automată cu scopul de a determina importanța caracteristicilor de intrare.

Capitolul 3

Contribuții personale privind extragerea și selectarea caracteristicilor relevante specifice leziunilor cutanate

Obiectivul acestui capitol s-a axat pe ideea de a evidenția acele caracteristici relevante extrase din imaginile leziunilor cutanate ce au capacitate crescută de a le diferenția și clasifica prin implementarea unor algoritmi specifici. Pentru îndeplinirea acestui deziderat s-au prezentat și discutat rezultatele furnizate de metode noi de procesare.

3.1 Analizarea leziunilor cutanate cu caracteristici semnificative

Astfel, am realizat un studiu unde am utilizat un set de caracteristici precum: asimetria, skewness, kurtosis, compacitatea, circularitatea, excentricitatea [193]. Abordările matematice ale metodelor și caracteristicilor sunt prezentate în capitolul 2. Studiul conține două etape importante:

- Segmentarea imaginilor cu o metoda clasică de binarizare;
- Extragerea caracteristicilor de ordinul I și cele geometrice.

În acest studiu, segmentarea imaginilor a fost realizată cu metoda de segmentare Otsu.

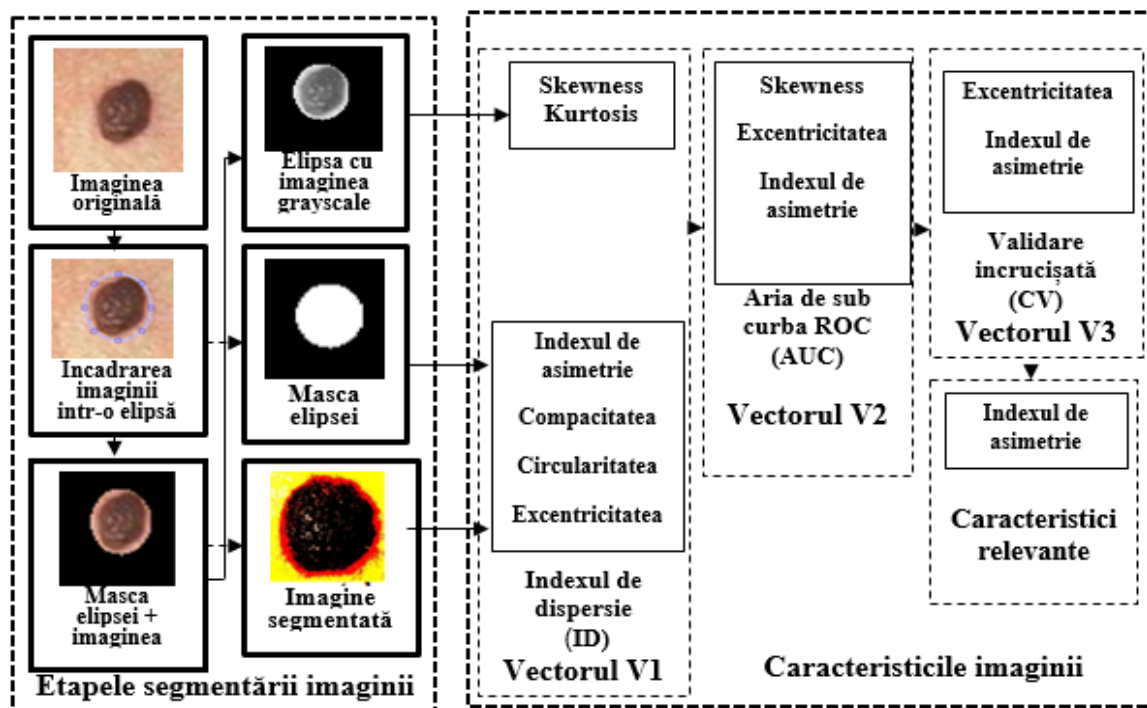


Figura 3.5 Algoritmul propus

Inițial, s-a format vectorul de caracteristici $V1 = \{AI, S, K, COMP, CIRC, E\}$ (tabelul 3.1). Pentru fiecare caracteristică s-a calculat ID. Pe baza valorilor obținute pentru ID și, în concordanță cu pragurile statistice stabilite de acesta, din vectorul V1 au fost eliminate acele caracteristici care au avut grad mare de dispersie ($ID > 1$) și se păstrează cele cu un grad mai mic de dispesie $ID < 1$. Astfel, s-a obținut un al 2-lea vector de charactersitici validat de ID și notat cu $V2 = \{AI, S, E\}$ (tabelul 3.2). Stabilitatea caracteristicilor care formează vectorul V2, s-a determinat folosind aria de sub curba (AUC). Rezultatul analizei permite construirea unui al treilea vector $V3 = \{IA, E\}$ format din caracteristicile pentru care care $AUC > 0.6$.

Tabelul 3.1 Valorile ID specifice caracteristicilor analizate


Imagine originală	AI	S	K	Comp	Circ	E
Nev	0.0109	0.178	5.461	24.947	15.559	0.079
Melanom	0.091	0.307	8.467	4.308	19.148	0.080

Tabelul 3.2 AUC și J calculate pentru caracteristicile din V₂

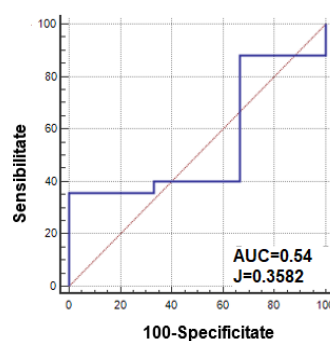
AUC/leziune cutanată	AI	S	E
AUC/nev	0.994	0.547	0.625
J/nev	0.969	0.3582	0.615
AUC/ melanom	0.949	0.532	0.761
J/ melanom	0.897	0.3831	0.666

Valorile AUC indică faptul că doar caracteristicile IA și E îndeplinesc condiția de stabilitate $AUC > 0.6$. Caracteristica S este exclusă. Pragurile care s-au asociat cu cei mai buni indici Youden sunt prezentate în tabelul 3.3 și figura 3.6. În studiul propus, J a fost folosit pentru interpretarea caracteristicile din V₂. Cum doar IA și E sunt stabile, am analizat indicii J corelați cu acestea.

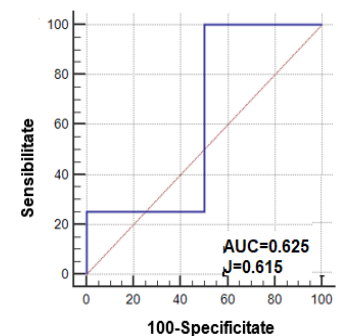
Din analiza datelor observăm $J = 0,969$ pentru AI și $J = 0,615$ pentru E (pentru nev), $J = 0,889$ pentru AI și $J = 0,666$ pentru E (pentru melanom). Cum ambele valori sunt mai apropiate de 1 decât de 0 recurgem la validarea acestora prin metoda metoda K-fold de validare încrucișată (CV).



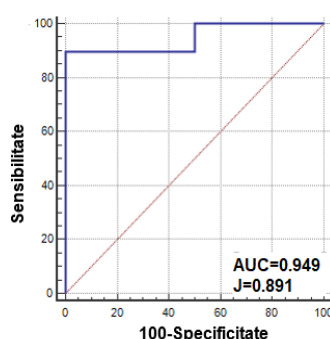
(a)




(b)




(c)



(d)



(e)



(f)

Figura 3.6 Curbele ROC. (a) AI nev; (b) S nev; (c) E nev; (d) AI melanom; (e) S melanom; (f) E melanom.

CV estimează procentul erorilor de clasificare al valorilor caracteristicilor din V3 după 10 repetări ale algoritmului, pe cele două seturi de date, de antrenare și de testare. Figura 3.7 prezintă evoluția CV-erorilor în funcție de numărul de repetiții. Constatăm că eroarea CV este cupinsă între 0.89 și 2.3 pentru caracteristica E și 0.68 și 3 pentru caracteristica IA.

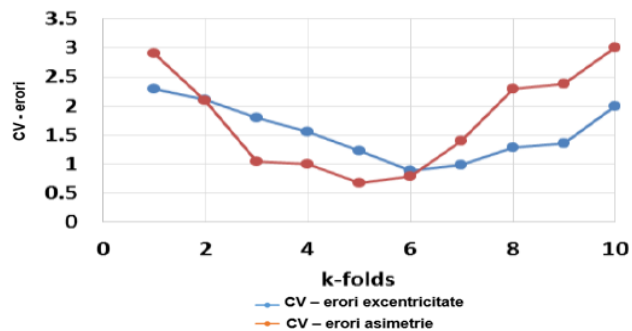


Figura 3.7 Evoluția eroare CV pentru E și AI.

În final, caracteristica AI este selectată ca fiind cea mai relevantă în diferențierea leziunilor cutanate, pentru aceasta înregistrându-se un minim de 0.68. Mai mult, caracteristica IA are $J = 0.89$ pentru nevi și $J = 0.96$ pentru melanom.

3.2 Studiul asimetriei leziunilor cutanate utilizând rețelele neuronale artificiale

Având în vedere că, asimetria este caracteristica cea mai relevantă în diferențierea nevilor de melanom am realizat un studiu cu scopul de a calcula asimetria folosind două metode determinarea asimetriei prin proiecția imaginii pe axele principale (GAF) și din proiecții ale histogrammei (AHP) ce au avut ca input imaginile dermoscopice din două baze de date: MED-NODE și PH2. Imaginile RGB au fost binarizate cu metoda Otsu (figura 3.8). Output-ul algoritmilor îl reprezintă valorile asimetriei prin cele două metode.

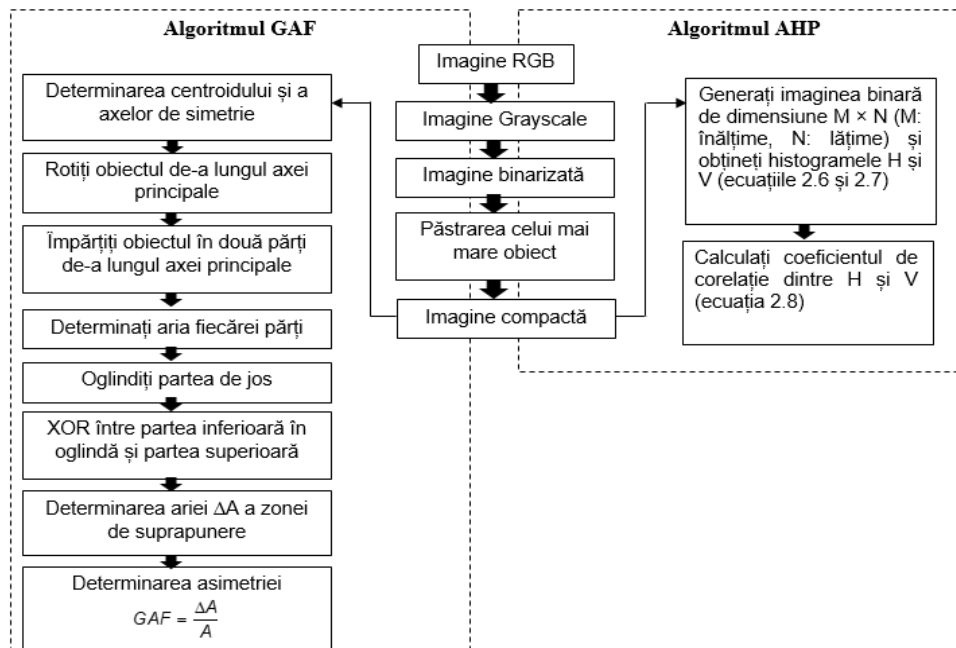


Figura 3.8 Algoritmi pentru calculul asimetriei.

Valorile obținute pentru caracteristica asimetrie, calculate folosind ambele metodele, au fost împărțite în 70% date instruire, 15%, date de testare și 15% date de validare. Tipul de rețea

selectat pentru instruire a fost propagarea înapoi *feed-forward backpropagation*. Algoritmul de propagare înapoi Levenberg-Marquardt (LMBP) este utilizat la instruirea rețelei. Funcția de antrenament actualizează valorile de comparare în conformitate cu optimizarea Levenberg-Marquardt. Funcția de învățare utilizată a fost Learngdm. După crearea rețelei, următorul pas este de a instrui rețeaua. S-a dezvoltat o ANN cu două straturi (figura 3.11): un strat ascuns și un strat de ieșire, pentru o transmitere bidirecțională și 10 neuroni în stratul ascuns care utilizează procedura de gradient conjugat scalat pentru antrenament. Această rețea neuronală este folosită pentru a clasifica leziunile cutanate. Termenul „*feed-forward backpropagation*” indică o activare înaintea fluxului de intrări și propagarea erorii înapoi a valorilor de comparare. Ca date de intrare, folosește asimetria GAF calculată pentru nevi și melanoame din baza de date MED-NODE. Ca date de ieșire folosește asimetria AHP calculată pentru nevi din MED-NODE.

ANN a fost creată în Matlab cu scopul de a efectua următoarele operații:

- Importarea datelor de intrare și ieșire în app-ul ANN din mediul Matlab;
- Crearea rețelei;
- Stabilirea procentelor din datele folosite la instruire, validare și testare.
- Calcularea valorilor statistice R și MSE.

Tabelul 3.3 Caracteristicile rețelei construite

Caracteristica	Denumire
Funcția de antrenament	LMB
Funcția de învățare	Learngdm
Eroarea medie pătrată, coeficientul de regresie	MSE, R
Numărul de straturi	1
Numărul de neuroni pe stratul ascuns	8,10,12,14

Tabelul 3.4 Date de intrare si date de ieșire

Variante antrenare	Antrenarea rețelei		
	Date de intrare /Tipul leziunii/baza de date/algorithm		Date de ieșire/Tipul leziunii/baza de date/algorithm
V1	Nev/MED-NODE/GAF	Melanom/ MED-NODE/GAF	Melanom/ MED-NODE/AHP
V2	Nev/MED-NODE/GAF	Melanom/ MED-NODE/GAF	Nev/ MED- NODE /AHP
V3	Nev/ PH2/GAF	Melanom/ PH2 /GAF	Melanom/ PH2 /AHP
V4	Nev/ PH2 /GAF	Melanom/ PH2 /GAF	Nev/ PH2 /AHP

După antrenare s-a recurs la validarea datelor cu diferitele arhitecturi ale rețele obținute modificând numărul de neuroni din stratul ascuns la valorile 8,10,12 și 14. În tabelul 3.5 se prezintă scorul de clasificare corectă (R și MSE) în funcție de numărul de neuroni de pe stratul ascuns. Antrenarea rețelei se oprește automat atunci când se obține o creștere a erorii medii pătratice (MSE) a probelor de validare. Eroarea medie pătratică (MSE) este diferența medie pătrată între ieșiri și rezultatele dorite. Valorile cele mai mici ale MSE sunt cele urmărite. Analiza de regresie R este efectuată pentru a măsura corelația dintre rezultate și rezultatele dorite. R apropiat de 1 indică o bună corelație. În Tabelul 3.5 se observă că opțiunile de antrenament V1 și V3 propuse sunt robuste pentru scopurile noastre. Modelul V1 are MSE mai mic, pentru 8 neuroni ascunși și este considerat modelul predictiv optim pentru baza de date MED-NODE. V3 modelul are un MSE mai mic pentru o structură cu 12 ascunse neuroni și este, de asemenea,

considerat un model predictiv optim pentru baza de date PH2. Modelele V2 și V4 sunt eliminate din analiza noastră.

Tabelul 3.5 Valorile MSE și R

Baza de date	Model	Număr de neuroni	MSE	R
MED-NODE	V1	8	0.003	0.89
		10	0.005	0.84
		12	0.004	0.86
		14	0.025	0.27
	V2	8	0.008	0.61
		10	0.006	0.79
		12	0.005	0.48
		14	0.004	0.36
PH2	V3	8	0.198	0.38
		10	0.022	0.62
		12	0.021	0.83
		14	0.037	0.69
	V4	8	0.030	0.52
		10	0.085	0.46
		12	0.069	0.34
		14	0.042	0.43

Performanța finală a ANN în funcție de datele de instruire, validare și testare este afișată în figura 3.12. Aceasta prezintă interpretarea erorii medii pătratice (MSE) în funcție de numărul de epoci, pentru cele două variante pentru care MSE este minim și anume V1 și V3. În general, MSE se reduce după mai multe epoci de antrenare, dar ar putea începe să crească pe setul de date de validare pe măsură ce rețeaua începe să potrivească date de validare cu cele de antrenare.



Figura 3.12 Cea mai bună performanță a modelului ANN în funcție de variația valorilor MSE conform numărului de epoci (iterații). (a) V1; (b) V3.

Cea mai bună performanță a fost obținută la epoca a 10-a pentru V1 și la epoca a 9-a pentru V3. Valorile MSE sunt 0,003 (RMSE = 0,055) pentru V1 și 0,021 pentru V3 (RMSE = 0,445).

În final modelul V1 este considerat modelul optim pentru care acuratețea metodei este determinată de cel mai mic MSE și cel mai mare R.

3.3 Compararea măsurilor metrice de distanță pentru diferențierea leziunilor cutanate

Având în vedere că asimetria și diametrul pot fi calculate cu o precizie bună [181] am realizat un studiu privind eficacitatea implementării unor noi măsuri metrice de distanță (distanța euclidiană, distanța cvasi-euclidiană, distanța city-block și distanța chessboard) pentru evaluarea leziunilor cutanate [195]. Algoritmul propus este prezentat în figura 3.13




Figura 3.13 Prezentarea generală a studiului

Metricile geometrice sunt comparate cu distanța manuală folosind aria de sub curba (AUC) și pragurile care s-au asociat cu cele mai bune valori ale indicilor Youden. S-a utilizat procesul de comparare încrucișată pentru perechile DE-DM, DC-DM, DB-DM, DQ-DM. Curbele ROC, valorile AUC și valorile de prag sunt prezentate în figurile 3.14 și 3.15.

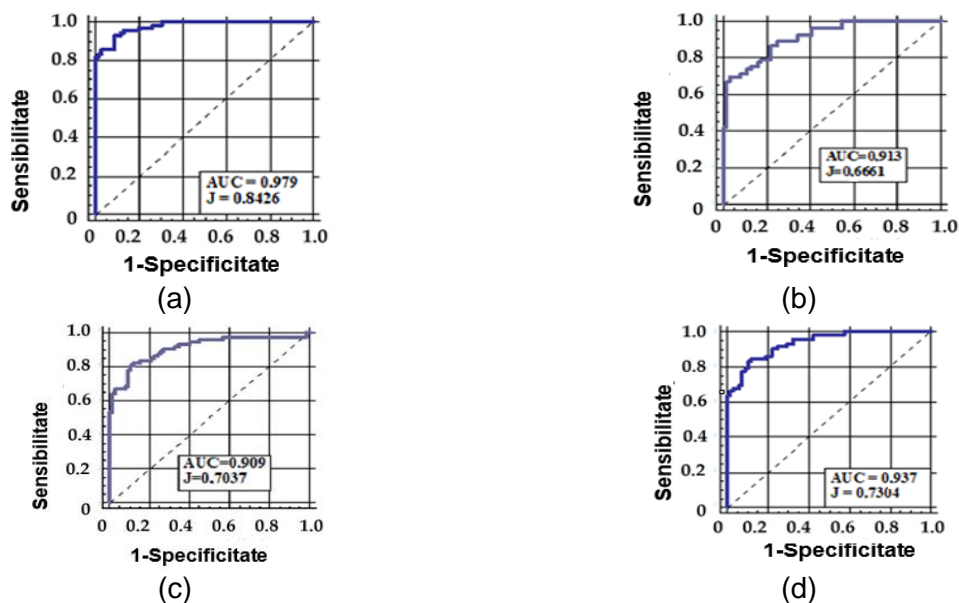


Figura 3.14 Curbele ROC pentru nevi
(a) DC-DM; (b) DB-DM; (c) DE-DM; (d) DQ-DM.

Stabilitatea valorilor metrice propuse este determinată utilizând următoarele valori de prag: $AUC > 0,6$ și indicele Youden $J \rightarrow 1$. Toate valorile de distanță investigate utilizate pentru măsurarea diametrului leziunilor cutanate au avut valori AUC mai mari de 0,9. Cele mai bune valori AUC au fost determinate pentru metrica distanței chessboard (DC), respectiv 0,979 pentru nevi și 0,982 pentru melanom. Indicele Youden J este 0,8426 pentru clasa nevi și 0,875 pentru clasa melanom indicând o relevanță excelentă a acestei valori pentru obiectivul declarat.

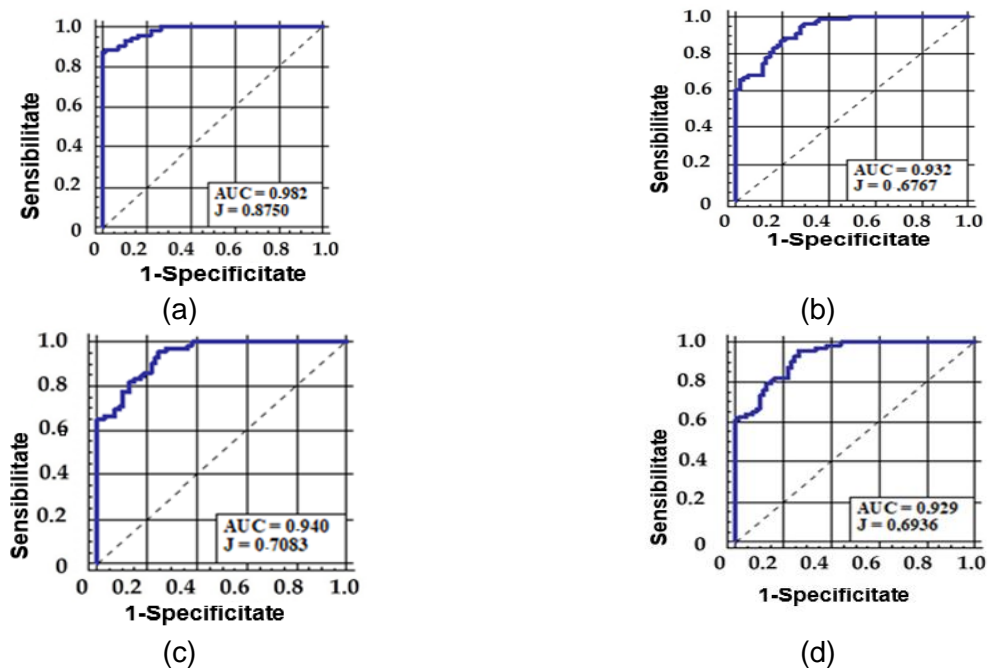


Figura 3.15 Curbele ROC pentru melanom.
(a) DC-DM; (b) DB-DM; (c) DE-DM; (d) DQ-DM.

Valorile mai mici ale AUC au fost obținute pentru distanța euclidiană (DE) cu o valoare de 0,909 pentru clasa nevi, și pentru distanța cvasi-euclidiană (DQ) cu o valoare de 0,929 pentru clasa melanomului, respectiv. În mod similar, valorile mai mici pentru J, au fost obținute pentru distanța city block (DB) cu 0,66661 pentru clasa nevi și 0,66767 pentru clasa melanom.

Precizia, sensibilitatea și specificitatea sunt prezentate în tabelul 3.6.

Tabelul 3.6 Sensibilitatea, specificitatea și acuratețea metricelor de distanță propuse: DC-DM, DB-DM, DE-DM și DQ-DM, în cazul nevilor și melanoamelor.

		DC-DM	DB-DM	DE-DM	DQ -DM
Sensibilitate (%)	nev	92.96	69.74	80.82	83.33
	melanom	87.50	87.34	95.83	92.83
Specificitate (%)	nev	91.30	96.87	89.55	89.71
	melanom	100.00	80.33	75.00	73.53
Acuratețe (%)	nev	92.13	83.30	85.18	86.52
	melanom	93.75	83.83	85.41	84.68

Conform datelor din tabelul 3.6 în ceea ce privește sensibilitatea și specificitatea, distanța chessboard (DC), se observă o precizie echilibrată atât pentru nevi (92.13) cât și pentru melanoame (93.75). În schimb, distanța city block (DB) are valori de sensibilitate de 69,74 / 87,34 față de specificitatea de 96,87 / 80,33 și, respectiv, valori de precizie de 83,30 / 83,83. În mod similar, valorile pentru distanța euclidiană (DE) prezintă valori de sensibilitate de 80,82 / 95,83 față de specificitate de 89,55 / 75,00 și 85,18 / 85,41 de precizie, iar valorile cvasi-euclidiene (DQ) indică o sensibilitate de 83,33 / 92,83 față de specificitatea de 89,71 / 73,53 și, respectiv, 86,52 / 84,68.

Rezultatele arată valori excelente de performanță pentru DC, având AUC de 0,997 pentru nevi și, respectiv de 0,982 pentru melanoame. De asemenea, J este 0,8426 pentru clasa nevilor și 0,875 pentru clasa melanoamelor.

3.4 Selectarea caracteristicilor relevante din imaginile non-dermatoscopice în vederea clasificării nevilor vs. melanoame

Încercând să ies din tiparele regulii ABCD, am realizat un studiu ce a vizat opt caracteristici, și anume indicele de asimetrie (AI), excentricitatea (E), circularitatea (CIRC), amplitudinea normalizată (FFT), asimetria de distribuției a culorii (Q), indicele de asimetrie a cadranelor (λ), și momentele Hu invariante (F6, F7). Aceste caracteristici sunt dedicate evaluării asimetriei pe baza evaluării formei și a culorilor leziunilor cutanate. Am urmărit să stabilesc potențialul lor în diferențierea leziunilor cutanate [196]. Am pus accentul pe evaluarea formei și culorii leziunii, care sunt exprimate prin diferite abordări matematice prezentate în capitolul 2. Sunt investigate 70 de melanoame și 100 de nevi. Pentru a evalua performanța procedurii de selecție a caracteristicilor propuse, au fost utilizate două seturi de date: D1 ce conține imagini originale și D2 ce conține imagini preprocesate pentru eliminarea zgomotului și reducerea neuniformă a iluminării. Imaginile sunt segmentate, urmate de extragerea caracteristicilor propuse. Curba ROC și aria de sub curbă (AUC) sunt folosite pentru a constata relevanța caracteristicilor selectate și capacitatea acestora de a diferenția leziunile cutanate. Etapele metodei propuse sunt prezentate în figura 3.16.

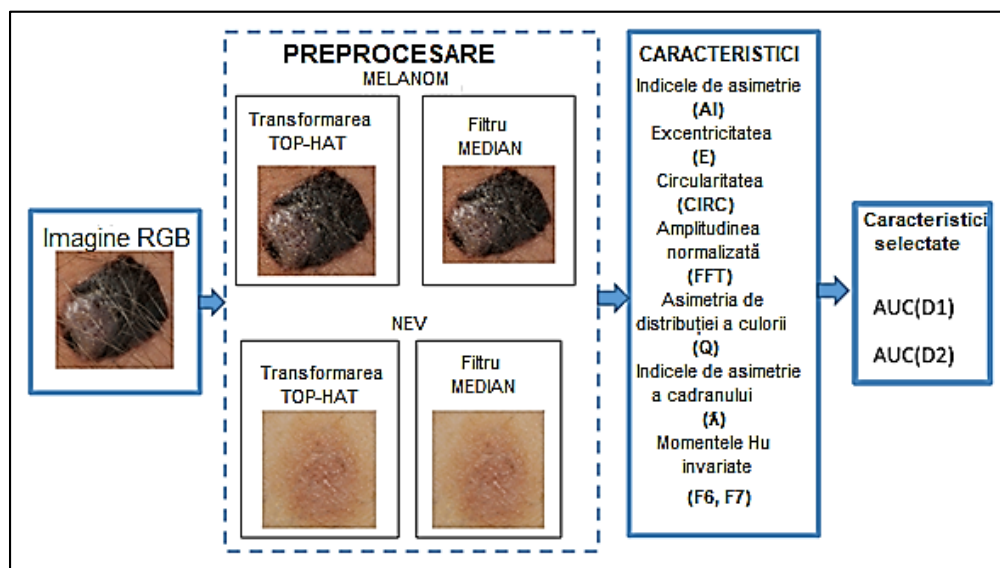


Figura 3.16 Metoda propusă pentru selectarea caracteristicilor

Un pas important pentru a obține performanțe ridicate în diferențierea leziunilor cutanate este eliminarea zgomotului și a artefactelor datorate existenței părului. Pentru îmbunătățirea imaginii cu o degradare minimă a imaginii inițiale este utilizat un filtru median. Pentru a corecta iluminarea neuniformă, a fost implementat un algoritm care utilizează transformarea Top-Hat. În figura 3.17 sunt prezentate exemple de imagini prelucrate pentru îndepărtarea zgomotului și corectarea neuniformă a iluminării.




Figura 3.17 Preprocesarea imaginilor.

(a1), (a2) Imagine originală; (b1), (b2) rezultate de egalizare a iluminării obținute prin utilizarea transformării Top-Hat; (c1), (c2) rezultatul filtrului median.
S-a folosit indicele 1 pentru nev și 2 pentru melanom.




Figura 3.18 Segmentarea leziunilor cutanate

(a1), (a2) Imaginea RGB originală; (b1), (b2) elipsă circumscrisă leziunii; (c1), (c2) mască eliptică; (d1), (d2) mască eliptică care înglobează leziunea pielii; (e1), (e2) mască eliptică în scala de gri care conține leziunea și (f1), (f2) mască asociată cu leziunea pielii (imagine segmentată).

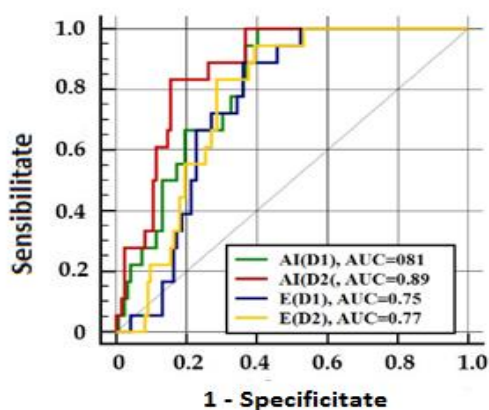
S-a folosit indicele 1 pentru nev și 2 pentru melanom.

Figura 3.18 afișează rezultatele procesului de segmentare a leziunilor cutanate. Metoda Otsu convertește în mod optim o imagine la nivel de gri într-o imagine binară prin setarea valorilor de prag pentru a reduce suprapunerea distribuției clasei.

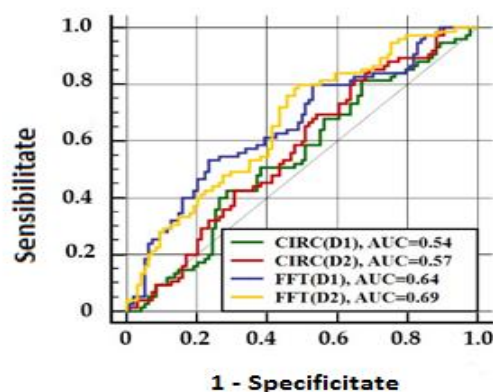
Curbele ROC și AUC sunt ilustrate în figura 3.19. Tabelul 3.7 ce prezintă valorile medii ale măsurilor de performanță pentru D1 ce conține imagini originale și D2 ce conține imagini preprocesate pentru eliminarea zgomotului și reducerea neuniformă a iluminării.

Tabelul 3.7 Sensibilitatea, specificitatea și acuratețea caracteristicilor analizate


	Caracteristici							
	AI	E	CIRC	TFF	Q	λ	F6	F7
Sensibilitate (D1)	0.98	0.90	0.81	0.53	0.61	0.67	0.68	0.76
Sensibilitate (D2)	0.84	0.94	0.81	0.80	0.63	0.65	0.72	0.62
Specificitate (D1)	0.64	0.66	0.32	0.76	0.57	0.46	0.80	0.51
Specificitate (D2)	0.87	0.63	0.35	0.51	0.58	0.53	0.82	0.71
Acuratețe (D1)	0.82	0.78	0.57	0.65	0.59	0.57	0.74	0.64
Acuratețe (D2)	0.85	0.79	0.58	0.66	0.61	0.59	0.77	0.67




(a)



(b)



(c)



(d)

Figura 3.19. Curbele ROC și valorile AUC pentru clasificarea leziunilor cutanate în melanom și nevi pentru seturile de date D1 și D2.

(a) AI (indice de asimetrie) și E (excentricitate); (b) caracteristicile de amplitudine ale normalității circularității (CIRC) și FFT; (c) asimetria caracteristicilor de distribuție a culorii (Q) și asimetriei cadranelor (λ); (d) momentele invariante ale lui F6 și F7 Hu.

Pentru imaginile din setul D2, se observă o acuratețe medie a clasificării melanom vs. nevi (tabelul 3.7). Excentricitatea (E) și amplitudinea normalizată (FFT) sunt caracteristici relevante pentru diferențierea leziunilor cutanate. Astfel că excentricitatea (E) și amplitudinea normalizată (FFT) pentru setul de date D2 indică o sensibilitate de 0,94 / 0,80, specificitate de 0,63 / 0,51 și acuratete de 0,79 / 0,66 iar, pentru setul de date D1 excentricitatea (E) și amplitudinea normalizată (FFT) indică o sensibilitate de 0,90 / 0,53, specificitate de 0,66 / 0,76 și acuratete de 0,78 / 0,65. Momentul invariant Hu F6 este important pentru analiza nevilor, deoarece specificitatea / sensibilitatea este de 0,82 / 0,72 cu acuratețea de 0,772. Momentul invariant Hu F7 urmează aceeași tendință, dar acuratețea este de 0,67 (D2). Asimetria distribuției culorii (Q) și indicele de asimetrie a cadranelor (λ) nu au arătat nicio contribuție semnificativă evaluată de sensibilitate, specificitate și acuratețe.

Conform acestor rezultate, indicele de asimetrie (AI) și excentricitatea (E) împreună cu momentul invariant Hu F6 sunt destul de competente pentru diferențierea leziunilor cutanate. De asemenea, amplitudinea normalizată (FFT) prezintă un mare potențial în clasificarea leziunilor cutanate. În figura 3.19 observăm următoarele aspecte: valorile ariei de sub curbă (AUC) pentru AI (indicele de asimetrie) este de 0,81 pentru D1 și 0,89 pentru D2 care arată o separare foarte bună între cele două clase (melanom și nev). În mod similar, pentru caracteristica E (excentricitate), AUC este 0,75 (D1) și 0,77 (D2) indicând o bună separare între cele două clase. Circularitatea (CIRC), asimetria de distribuției a culorii (Q) și indicele de asimetrie a cadranelor (λ) au ariile de sub curba ROC cuprinse între valorile 0,51 și 0,58 indicând o separare modestă a celor două clase. Amplitudinea normalizată (FFT) are AUC 0,64 pentru D1 și 0,69 pentru D2 și prezintă o separare medie a celor două clase. Momentele Hu invariante F6 și F7 au AUC 0,71 pentru D1 și 0,77 pentru D2 și respectiv 0,61 pentru D1 și 0,66 pentru D2. F6 are o separare bună a celor două clase, în timp ce F7 are o separare medie a celor două clase.

Capitolul 4

Contribuții personale privind clasificarea leziunilor cutanate bazate pe clustere de culoare

Scopul acestui capitol este aducerea în prim plan de noi metode de segmentare avansate bazate pe clusterizare și contururi active capabile să extragă structurile leziunilor cutanate. Caracteristicile extrase din zonele de interes pot fi analizate și clasificate cu metode statistice astfel încât partajarea claselor ce conțin nevi și melanoame să fie cât mai evidentă. Obiectivul acestui capitol s-a axat pe înțelegerea influenței operatorilor morfologici, în diferențierea leziunilor cutanate.

În cadrul acestui capitol sinteza cercetărilor științifice este relatată prin studii ce permit selectarea distribuției relevante a culorii din imaginile leziunilor cutanate utilizând analiza histogramei de culoare, algoritmul kNN, dimensiunea fractală de suprafață și a caracteristicilor statistice ale grupului de culori folosind un ansamblu de tehnici de învățare automată, algoritmul Random Forest (RF).

4.2 Analiza histogramei de culoare pentru diferențierea leziunilor cutanate

Am propus o nouă soluție pentru detectarea granițelor leziunilor cutanate utilizând histograma culorilor ca instrument principal în evaluarea distribuției culorilor din canalele roșii, verzi și albastre [200]. Pentru fiecare canal monocrom se calculează o valoare a pragului global folosind metoda Otsu. Se realizează gruparea pixelilor obiectelor și a fundalului imaginii luându-se în considerare variațiile intra și inter-clasă. Pragurile selectate sunt marcate clar în figura 4.4 și figura 4.5.




Figura 4.4 Histograme, canale monocrome R, G și B și valori prag pentru melanom.

(a) Histograma canalelor RGB; (b) canal roșu; (c) canal verde; (d) canal albastru.

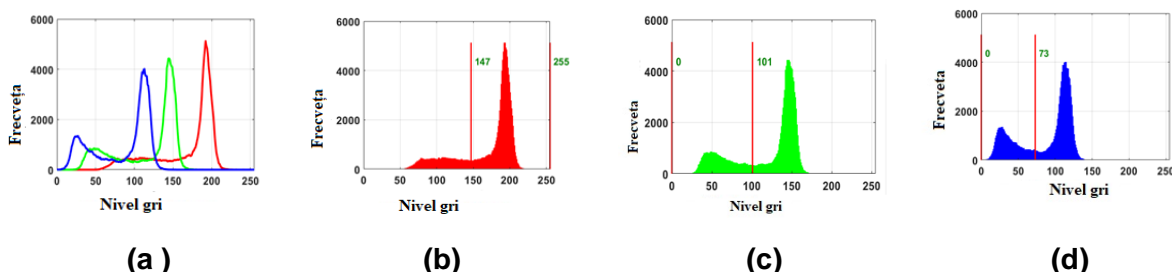


Figura 4.5 Histograme, canale monocrome R, G și B și valori de prag pentru nevi.

(a) Histograma canalelor RGB; (b) canal roșu; (c) canal verde; (d) canal albastru.

Datele afișate în histogramele de culoare sunt analizate folosind „răspândirea” histogramei (HS) [61] ca raportul dintre amplitudinea interquartilică (IQR) și amplitudinea pixelilor monocromatici (R). Pentru a determina similaritatea dintre caracteristici am utilizat algoritmul K-

means. Am presupus că, odată formate clusteretele, nu există caracteristici redundante în modelul nostru.

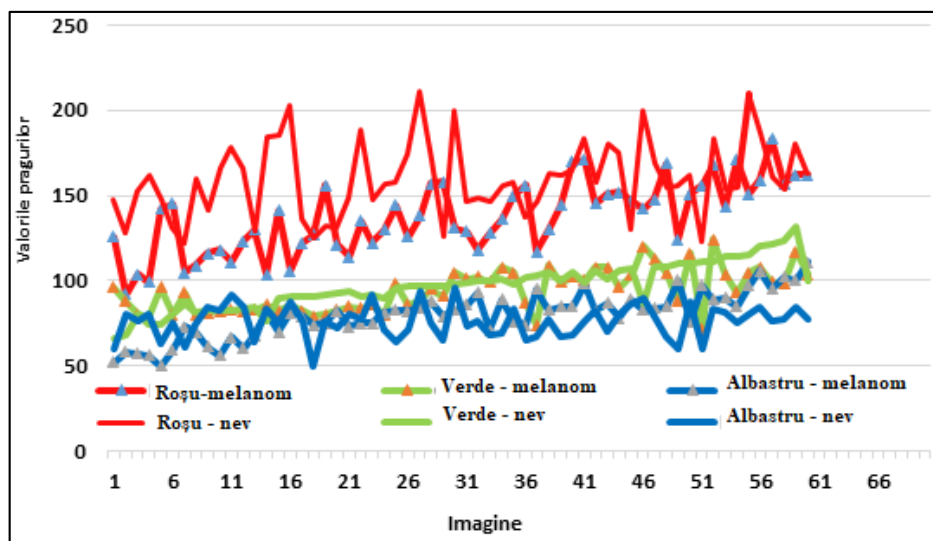


Figura 4.7 Valorile pragului pentru canalele monocromatice R, G și B pentru melanom și nevi

Se observă că, pentru canalul G și B valorile de prag sunt distribuite uniform deci, nu pot furniza informații semnificative. Pentru canalul R valorile pragului sunt mai mari și distribuția datelor este mai bine separată între clase, astfel încât acesta ar putea fi ușor analizat. Aceste valori prag pentru fiecare canal monocrom creează o nouă bază de date pentru cluster.

Pentru a determina calitatea și valabilitatea clusterului, s-au calculat: silueta unui obiect, silueta medie a unui cluster și silueta medie globală pentru întregul set de imagini a leziunilor cutanate (Figura 4.9). O decizie privind importanța canalului monocrom în clasificarea leziunilor cutanate este realizată corelând HS cu ponderea relativă a valorilor pragului pentru fiecare canal monocrom (Tabel 4.2).

Tabelul 4.2 Valoarea HS pentru melanom și nevi

	Melanoma	Nevi
HS	0,143178	0,100046

O alocare corespunzătoare a obiectelor în cluster este evaluată de grosimea siluetei.




Figura 4.9 Analiza siluetei pentru clusteretele de date, $n = 2$.

(a) Canal roșu; (b) canal verde; (c) canal albastru; 1 - melanom; 2 - nev.

Numărul de clustere a fost ales a priori pentru 2, deoarece există două clase de cluster: melanom și nev. Așadar clusterelor sunt distincte, neuniforme dar și negative pentru canalele G și B iar pentru canalul R clusterelor sunt distincte, uniforme și pozitive.

Tabelul 4.3 Valorile SC pentru canalele monocromatice

Leziunea cutanată	Roșu	Verde	Albastru
Melanom	0,91	0,62	0,41
Nev	0,90	0,61	0,39

Canalul roșu se dovedește a fi cel mai potrivit pentru această sarcină, deoarece oferă o bună uniformitate a lățimii siluetei, fără coeficient de siluetă negativă și valori SC apropiate de 1.

4.4 Clasificarea leziunilor cutanate pe baza dimensiunilor fractale de suprafață și a caracteristicilor statistice ale grupului de culori folosind un ansamblu de tehnici de învățare automată

Obiectivul studiului constă în recunoașterea și clasificarea leziunilor cutanate prin implementarea unei noi combinații de caracteristici dintre dimensiunea fractală de suprafață a lui Higuchi 2D și caracteristicile relevante ale zonei de culoare și doi clasificatori, ca metodă de diagnosticare auxiliară pentru recunoașterea melanomului.

Baza experimentală a fost alcătuită din 248 imagini de nevi și 407 imagini de melanom aparținând bazelor de date publice: 7-Point (68 nevi și 297 imagini dermoscopice cu melanoame), Med-Node (100 nevi și 40 melanoame imagini non-dermoscopice), PH2 (80 nevi și 40 melanoame imagini dermoscopice).

Pentru atingerea obiectivului propus s-au parcurs următoarele direcții:

- determinarea procentului mediu reprezentativ de zone de culoare ale leziunilor cutanate pentru fiecare set de date considerat.
- propunerea unui descriptor pentru investigarea dimensiunilor fractale ale suprafeței pielii pentru canalele din imagini color RGB, adică dimensiunea fractală Higuchi 2D ca obiectiv cantitativ.
- Implementarea a două clasificatoare distincte de învățare automată, și anume un algoritm kNN-CV și o abordare RBFNN ca clasificator neliniar, pentru a genera predicția.
- partiționare dinamică a datelor este efectuată folosind metoda de validare încrucișată de 5 ori (CV). Aceste clasificatoare de învățare automată aparțin unor paradigme de clasificare diferite.

Un exemplu de preprocesare a imaginii pentru reducerea zgomotului, îndepărtarea părului și segmentare a imaginii este prezentat în figura 4.13. Pentru îndepărtarea părului s-a utilizat soft-ul DullRazor și segmentarea imaginii pe baza pragului de culoare.

Caracteristicile de culoare sunt selectate prin folosirea unei metode de grupare ce permite selectarea distribuției relevante a culorii în imaginile leziunilor melanocitare și calcularea procentului mediu de zone de culoare din zona leziunii de nevi și melanom. Pentru aceasta, am analizat histograma color a fiecărei imagini asociate leziunii cutanate.

Astfel, am considerat douăzeci și trei de grupuri de culori, notate ca cl_1, \dots, cl_{23} , care se caracterizează prin cele mai mari diferențe între intensitatea minimă și maximă în fiecare canal R, G și B, conform datelor furnizate în [203]. Pentru fiecare imagine, procentul fiecărui grup de culori este calculat ca raport între numărul de pixeli din leziunea aparținând grupului de culori specificat și totalul de pixeli ai leziunii.




Figura 4.13 Ilustrarea preprocesării pentru îndepărtarea părului și segmentare.

Rândurile 1 și 2: imaginea nevi (baza de date PH2). Rândurile 3 și 4: imaginea melanomului (baza de date cu 7 puncte în rândul 3 și baza de date Med-Node în rândul 4).

Prima coloană: imaginea originală. A doua coloană: imagine după îndepărtarea părului.

A treia coloană: imagine segmentată.

Aceste procente medii ale zonelor de culoare reprezintă caracteristici statistice relevante pentru diferențierea leziunilor cutanate. Se construiește un vector cu multe caracteristici. Pentru a elimina caracteristicile fără informații predictive, se folosește un test t. O valoare de $p < 0,05$ este considerată semnificativă statistic, adică eşantioanele selectate sunt diferite unele de altele într-un mod semnificativ statistic. Caracteristicile selectate sunt universal acceptate și utilizate pentru diferențierea leziunilor cutanate. Un exemplu de măsurare a conținutului de culoare și metoda de grupare pentru a selecta distribuția relevantă a culorii este prezentat în Figura 4.14. Dimensiunea fractală a suprafeței este calculată folosind o generalizare 2D a HFD. Acesta calculează HFD al culorilor canalelor R, G și B din imagini RGB asociate leziunilor cutanate. Descriptorul fractal de suprafață al lui Higuchi 2D a fost calculat pentru fiecare imagine cu parametrul de scalare fractal variind de la $k = 1$ la $k = 8$ (Figura 4.15).

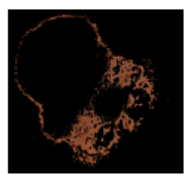
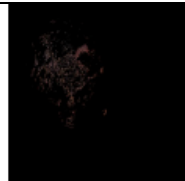
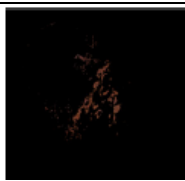

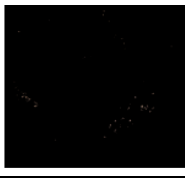
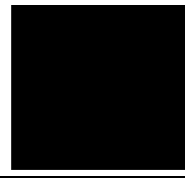




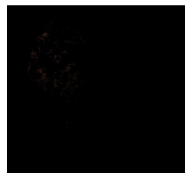
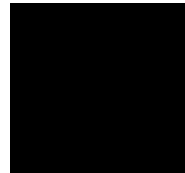
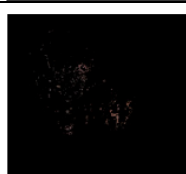

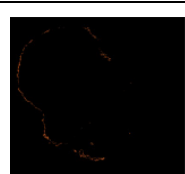
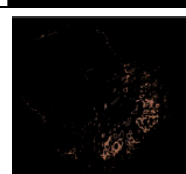

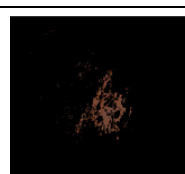


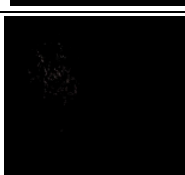
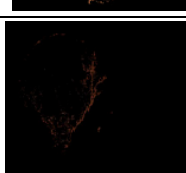
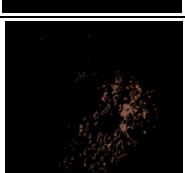

cl1 R_{min} 128 G_{min} 64 B_{min} 32 R_{max} 159 G_{max} 95 B_{max} 63		cl9 R_{min} 64 G_{min} 32 B_{min} 32 R_{max} 95 G_{max} 63 B_{max} 63		cl17 R_{min} 96 G_{min} 32 B_{min} 32 R_{max} 127 G_{max} 63 B_{max} 63	
cl2 R_{min} 32 G_{min} 0 B_{min} 0 R_{max} 63 G_{max} 31 B_{max} 31		cl10 R_{min} 160 G_{min} 128 B_{min} 96 R_{max} 191 G_{max} 159 B_{max} 127		cl18 R_{min} 192 G_{min} 96 B_{min} 96 R_{max} 223 G_{max} 127 B_{max} 127	
cl3 R_{min} 32 G_{min} 32 B_{min} 32 R_{max} 63 G_{max} 63 B_{max} 63		cl11 R_{min} 96 G_{min} 32 B_{min} 0 R_{max} 127 G_{max} 63 B_{max} 31		cl19 R_{min} 224 G_{min} 160 B_{min} 128 R_{max} 255 G_{max} 191 B_{max} 159	
cl4 R_{min} 160 G_{min} 96 B_{min} 64 R_{max} 191 G_{max} 127 B_{max} 95		cl12 R_{min} 32 G_{min} 32 B_{min} 0 R_{max} 63 G_{max} 63 B_{max} 31		cl20 R_{min} 192 G_{min} 128 B_{min} 64 R_{max} 223 G_{max} 159 B_{max} 95	
cl5 R_{min} 96 G_{min} 64 B_{min} 64 R_{max} 127 G_{max} 95 B_{max} 95		cl13 R_{min} 128 G_{min} 96 B_{min} 96 R_{max} 159 G_{max} 127 B_{max} 127		cl21 R_{min} 128 G_{min} 64 B_{min} 0 R_{max} 159 G_{max} 95 B_{max} 31	
cl6 R_{min} 128 G_{min} 96 B_{min} 64 R_{max} 159 G_{max} 127 B_{max} 95		cl14 R_{min} 160 G_{min} 64 B_{min} 32 R_{max} 191 G_{max} 95 B_{max} 63		cl22 R_{min} 96 G_{min} 64 B_{min} 32 R_{max} 127 G_{max} 95 B_{max} 63	
cl7 R_{min} 160 G_{min} 96 B_{min} 32 R_{max} 191 G_{max} 127 B_{max} 63		cl15 R_{min} 160 G_{min} 96 B_{min} 96 R_{max} 191 G_{max} 127 B_{max} 127		cl23 R_{min} 64 G_{min} 64 B_{min} 64 R_{max} 95 G_{max} 95 B_{max} 95	
cl8 R_{min} 64 G_{min} 32 B_{min} 0 R_{max} 95 G_{max} 63 B_{max} 31		cl16 R_{min} 128 G_{min} 64 B_{min} 64 R_{max} 159 G_{max} 95 B_{max} 95		Imaginea segmentată	

Figura 4.14 Exemplu de măsurare a conținutului de culoare și metoda de grupare pentru a selecta distribuția relevantă a culorii din imaginile leziunilor cutanate.

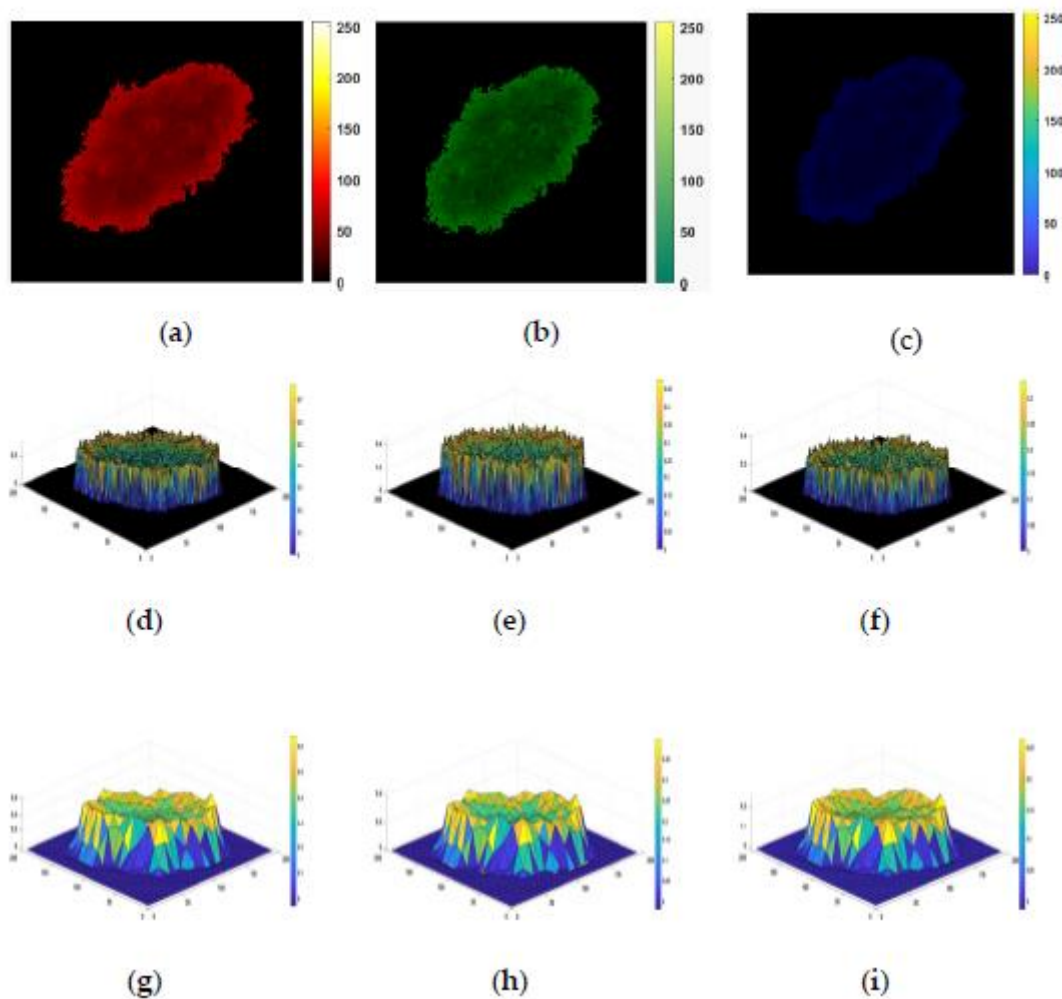


Figura 4.15 Exemplu de calcul HFD.

(a–c) Canale de culoare R, G și B pentru o imagine digitală; (d–i) O ilustrare a modelelor de teselație pentru fiecare canal de culoare. Formele triunghiulare ale lui $k = 1$ sunt prezentate în (d–f); parametrul de scalare fractal $k = 4$ este prezentat în (g, i); (d,g) sunt imagini de canal R; (e,h) sunt imagini de canal G; (f, i) sunt imagini de canal B.

Clasificarea caracteristicile de culoare, cât și a celor fractale se realizează separat, folosind algoritmul kNN cu o metodă de validare încrucișată de 5 ori. Aceleași caracteristici discriminante sunt utilizate pentru clasificarea prin abordarea RBFNN ca și cele pentru un clasificator neliniar.

Se efectuează o analiză a performanței acestor metode diferite de clasificare. Performanța de predicție a kNN bazată pe procentul mediu al descriptorilor de caracteristici ale zonelor colorate a diferit semnificativ în ceea ce privește grupurile de culori și seturile de date (Figura 4.16). Cele mai mari precizii de clasificare de 82,47% (clustere cl10 și cl15), 81,44% (cl23) și 80,41% (cl20) aparțin setului de date PH2. A doua cea mai mare precizie de clasificare de 75,91% (cl5 cl7 și cl14) aparține setului de date Med-Node. Clusterelor de culoare cl3, cl11 și cl13 din setul de date cu 7 puncte au dat rezultate de precizie mai scăzută. Grupurile de culori cl8, cl16, cl17, cl19 și cl22 nu au conținut niciun procent mediu relevant de descriptori de caracteristici ai zonelor de culoare.




Figura 4.16. Performanța de predicție pentru validarea încrucișată de 5 ori și clasificatorul kNN pentru procentaj mediu diferit de zone de culoare/descriptori de clusteri de culoare.

Performanța clasificării bazată pe descriptorul fractal de suprafață al lui Higuchi 2D este afișată în Tabelul 4.5. Rezultatele clasificării arată că descriptorul fractal de suprafață al lui Higuchi 2D produce o precizie de clasificare mai mare (79,38%) decât procentul mediu de descriptori de caracteristici ai zonelor de culoare pentru setul de date PH2.

Tabelul 4.5. Precizia pentru validarea încrucișată de 5 ori și clasificatorul kNN pentru descriptorii fractali de suprafață 2D Higuchi.

Baza de date	Sensitivitate (%)	Acuratețe (%)	Precizia (%)	AUC	Dice Score
7-Point	80.77	71.43	73.26	0.6948	0.7683
Med-Node	30.19	64.23	57.14	0.6423	0.3951
PH2	83.33	79.38	62.50	0.8047	0.7143

Caracteristicile discriminante selectate au fost clasificate printr-o validare încrucișată de cinci ori și o abordare RBFNN. Datele de intrare au fost împărțite în cinci subseturi; un subset a fost setul de testare, iar celelalte patru subseturi au fost pentru antrenament. Funcțiile gaussiene folosite h_1, h_2, \dots, h_g au fost după cum urmează: $g = 15$ pentru setul de date cu 7 puncte; $g = 11$ pentru setul de date Med-Node și $g = 10$ pentru setul de date PH2.

Investigația a fost dedicată stabilirii celei mai bune performanțe pentru clasificatorul RBFNN cu diferite intrări: 50 de neuroni pe stratul ascuns și două ieșiri. Numărul de neuroni ascunși a variat de la 0 la 50, iar noile noduri ascunse au fost încorporate automat de rețea. Verificarea experimentală a indicat că 50 de neuroni de pe stratul ascuns au asigurat cea mai bună performanță de clasificare, iar clasificatorul a obținut soluția optimă globală caracterizată prin MSE mai scăzută.

Obiectivul nostru de eroare medie pătrată specificat a fost 0,01. Performanța de diagnosticare a modelelor a fost evaluată în termeni de sensibilitate, acuratețe, precizie, AUC, scoruri Dice și MSE furnizate de clasificatorul RBFNN. Pentru a evidenția faptul că ambele caracteristici se pot promova reciproc în procesul de diagnosticare, procentul mediu de zone de culoare și caracteristicile HFD au fost evaluate și comparate împreună și separat, iar modificările de performanță sunt prezentate în tabelul 4.6.

Tabelul 4.6. Performanța clasificatorului RBFNN în experimentele de testare.

Baza de date	RBFNN intrare	Senzitivitate (%)	Acuratețe (%)	Precizia (%)	AUC	Scor DICE	Nr. neuroni ascunși	MSE
7-POINT	Cluster de culoare	97.77	95.12	94.32	0.9412	0.9603	50	0.1904
	Cluster de culoare și HFD	98.01	95.42	94.44	0.9422	0.9630		0.0924
Med-Node	Cluster de culoare	96.22	94.12	88.61	0.9550	0.9333	50	0.1789
	Cluster de culoare și HFD	96.42	94.71	87.50	0.9588	0.9396		0.1662
PH2	Cluster de culoare	1.00	94.17	85.03	0.9553	0.9195	50	0.1372
	Cluster de culoare și HFD	1.00	94.88	85.62	0.9685	0.9211		0.1128

Tabelul 4.6. arată că pentru toate seturile de date investigate, atunci când intrarea rețelei neuronale a constat atât din procentul mediu de zone de culoare/cluster de culori, cât și din descriptorii fractali de suprafață Higuchi 2D, performanța de diagnosticare a fost îmbunătățită în ceea ce privește acuratețea, AUC, scorurile Dice, și MSE. În plus, RBFNN propus sa dovedit a fi mai precis și mai eficient decât algoritmul kNN în recunoașterea și clasificarea cancerului de piele.

Erorile RBFNN au fost mai mici atunci când datele de intrare erau grupuri de culori și descriptorii HFD, confirmând ipoteza noastră de lucru de a folosi descriptorii fractali de suprafață ai lui Higuchi 2D pentru a îmbunătăți performanța clasificării a fost corectă. În plus, analiza leziunilor cutanate a fost mai precisă atunci când a fost folosit RBFNN propus.

Am comparat rezultatele obținute cu metodele de învățare automată, cât și cu metodele rețelei neuronale (tabelul 4.7). Precizia de clasificare a kNN-CV cu caracteristicile fractale de suprafață 2D Higuchi este comparabilă cu cea oferită de alți clasificatori. Se poate observa că algoritmul RBFNN propus a obținut o îmbunătățire semnificativă a preciziei în toate cazurile.

Tabelul 4.7. *Comparația rezultatelor acurateței ale metodei propuse cu cele ale metodelor existente.*

Autor	Acuratețe (%) și detalii
Nasiri et al.[204]	64% (pentru primul test: kNN (300, 100) și caracteristici punctuale) 67% (al doilea test: kNN (1346, 450) și caracteristici spot)
Kavitha et al. [205]	78.2 (caracteristici kNN și GLCM) 81.79% (caracteristici Inception-ResNet-v2, ISIC 2016)
Al-masni et al. [206]	81.57% (setul de date ResNet-50, ISIC 2017) 89.29% (setul de date ResNet-50, ISIC 2018)
Seeja & Suresh [207]	79.26% (kNN, LBP și histograma Edge, HOG, filtru Gabor)
Khan et al. [208]	94.50% (Rețea neuronală/ Feed Forward/ funcție sigmoidă/ 3 straturi ascunse, setul de date ISBI2016, antrenament și testare 70:30). 94.20% (Rețea neuronală/ Feed Forward/ funcție sigmoidă/ 3 straturi ascunse, setul de date ISBI2017, antrenament și testare 70:30).
Clasificatorul propus kNN pentru descriptorii fractali de suprafață 2D Higuchi	71.43% (7-Point); 64.23% (Med-Node) 79.38% (PH2) pentru caracteristicile fractale de suprafață ale lui Higuchi 2D
Clasificatorul propus RBFNN	95.42% (7-Point) 94.71% (Med-Node) 94.88% (PH2)

4.5 Clasificarea leziunilor cutanate utilizând algoritmul Random Forest (RF)

Deoarece primele semne de avertizare pentru depistarea precoce și prevenirea melanomului sunt culoarea și marginile neregulate o importanță deosebită am acordat metodelor și tehnicilor de investigare a culorii imaginilor dermoscopice pe baza algoritmilor de clusterizare și caracterizarea formelor obiectelor dintr-o imagine pe baza momentelor lui Hu privite ca trăsături ale momentului invariant [209].

Obiectivul cercetării a fost dezvoltarea unui algoritm original pentru diferențiere a leziunilor cutanate pe baza caracteristicilor de culoare (C) și a momentelor Hu (H) utilizând algoritmul Random Forest (RF).

Baza experimentală utilizată a fost alcătuită din 68 nevi și 98 melanoame din baza de date 7-Point, 100 nevi și 70 melanom din baza de date Med-Node și 80 nevi și 40 melanoame din baza de date PH2. Pentru toate seturile de date, 70% din eșantioanele totale au fost prelevate în setul de antrenament, iar restul de 30% pentru setul de testare. Metodologia propusă pentru identificarea caracteristicilor relevante pentru clasificarea leziunilor cutanate este prezentată în Figura 4.17.

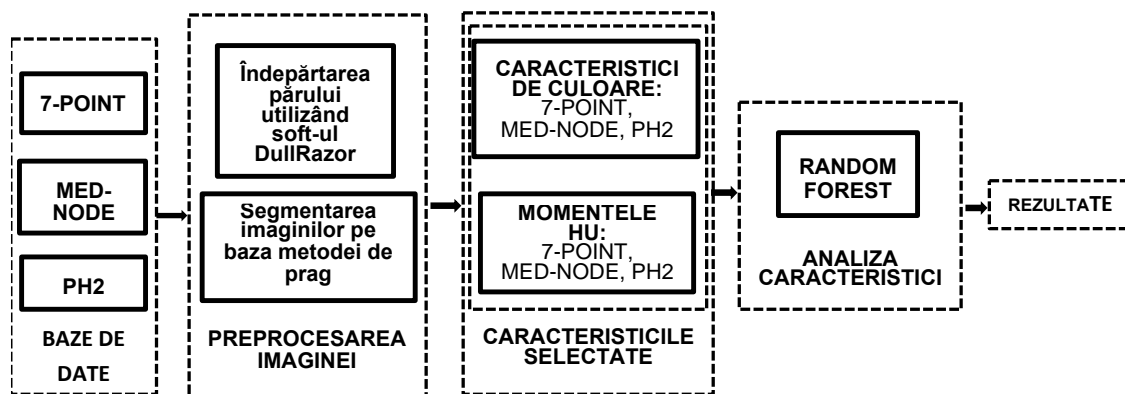


Figura 4.17 Prezentarea generală a metodologiei

Pentru extragerea caracteristicilor de culoare, imaginile au fost segmentate pe baza metodei de prag optim de culoare aplicată pe fiecare canal de culoare RGB (roșu, verde, albastru). S-a obținut o mască binară pentru fiecare imagine și a fost evidențiată zona de interes pentru leziunea cutanată. De asemenea, imaginile segmentate au fost preprocesate folosind software-ul DullRazor pentru îndepărtarea părului.




Figura 4.18 Exemple de imagini preprocesate.

Rândul 1: imagini din baza de date 7-Point; Rândul 2: imagini din baza de date MED-NODE;

Rândul 3: imagini din baza de date PH2

În figura 4.18 sunt prezentate exemple de imagini preprocesate. Fiecare imagine este împărțită în grupuri de culori pe baza metodei propuse de Seidenari et al. [203]. Folosind intensitatea RGB minimă și maximă au fost extrase 23 de caracteristici de culoare. Metoda de grupare permite selectarea distribuției de culoare relevante, și calculează procentul mediu al zonelor de culoare din zona leziunii cutanate [202].

Am utilizat algoritmul RF care implică 30 caracteristici de intrare pentru imaginile leziunilor cutanate a trei seturi de date și două clase de ieșire (nevi și melanoame). Seturile de caracteristici obținute sunt introduse în clasificatorul RF aleatoriu pentru a determina caracteristica relevantă pentru a clasifica leziunile cutanate cu cea mai mare acuratețe. Cum algoritmul RF pentru problemele de clasificare folosește votul majoritar, iar pentru problemele de regresie folosește predicția medie a arborilor de decizie individuali vom analiza acele caracteristici pentru care relevanța depășește media (0,033). Figura 4.19 arată performanța calculată pentru caracteristicile propuse.




Figura 4.19 Acuratețea caracteristicilor

Acuratețea diferențierii leziunilor cutanate a fost evaluată pe un set de antrenament format din 30% de imagini ale leziunilor cutanate și testat pe 70% de alte imagini ale leziunilor cutanate pentru fiecare set de date. Deoarece performanța de diagnostic poate depinde de gradul de dificultate al imaginii, am corelat parametrii matematici ai caracteristicilor leziunilor cutanate și am comparat acuratețea pentru fiecare bază de date. Caracteristicile relevante sunt:

- H5, H7, H6, H2, C08 pentru setul de date 7 Point;
- H7, H5, H6, H2, H1 pentru setul de date Med-Node;
- H5, H6, H7, C03, H1 pentru setul de date PH2.

Impactul utilizării caracteristicilor selectate pentru fiecare set de date sunt prezentate în tabelul 4.8.

Tabelul 4.8 Caracteristicile relevante și performanțele clasificatorului RF

Baza de date	Acuratețe	Senzitivitate	Specificitate
7-Point	94.0%	92.5 %	94.9%
Med-Node	98.1 %	99.0 %	97.1%
PH2	96.5 %	98.7 %	92.7%

Rezultatele obținute au fost comparate cu rezultatele obținute în alte studii. În studiul prezentat s-a obținut o precizie mai mare în clasificarea leziunilor cutanate pentru momentele HU comparativ cu caracteristicile de culoare, respectiv 94% pentru baza de date 7-Point, 98,1% pentru baza de date Med-Node și 96,5% pentru baza de date PH2. Aceste caracteristici sunt dedicate evaluării imaginilor pe baza evaluării neregularității marginilor și culorilor leziunilor cutanate. Abordarea noastră de a analiza geometria formei și culoarea leziunilor benigne (nevi) și maligne (melanoame) va fi utilă pentru a detecta leziunile înainte ca acestea să crească și să devină un caz de melanom.

Capitolul 5

Contribuții personale privind implementarea sistemului expert „Skin Lesions”

Scopul sistemului expert „**Skin Lesions**” este de a oferi utilizatorului informații relevante care să îi permită acestuia să tragă propriile concluzii pe baza analizei leziunii cutanate, cu specificatia clara că sistemul nu este menit să înlocuiască medicii, ci doar oferă utilizatorilor o motivație suplimentară pentru a solicita asistență medicală, dacă este necesar.

5.1 Cerințe pentru dezvoltarea unei aplicații

Sistemul expert „Skin Lesions” a fost transformat într-o aplicație mobilă (app) care poate fi descărcată și instalată pe platforme de telefonie mobilă Android de la Google.

Principalele cerințe pentru aplicația mobilă:

- să poată captura imagini utilizând camera foto a telefonului;
- să poată încărca imagini din memoria telefonului;
- interfața grafică a aplicației să conțină butoane pentru pornirea proceselor de analiză;
- să afișeze mesaje de informare.

Un sistem expert de analiză a melanomului este construit în patru etape principale. Prima etapă este achiziția imaginii care poate fi efectuată prin diferite dispozitive cum ar fi dermatoscopul, spectroscopul, camera digitală standard sau camerei foto a telefonului. Imaginile achiziționate de aceste dispozitive prezintă trăsături particulare și calități diferite, care pot schimba semnificativ rezultatul procesului de analiză. A doua etapă implică detectarea leziunilor cutanate și redimensionarea imaginii. A treia etapă calculează caracteristicile A, B, C, D cu algoritmi proprii. În cele din urmă, a patra etapă clasifică leziunile în funcție de scorul TDS producând o estimare dacă leziunea este benignă sau malignă (melanom).

Pentru a calcula scorul TDS, caracteristicile asimetrie, regularitatea muchiei/granitei, culoare și diametru sunt utilizați algoritmi proprii. Fiecare dintre caracteristici este apoi înmulțită cu un factor de ponderare dat pentru a obține un scor dermoscopic total (TDS). Valorile TDS sub 4,75 indică o leziune melanocitară benignă, valorile între 4,8 și 5,45 indică o leziune suspectă, iar valorile egale sau mai mari de 5,45 sunt foarte sugestive pentru melanom [210].

○ Pentru dezvoltarea sistemului expert propus am utilizat:

- kit-ul de dezvoltare pentru limbajul de programare Java;
- SDK-ul (Software Development Kit) de Android;
 - Android Studio: un mediu integrat de dezvoltare (IDE);
- Android Virtual Device (livrat împreună cu SDK-ul de Android), un dispozitiv pe care să se ruleze aplicațiile;
- Un telefon mobil cu sistemul de operare Android pentru care s-a dezvoltat aplicația „**Skin Lesions**”.

Compilarea acesteia și rularea pe un dispozitiv este realizat cu ajutorul SDK-ului. Este componenta care crează fișierul ce va fi instalat pe dispozitiv și care are extensia .apk, îmbinând toate resursele aflate în proiectul aplicației.

Am încorporat codurile MATLAB pentru fiecare caracteristică utilizând ToApp Block din pachetul de asistență Android Studio.

5.2 Tehnica propusă

Achiziționarea imaginii digitale a leziunii cutanate este primul și principalul pas în realizarea sistemului expert „**Skin Lesions**”. Noi folosim fie imagini obținute cu ajutorul unei camere digitale disponibile în comerț sau dermoscopie, fie imagini obținute cu telefonul mobil. După ce imaginea este achiziționată se extrag caracteristicile discriminatorii din leziunea cutanată. Pentru a evalua asimetria am utilizat algoritmul de calcul al asimetriei din caracteristicile geometrice (GAF) prezentat în studiul [194]. Pentru a evalua neregularitatea conturului (granița) (B) am utilizat indicele de compactitate prezentat în studiul [193]. Pentru determinarea scorului de culoare se iau în considerare șase culori diferite: alb, roșu, maro deschis, maro închis, albastru-cenușiu și negru. Albul ar trebui să fie luat în considerare numai dacă zona este mai deschisă decât pielea adiacentă. Scorul maxim al culorii este 6, iar scorul minim este 0. Pentru detectarea culorilor am utilizat metoda propusă în studiul [200]. Pentru diametru am utilizat distanța Chessboard metodă prezentată în studiul [195].

Pentru clasificarea leziunilor cutanate propun calcularea scorului total al dermoscopiei (TDS) ce folosește formula 1.1. [211]:

După calcularea TDS, diagnosticul va fi obținut conform interpretării din tabelul 5.1.

Tabelul 5.1 Diagnosticul leziunilor conform TDS.

Scorul total al dermoscopiei TDS	Interpretare
0 - 2.75	Leziune benignă
2.76 - 4.75	Leziune ușor suspectă (benignă)
4.76 - 5.45	Leziune suspectă de a fi melanom (melanom)
>5.46	Leziune cu un înalt grad de suspiciune de a fi melanom (melanom)

În aplicație mesajul afișat va fi realizat conform algoritmului:

Algoritmul

propus:

```
if (TDS >= 0.00 && TDS<= 2.75)
    msgbox('We keep under observation')
elseif (TDS >= 2.76 && TDS<= 4.75)
    msgbox('Go to the doctor')
elseif (TDS >= 4.8 && TDS<= 5.45)
    msgbox('Suspicious Melanoma Cancer Detected')
% elseif (TDS >= 5.46)
else
    msgbox('Highly suspicious Melanoma Cancer Detected')
end.
```

5.3 Descrierea aplicației

Instalarea aplicației „**Skin Lesions**” pe telefonul mobil se face:

➤ prin accesarea link-ului:

<https://drive.google.com/drive/folders/18ayYaLWY3hMrn12ghcuQ4q-30f fWmoi?usp=share link>

➤ prin scanarea codului QR (figura 5.5):



Figura 5.5 Codul QR aplicația „Skin Lesions”

Pentru a se putea instala o aplicație pe un dispozitiv mobil, trebuie să se activeze posibilitatea de rulare, din *Settings* → *System* → *Developer Options*. Această opțiune trebuie activată, ca de altfel și opțiunea *Debugging* → *Android Debugging* (pe unele sisteme poate apărea ca USB Debugging).

După instalarea aplicației pe dispozitiv în meniul telefonului va putea fi observată următoarea pictogramă care corespunde aplicației „Skin Lesions” (figura 5.6):




Figura 5.6 Pictograma aplicației „Skin Lesions”

Din punct de vedere al arhitecturii, sistemul expert „Skin Lesions” conține și o interfață grafică (GUI) (Figura 5.7) ce facilitează analiza caracteristicilor imaginii digitale a leziunii cutanate necesare pentru calcularea scorului final (scorul total al dermoscopiei - TDS).

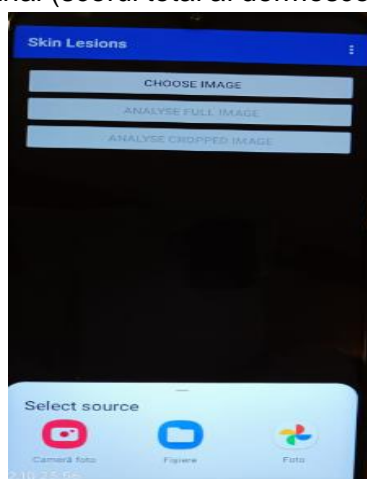


Figura 5.7 Interfața grafică (GUI) - aplicația „Skin Lesions”

Selectarea imaginii se poate face prin accesarea butonului *CHOOSE IMAGE*. Acesta are următoarele opțiuni:

➤ butonului *Camera foto* care va efectua o imagine digitală instant (figura 5.8);



Figura 5.8 Butonul Camera foto

➤ butonului *Fisier* care face posibil alegerea unei imagini digitale ce este salvată telefon sau în drive-ul propriu (figura 5.9);



Figura 5.9 Butonul *Fisier*

➤ butonului *Foto* care face posibil alegerea unei imagini digitale din telefonul mobil, de pe WhatsApp sau Messenger (figura 5.10).



Figura 5.10 Butonul *Foto*

După selectarea imaginii digitale a leziunii cutanate se poate analiza imaginea originală sau se analizează după ce se execută redimensionarea imaginii digitale prin ciupire (mărire și micșorare prin îndepărtarea a două degete sau prin apropierea celor două degete) (figura 5.11).

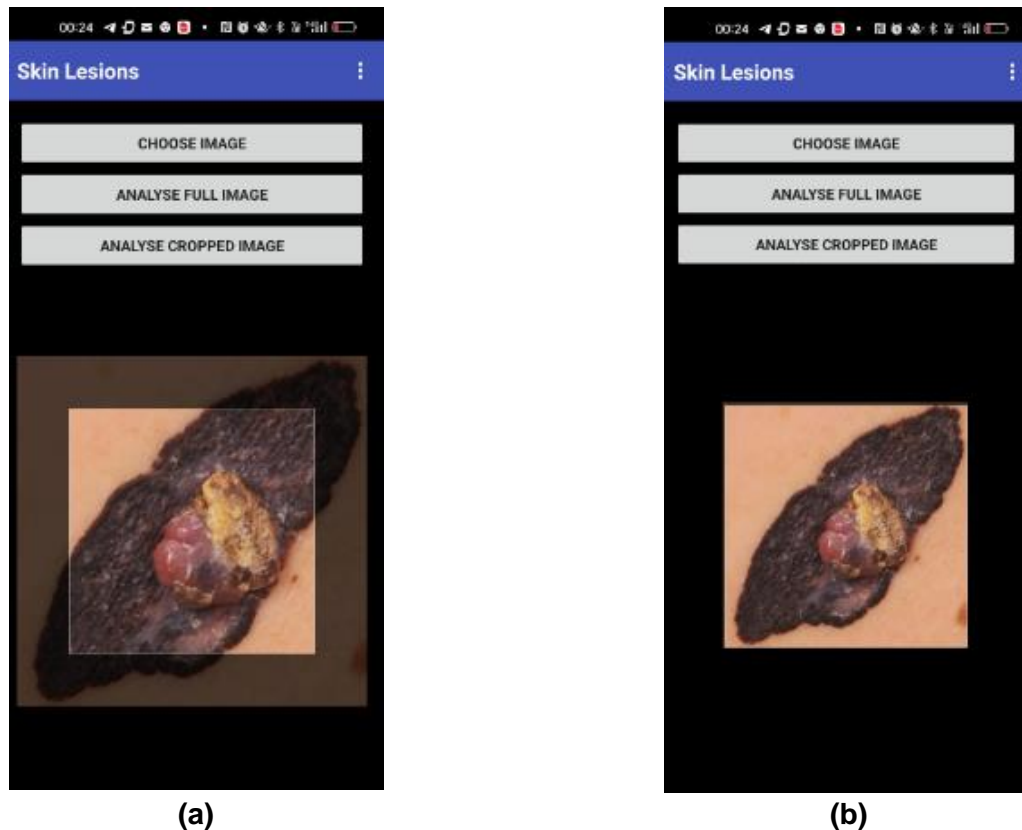


Figura 5.11 Fereastra interfeței grafice cu utilizatorul (GUI) cu imaginea digitală selectată.
(a) Imaginea originală; **(b)** Imaginea redimensionată

După alegerea imaginii, aceasta poate fi analizată. În urma analizei și în funcție de valoarea TDS se pot obține următoarele rezultate (figura 5.12):

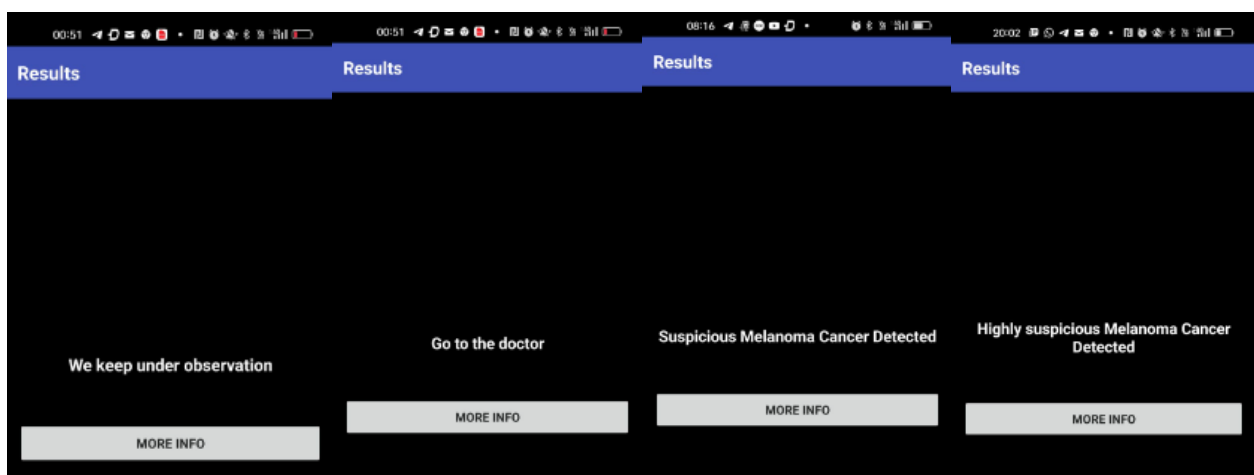
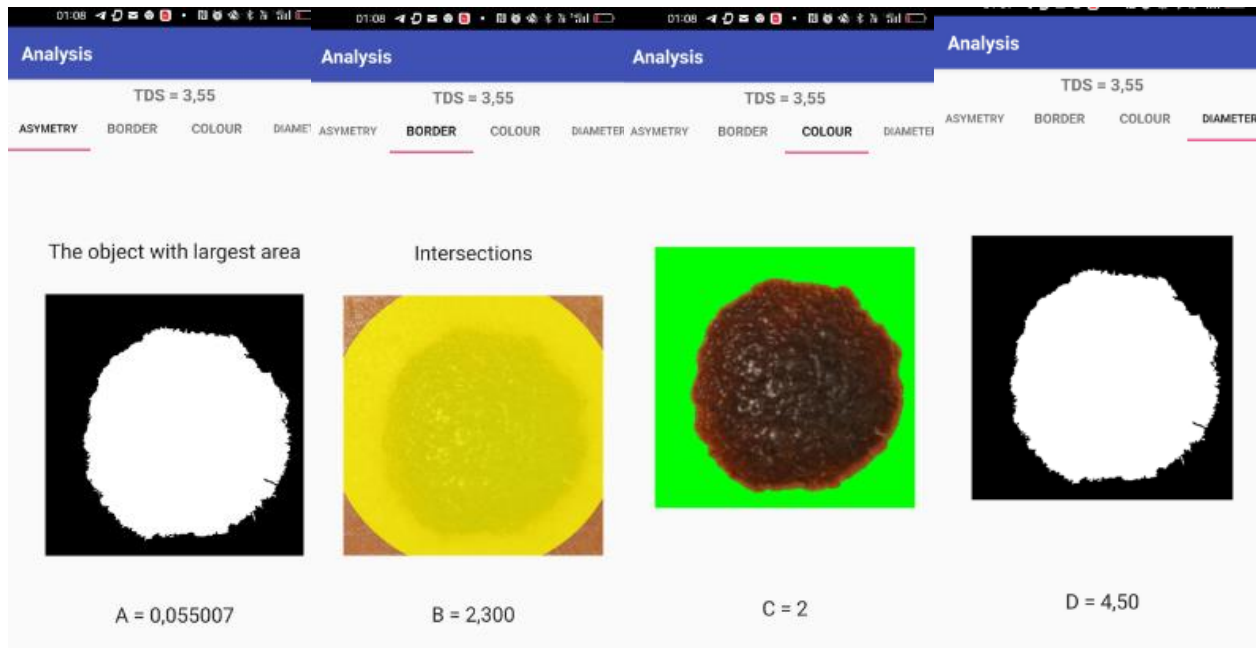


Figura 5.12 Fereastra interfeței grafice cu utilizatorul (GUI) cu mesajele obținute.
(a) Leziune melanocitică benignă; **(b)** Leziune ușor suspectă; **(c)** Leziune suspectă de a fi melanom; **(d)** Leziune cu un înalt grad de suspiciune de a fi melanom.

Dacă se dorește afișarea valorilor a caracteristicilor A, B, C, D și a scorului TDS se poate deschide butonul *More info* (figura 5.13).



(a) (b) (c) (d)

Figura 5.13 Fereastra interfeței grafice cu utilizatorul (GUI) cu rezultatele obținute.

(a) Asimetria; (b) Granița (bordura); (c) Culoarea; (d) Diametru.

Aceste rezultate arată cât de eficient se realizează detectarea melanomului și cum se realizează clasificarea leziunilor cutanate.

5.4 Contribuții originale

Contribuțiile originale la acest capitol se pot rezuma în felul următor:

- prezentarea și explicarea etapelor dezvoltării sistemului expert „**Skin Lesions**”;
- prezentarea metodologiei utilizate pentru dezvoltarea sistemelor expert „**Skin Lesions**”.

Pentru a evalua performanța modelului propus de diferențiere a leziunilor cutanate au fost utilizate 170 de imagini digitale color (70 de melanomuri și 100 de nevi) din Arhiva Digitală a Departamentului de Dermatologie al Centrului Medical Universitar din Groningen (UMCG). Tabelul 5.2 prezintă valorile medii ale măsurilor de performanță. Performanța a fost testată pe parametrii: sensibilitatea (SE), specificitate (SP), acuratețea (Acc) și precizia (P). Formulele de calcul a valorilor de evaluare menționate sunt prezentate în capitolul 2 (2.81 – 2.87). TP, TN, FP, FN reprezintă adevărat pozitiv, adevărat negativ, fals pozitiv și, respectiv, fals negativ. În funcție de valorile TDS imaginile din clasa melanom sunt considerate drept pozitive (TP) dacă leziunile cutanate sunt detectate corect, altfel sunt considerate fals negative (FN). În ceea ce privește imaginile din clasa nev sunt considerate adevărat negative (TN) dacă sunt precise ca nev, altfel sunt considerate fals pozitive (FP). Curbele ROC și AUC sunt ilustrate în figura 5.14.

În experiment, 80% din imagini sunt folosite pentru antrenament și 20% sunt folosite în scop de testare.

Tabelul 5.2 Valorile măsurilor de performanță.

TDS	TP	TN	FP	FN	SE (%)	SP (%)	ACC (%)	P (%)
MELANOM	46	117	3	4	92.00	97.50	95.88	93.88
NEV	71	90	4	5	93.42	95.74	94.71	94.67

Tabelul 5.2 indică o SE de 92% pentru melanom față de 93.42 % pentru nev, o SP de 97,50% pentru melanom față de 95.74 % pentru nev, o ACC de 95,88 % pentru melanom față de 94.71 % pentru nev, o P de 93,8 % pentru melanom față de 94.67 % pentru nev. În ceea ce privește SE, SP, ACC și P pentru imaginile analizate, arată o precizie echilibrată a clasificării corecte pentru melanom și nevi.

În figura 5.14 se prezintă valorile AUC din curbele ROC ce au valori cuprinse între 0,826 și 0,938 indicând o separare bună a celor două clase: nev și melanom.

Am apreciat valorile măsurilor de performanță a sistemului expert „Skin Lesions” ca media dintre cele două clase astfel obținând: pentru SE - 92.71 %, SP – 96.62 %, ACC – 95,29 %, P – 94,27%.




Figura 5.14 Curbele ROC și aria de sub AUC corespunzător valorilor TDS.
(a) pentru melanom; (b) pentru nev

Am comparat rezultatele obținute cu rezultatele evaluării clinice a riscurilor algoritmilor integrați din aplicații (tabelul 5.3). Se poate observa că algoritmul propus a obținut o îmbunătățire semnificativă a preciziei aplicației.

Tabelul 5.3 Compararea rezultatelor ale aplicației propuse cu cele ale aplicațiilor existente.

Aplicația	SE (%)	SP (%)
SkinVision [112]	73	83
Lübax [112]	90,4	91,5
SkinMD [212]	85,9	86
MelaFind [213]	82,5	52,4
FotoFinder Moleanalyzer Pro [213]	88,1	78,8
Verisante Aura [213]	21,4	86,2
Skin Lesions [propus]	92,71	96,62

Acuratețea aplicațiilor de detectare a leziunilor cutanate este măsurată prin calcularea sensibilității și specificității. Sensibilitatea cuantifică capacitatea aplicației de a diagnostica cu precizie prezența melanomului, în timp ce specificitatea reflectă capacitatea aplicației de a diagnostica cu precizie absența melanomului.

Această comparație demonstrează că cea mai mare sensibilitate și specificitate a instrumentelor au fost stabilite cu **Skin Lesions**, care ar putea fi un instrument valoros pentru a trage un semnal de alarmă, dar care nu înlocuiește luarea deciziilor clinice de către medicul specialist.

Această aplicație poate ajuta utilizatorii să fie mai atenți la îngrijirea sănătății și să îmbunătățească comunicarea dintre ei și medicii lor, dar este important ca utilizatorii să nu permită „aplicației să înlocuiască sfatul medicului și diagnosticul medicului”.

Capitolul 6

Concluzii generale și direcții viitoare de cercetare

Cercetările întreprinse în domeniul procesării imaginilor arată că domeniul are nevoie în continuare de idei novatoare, atât în ceea ce privește soluțiile software de prelucrate ale imaginilor dar și cele hardware care să achiziționeze imagini dermatoscopice digitale fără defecte, artefacte sau zgomot.

În cadrul acestei teze de doctorat am realizat o serie de algoritmi proprii a căror soluții software implementate se adaptează foarte bine pentru analiza și managementul leziunilor cutanate. Așadar, pot afirma că am îndeplinit cu succes obiectivul general propus.

Studiile citate în această teză au fost preluate după o cercetare atentă a literaturii folosind mai multe baze de date, și anume:

- IEEE Xplore (<http://ieeexplore.ieee.org/>);
- Springer Link(<http://link.springer.com/>);
- Science Direct (<http://www.sciencedirect.com/>);
- Wiley Online Library (<http://onlinelibrary.com/>);
- wiley.com/, Web of Science (<http://webofscience.com/>);
- PubMed (<http://www.ncbi.nlm.nih.gov/pubmed/>);
- Google Scholar (<https://scholar.google.com/>).

Metodele și algoritmi propuși au fost riguros validați și acceptați în literatura de specialitate prin lucrările științifice publicate în jurnale de prestigiu și comunicările realizate la conferințele naționale și internaționale.

Pentru realizarea tezei de doctorat am dezvoltat partea teoretică, partea metodologică și partea aplicativă ce reprezintă contribuții originale în domeniul cercetărilor care vizează realizarea unui sistem expert de evaluare a leziunilor cutanate. Astfel că:

➤ **Din punct de vedere al obiectivelor de cercetare:**

- în capitolul introducere, am identificat importanța dezvoltării unui sistem expert capabil să evalueze leziunile cutanate pe baza unui set de caracteristici corelate cu regulile de decizie folosite de specialistii medici dermatologi și am stabilit, în consecință, scopul și obiectivele de cercetare în cadrul prezentei teze. Am identificat posibilitatea de realizare și implementare a sistemului expert „**Skin Lesions**” practicabil pentru utilizatori de telefoane mobile.

➤ **Din punct de vedere al contribuțiilor practice și aplicative:**

- în capitolul 3 am realizat studii privind: analiza leziunilor cutanate cu caracteristici semnificative [193], studiul asimetriei leziunilor pielii utilizând rețelele neuronale artificiale [194], compararea măsurilor metrice de distanță pentru diferențierea leziunilor cutanate [195], selectarea caracteristicilor relevante din imaginile non-dermatoscopice în vederea clasificării nevilor vs. melanoame [196], influența spațiului de culoare asupra clasificării leziunilor cutanate folosind caracteristici statistice [197], algoritm de watermarking invizibil aplicat imaginilor dermatoscopice descompuse cu transformata wavelet discretă [195].

- în capitolul 4 am realizat studii privind: analiza leziunilor cutane cu algoritm de selectare a caracteristicilor geometrice [199], analiza histogramei de culoare pentru diferențierea leziunilor cutanate [197], clasificare clusterilor de culoare cu algoritmul kNN [198], clasificarea leziunilor cutanate pe baza dimensiunilor fractale de suprafață și a caracteristicilor statistice ale grupului de culori folosind un ansamblu de tehnici de învățare automată [202], diferențierea leziunilor cutanate utilizând algoritmul Random Forest (RF) [206].

- în capitolul 5 pentru asigurarea caracterului aplicativ al tezei am dezvoltat algoritmi necesari pentru determinarea caracteristicilor A, B, C, D ale leziunilor cutanate în vederea implementării sistemului expert „Skin Lesions”.

Se poate concluziona că este posibil să utilizăm un sistem expert de autoevaluare a leziunilor cutanate, implementat pe telefonul mobil, folosind analiza imaginilor și învățarea automată, astfel încât orice persoană cu un telefon mobil să îl poată utiliza. Acesta a fost obiectivul general al tezei de cercetare deși programele de analiză și clasificare a imaginilor de melanom au fost abordate și au primit soluții în mai multe lucrări în trecut, acestea nu sunt disponibile publicului, cu excepția aplicațiilor MelApp și Skin Scan menționate anterior, care sunt disponibile în prezent, contra cost.

Printre direcțiile viitoare de cercetare se pot identifica:

- testarea algoritmilor de clasificare a leziunilor cutanate pe alte imagini dermatoscopice digitale achiziționate cu un dispozitiv mobil. Această clasificare reprezintă primul pas în dezvoltarea unui Sistem Expert de diagnosticare și de evaluare a severității melanoamelor. Consider că avantajul major al acestei abordări este de a fi ieftină, rapidă, robustă și ușor de utilizat, cu foarte puține constrângeri privind protocolul de achiziție al imaginilor ce conțin melanoame;
- extinderea bazei de date de instruire ar ajuta predicțiile viitoare având în vedere că în prezenta teză, studiile s-au realizat pe imagini colectate din bazele de date dedicate dar care au folosit tehnici de achiziționare diferite (setările camerei, poziționare, condiții de iluminare etc.);
- adaptarea sistemului expert la mai multe sisteme de operare pentru smartphone-uri având în vedere că în prezent aplicația poate fi folosită doar pe telefoanele mobile cu sistemul de operare Android.

Lista lucrărilor publicate

Lucrări publicate în reviste cotate ISI

1. **Damian, F. A.**, Moldovanu, S., Dey, N., Ashour, A. S., Moraru, L., *Feature Selection of Non-Dermoscopic Skin Lesion Images for Nevus and Melanoma Classification*, MDPI, Journals Computation, Volume 8, 2020, Issue 2: 41, eISSN: 2079-3197, doi: 10.3390/computation8020041, <https://www.mdpi.com/2079-3197/8/2/41>, (IF=0, emerging) **11 citări.**
2. Moldovanu, S., **Damian Michis, F. A.**, Biswas, K. C., Culea-Florescu, A., Moraru, L., *Skin lesion classification based on surface fractal dimensions and statistical color cluster features using an ensemble of machine learning techniques*, Cancers, Volume 13, 2021, Issue 21: 5256, eISSN: 2072-6694, doi:10.3390/cancers13215256, <https://www.mdpi.com/2072-6694/13/21/5256>, (IF=6,639 Clarivate) **8 citări.**

Lucrări publicate în volume ISI Proceedings

1. Moldovanu, S., Stefanescu, D., Damian, A. F., *Watermarking skin lesion digital color images based on channels*, 24th International Conference on System Theory, Control and Computing (ICSTCC), Sinaia, Romania, 2020, Pages 933-936, ISSN: 2372-1618 doi: 10.1109/ICSTCC50638.2020.9259631, <https://ieeexplore.ieee.org/document/9259631>
2. **Damian, F. A.**, Moldovanu, S., Moraru, L., *Skin Lesions Asymmetry Estimation Using Artificial Neural Networks*, 25th International Conference on System Theory, Control and Computing (ICSTCC), Iași, România, 2021, Pages 64-67, ISSN: 2372-1618, doi: 10.1109/ICSTCC52150.2021.9607133, <https://ieeexplore.ieee.org/document/9607133>
3. **Felicia Anișoara Damian**, Simona Moldovanu, Luminița Moraru, *Melanoma Detection using a Random Forest Algorithm*, The 10th IEEE International Conference on E-Health and Bioengineering - EHB 2022, Grigore T. Popa University of Medicine and Pharmacy, 17-19 November 2022, Iași, Romania, ISSN: 2575-5145, doi: 10.1109/EHB55594.2022.9991668, <https://ieeexplore.ieee.org/document/9991668>

Lucrări publicate în volume ale conferințelor internaționale

1. **Felicia Anișoara Damian**, Simona Moldovanu, Luminița Moraru, *Skin lesions analysis based on significant features selection algorithm*, 8th International Conference on Experiments/ Process/System/ Modeling/ Simulation/ Optimization (IC-EPSMSO), 3-6 July 2019, Athens, Greece, Pages 380-387, ISSN: 2241-9209, https://www.researchgate.net/publication/349806616_IC-EPSMSO_8thInternational_Conference_on_Experiments_Process_System_Modeling_Simulation_Optimization_ProceedingsVOLUME_II_Pages_200-475
2. **Damian, F. A.**, Moldovanu, S., & Moraru, L., *Colour histogram analysis for skin lesions discrimination*, SGEM Conference Proceedings: 19th International Multidisciplinary Scientific GeoConference SGEM 2019, Section Advances in Biotechnology, 9 - 11 December 2019, Vienna, Austria, Volume 19, Issue 6.3, Pages 75-82, doi:10.5593/sgem2019V/ 6.3/S08.010, <https://search.proquest.com/docview/2348209566/C48A0D4612324515PQ/2>
3. S. Moldovanu, **F. A. Damian**, L. Moraru, *A kNN approach for melanoma diagnosis based on color cluster features*, 3rd International Conference on Advances in Signal Processing and Artificial

Intelligence (ASPAI' 2021), 17-19 November 2021, Porto, Portugal, Pages 6-8, eISSN: 978-84-09-35865-6,

https://www.sensorsportal.com/ASPAI_2021/ASPAI_2021_Conference_Proceedings.pdf

Lucrări publicate în reviste cotate BDI

1. Moraru, L., **Damian, F. A.**, Moldovanu, S., *Analysis of Common Melanomas and Nevi Using Geometrical Features*, Annals of "Dunarea De Jos" University Of Galati Mathematics, Physics, Theoretical Mechanics, Fascicle II, YEAR XI(XLII) 2019, Volume 42, No. 1, Pages 27- 33, <https://doi.org/10.35219/ann-ugal-math-phys-mec.2019.1.04>

2. **Damian, F. A.**, Moldovanu, S. and Moraru, L., *Comparison of distance metric measures in differentiation of non - dermoscopic skin lesions*, Annals Of "Dunarea De Jos" University of Galati Mathematics, Physics, Theoretical Mechanics, Fascicle II, YEAR XII(XLIII) 2020, Volume 43, No. 1, Pages 20- 27, <https://doi.org/10.35219/ann-ugal-math-phys-mec.2020.1.03>

3. **Damian, F.**, Moldovanu, S., Moraru, L., *Color space influence on ANN skin lesion classification using statistics texture feature*, Annals of the "Dunarea de Jos" University of Galati. Fascicle II, Mathematics, Physics, Theoretical Mechanics, YEAR XIII(XLIV) 2021 Volume 44, No.1, Pages 53-62. <https://doi.org/10.35219/ann-ugal-math-phys-mec.2021.1.08>

Lucrări comunicate la conferințe naționale și internaționale

1. **Damian Felicia Anișoara**, Moldovanu Simona, Moraru Luminița, *Analizarea nevilor pe baza caracteristicilor semnificative*, Conferința științifică: "Fizica medicală: simbioză între Fizică, Medicină și Mediu", 28 Februarie 2019, Galați, Secțiunea 1: Fizică medicală; aplicații ale Fizicii în Medicină,

https://www.ugal.ro/files/stiri%20si%20evenimente/programconferintaFizica_medicala2019.pdf

2. Luminița Moraru, **Felicia Anișoara Damian**, Simona Moldovanu, *Analysis of Common Melanomas and Nevi Using Geometrical Features*, Scientific Conference of Doctoral Schools from "Dunărea de Jos" University of Galati (SCDS-UDJG 2019), 7th Edition, 13th-14th of June 2019, Galați, Section 2. Advanced investigation methods in environment and biohealth,

http://www.cssd-udjg.ugal.ro/files/2019/Program_detaliat_al_conferintei_nou.pdf

3. **Damian Felicia Anișoara**, Moldovanu Simona, Moraru Luminița, *Skin lesions analysis based on significant features selection algorithm*, 8th International Conference on Experiments/ Process/System/ Modeling/ Simulation/ Optimization, 3-6 July, Athens, Greece,

<https://lfme.gr/8th-ic-epsmsso-program/#1645452905480-7ab7aae2-2cc5>

4. **Felicia Anișoara Damian**, Simona Moldovanu, Luminita Moraru, *Colour histogram analysis for skin lesions discrimination*, 19th International Multidisciplinary Scientific GeoConference SGEM, Section Advances in Biotechnology, 9 - 11 December 2019, Vienna, Austria,

https://www.sgemviennagreen.org/images/deadlines/conference_programme/Day2Programme_POSTER.pdf

5. **Felicia Anișoara Damian**, Simona Moldoveanu, Luminița Moraru, *Comparison of distance metric measures in differentiation of non-dermoscopic skin lesions*, Scientific Conference of Doctoral Schools from "Dunărea de Jos" University of Galati SCDS-UDJG, 8th Edition, 18th -19th of June 2020, Galați, Section 2. Advanced investigation methods in environment and biohealth,

http://www.cssd-udjg.ugal.ro/files/2020/program/CSSD_Section2_Program_2020_draft.pdf

6. Moldovanu, S., **Damian, F. A.**, Pană, L., Moraru, L., *Machine Learning and Artificial Intelligence for health monitoring*, International Conference Environmental Challenges in the Black Sea Basin: Impact on Human Health, 23 – 26 September 2020, Galati, Romania, Pages 47-47a,

https://ibn.idsi.md/vizualizare_articol/115939

7. **Damian, F.**, Moldovanu, S., Moraru, L., *Color space influence on ANN skin lesion classification using statistics texture feature*, Scientific Conference of Doctoral Schools from “Dunărea de Jos” University of Galati SCDS-UDJG, 9th Edition, 10th- 11th of June 2021, Galați, Section 2. Advanced investigation methods in environment and biohealth, <http://www.cssd-udjg.ugal.ro/index.php/2020-2/programme-22>
8. S. Moldovanu, **F. A. Damian**, L. Moraru, *A kNN approach for melanoma diagnosis based on color cluster features*, 3rd International Conference on Advances in Signal Processing and Artificial Intelligence (ASPAI' 2021), 17-19 November 2021, Porto, Portugal, https://www.sensorsportal.com/ASPAI_2021/ASPAI_2021_Conference_Programme.pdf
9. **F. A. Damian**, S. Moldovanu, L. Moraru, *Skin Lesions Asymmetry Estimation Using Artificial Neural Networks*, 25th International Conference on System Theory, Control and Computing (ICSTCC), Iași, România, 2021, https://icstcc2021.ac.tuiasi.ro/wp-content/uploads/2021/10/Book-of-Abstracts-ICSTCC-2021_V5-online.pdf
10. **Felicia Anișoara Damian**, Simona Moldovanu, Luminița Moraru, *Melanoma Detection using a Random Forest Algorithm*, The 10th IEEE International Conference on E-Health and Bioengineering - EHB 2022, Grigore T. Popa University of Medicine and Pharmacy, 17-19 November 2022, Iași, Romania, http://www.ehbconference.ro/Portals/18/EHB2022_Detailed_Program.pdf

Citări

Damian, F. A., Moldovanu, S., Dey, N., Ashour, A. S., Moraru, L., *Feature Selection of Non-Dermoscopic Skin Lesion Images for Nevus and Melanoma Classification*, MDPI, Journals Computation, Volume 8, 2020, Issue 2: 41, eISSN: 2079-3197, doi:10.3390/computation8020041, <https://www.mdpi.com/2079-3197/8/2/41> (IF=0, emerging).

Citat de:

1. Ashour, A. S., Nagieb, R. M., El-Khobby, H. A., Abd Elnaby, M. M., & Dey, N, *Genetic algorithm-based initial contour optimization for skin lesion border detection*, Multimedia Tools and Applications, Volume 80, 2020, Issue 2, Pages 2583-2597, eISSN: 1573-7721, doi: 10.1007/s11042-020-09792-8, <https://dl.acm.org/doi/abs/10.1007/s11042-020-09792-8>
2. Srivastava, R., Ong, E. P., Lee, B. H., Tan, L. S., Tey, H. L., *Quantitative Comparison of Color Asymmetry Features for Automatic Melanoma Detection*, 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), 2021, Pages 3753-3756, eISSN:1558-4615, doi: 10.1109/EMBC46164.2021.9631103, <https://ieeexplore.ieee.org/document/9631103>
3. Hu, L., Chen, Q., Qiao, L., Du, L., Ye, R., *Automatic Detection of Melanins and Sebums from Skin Images Using a Generative Adversarial Network*, Cognitive Computation, Volume 14, 2022, Issue 5, Pages 1599-1608, eISSN: 1866-9964, doi: 10.1007/s12559-021-09870-5, <https://link.springer.com/article/10.1007/s12559-021-09870-5>
4. Moldovanu, S., Obreja, C. D., Biswas, K. C., Moraru, L., *Towards Accurate Diagnosis of Skin Lesions Using Feedforward Back Propagation Neural Networks*, Diagnostics, Volume 11, 2021, Issue 6: 936, Pages 1-16, eISSN: 1573-7721, doi: 10.3390/diagnostics11060936, <https://www.mdpi.com/2075-4418/11/6/936>
5. Barhoumi, W., Khelifa, A., *Skin lesion image retrieval using transfer learning-based approach for query-driven distance recommendation*, Computers in Biology and Medicine, Volume 137, 2021, 104825, eISSN: 1879-0534, doi: 10.1016/j.combiomed.2021.104825,

<https://www.sciencedirect.com/science/article/abs/pii/S0010482521006193?via%3Dihub>

6. Mello-Román, J.C., Vázquez Noguera, J.L., Legal-Ayala, H., García-Torres, M., Facon, J., Pinto-Roa, D.P., Grillo, S.A., Salgueiro Romero, L., Salgueiro Toledo, L.A., Bareiro Paniagua, L.R. and Leguizamon Correa, D.N., *Dermoscopy Images Enhancement via Multi-Scale Morphological Operations*, Applied Sciences, Volume 11, 2021, Issue 19: 9302, Pages 1-16, eISSN: 2076-3417, doi: 10.3390/app11199302, <https://www.mdpi.com/2076-3417/11/19/9302>

7. Wang, J., Yan, Y., Kim, J., *Classification of melanoma images using 2D multifractal detrended cross-correlation analysis*, Modern Physics Letters B, Volume 36, 2022, Issue 09: 2150619, eISSN: 1793-6640, doi:10.1142/S0217984921506193,

<https://www.worldscientific.com/doi/abs/10.1142/S0217984921506193>

8. Anghelache Nastase, I. N., Moldovanu, S., Moraru, L., *Image Moment-Based Features for Mass Detection in Breast US Images via Machine Learning and Neural Network Classification Models*, Inventions, Volume 7, 2022, Issue 2: 42, eISSN: 2411-5134, doi: 10.3390/inventions7020042, <https://www.mdpi.com/2411-5134/7/2/42>

9. Gulzar, Y., & Khan, S. A., *Skin Lesion Segmentation Based on Vision Transformers and Convolutional Neural Networks-A Comparative Study*, Applied Sciences, Volume 12, 2022, Issue 12: 5990, eISSN: 2076-3417, doi: 10.3390/app12125990,

<https://www.mdpi.com/2076-3417/12/12/5990>

10. Radhika, V., & Chandana, B. S., *Skin Melanoma Classification from Dermoscopy Images using ANU-Net Technique*, International Journal of Advanced Computer Science and Applications, Volume 13, 2022, Issue 10, ISSN: 2158-107X, doi: 10.14569/IJACSA.2022.01310109,

https://thesai.org/Downloads/Volume13No10/Paper_109-Skin_Melanoma_Classification_from_Dermoscopy_Images.pdf

11. Hasan, M. K., Ahamad, M. A., Yap, C. H., & Yang, G., *A survey, review, and future trends of skin lesion segmentation and classification*, Computers in biology and medicine, Volume 155, 2023, ISSN: 0010-4825, doi:10.1016/j.compbimed.2023.106624,

<https://arxiv.org/abs/2208.12232>

Moldovanu, S., **Damian Michis, F. A.**, Biswas, K. C., Culea-Florescu, A., Moraru, L., *Skin lesion classification based on surface fractal dimensions and statistical color cluster features using an ensemble of machine learning techniques*, Cancers, Volume 13, 2021, Issue 21: 5256, eISSN: 2072-6694, doi: 10.3390/cancers13215256, <https://www.mdpi.com/2072-6694/13/21/5256> (IF=6,639 Clarivate).

Citat de:

1. Kara, A. C., Hardalaç, F., *Detection and Classification of Knee Injuries from MR Images Using the MRNet Dataset with Progressively Operating Deep Learning Methods*, Machine Learning and Knowledge Extraction, Volume 3, 2021, Issue 4, Pages 1009-1029, eISSN: 2504-4990, doi: 10.3390/make3040050, <https://www.mdpi.com/2504-4990/3/4/50>

2. Anghelache Nastase, I. N., Moldovanu, S., Moraru, L., *Image Moment-Based Features for Mass Detection in Breast US Images via Machine Learning and Neural Network Classification Models*, Inventions, Volume 7, 2022, Issue 2: 42, eISSN: 2411-5134, doi: 10.3390/inventions7020042, <https://www.mdpi.com/2411-5134/7/2/42>

3. Li, S., Wang, H., Xiao, Y., Zhang, M., Yu, N., Zeng, A., & Wang, X., *A Workflow for Computer-Aided Evaluation of Keloid Based on Laser Speckle Contrast Imaging and Deep Learning*, Journal of Personalized Medicine, Volume 12, 2022, Issue 6: 981, eISSN: 2075-4426, doi:

10.3390/jpm12060981, <https://www.mdpi.com/2075-4426/12/6/981>

4. Popecki, P., Kozakiewicz, M., Ziętek, M., & Jurczyszyn, K., *Fractal Dimension Analysis of Melanocytic Nevi and Melanomas in Normal and Polarized Light-A Preliminary Report*, Life-Basel, Volume 12, 2022, Issue 7: 1008, eISSN: 2075-1729, doi: 10.3390/life12071008, <https://www.mdpi.com/2075-1729/12/7/1008>

5. Hussain, A., Alam, S., Ghauri, S.A., Ali, M., Sherazi, H.R., Akhunzada, A., Bibi, I., Gani, A., *Automatic Modulation Recognition Based on the Optimized Linear Combination of Higher-Order Cumulants*, Sensors, Volume 22, 2022, Issue 19: 7488, eISSN: 1424-8220, doi: 10.3390/s22197488, <https://www.mdpi.com/1424-8220/22/19/7488>

6. Panthakkan, A., Anzar, S.M., Jamal, S., Mansoor, W., *Concatenated Xception-ResNet50-A novel hybrid approach for accurate skin cancer prediction*, Computers in Biology and Medicine, Volume 150, 2022, 106170, eISSN: 1879-0534, doi: 10.1016/j.combiomed.2022.106170,

<https://www.sciencedirect.com/science/article/abs/pii/S0010482522008782?via%3Dihub>

7. Maiti, A., Sultana, M. and Bhattacharya, S., *Detection of skin cancer through hybrid color features and soft voting ensemble classifier*, Innovations in Systems and Software Engineering, 2022, Pages 1-14, eISSN: 1614-5054,

<https://link.springer.com/article/10.1007/s11334-022-00498-8>

8. Hasan, M. K., Ahamad, M. A., Yap, C. H., & Yang, G., *A survey, review, and future trends of skin lesion segmentation and classification*, Computers in biology and medicine, Volume 155, 2023, ISSN: 0010-4825, doi:10.1016/j.combiomed.2023.106624,

<https://arxiv.org/abs/2208.12232>

Bibliografie selectivă

- [36] M. E. Celebi, N. Codella, A. Halpern, *Dermoscopy Image Analysis: Overview and Future Directions*, IEEE Journal of Biomedical and Health Informatics, Volume 23, 2019, Issue 2, Pages 474–478, eISSN 2168-2208, doi: 10.1109/JBHI.2019.2895803, <https://pubmed.ncbi.nlm.nih.gov/30703051/>;
- [37] A. W. Choi, R. S. Xu, S. Jacob, B. O. Dulmage, M. L. Colavincenzo, J. K. Robinson, S. Xu, *Visual perception training: a prospective cohort trial of a novel, technology-based method to teach melanoma recognition*, Postgraduate Medical Journal, Volume 95, 2019, Issue 1124, Pages 350-352, eISSN 1469-0756, doi: 10.1136/postgradmedj-2018-136379 <https://pubmed.ncbi.nlm.nih.gov/31266882/>;
- [38] D. Coppola, H. K. Lee, C. Guan, *Interpreting mechanisms of prediction for skin cancer diagnosis using multi-task learning*, Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, WA, USA, 2020, Pages 3162-3171, doi: 10.1109/CVPRW50498.2020.00375, <https://ieeexplore.ieee.org/document/9150967>;
- [39] S. W. Menzies, C. Ingvar, K. A. Crotty, W. H. McCarthy, *Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features*, Archives of dermatology, Volume 132, 1996, Issue 10, Pages 1178–1182, ISSN 0003-987X, <https://pubmed.ncbi.nlm.nih.gov/8859028/>;
- [40] J. S. Henning, S. W. Dusza, S. Q. Wang, A. A. Marghoob, H. S. Rabinovitz, D. Polsky, A. W. Kopf, *The CASH (color, architecture, symmetry, and homogeneity) algorithm for dermoscopy*, Journal of the American Academy of Dermatology, Volume 56, 2007, Issue 1, Pages 45-52, eISSN 1097-6787, doi: 10.1016/j.jaad.2006.09.003, <https://pubmed.ncbi.nlm.nih.gov/17190620/>;
- [41] R. Ramji, G. Valdes-Gonzalez, A. Oakley, M. Rademaker, *Dermoscopic ‘Chaos and Clues’ in the diagnosis of melanoma in situ*, Australas Journal Dermatology, Volume 59, 2018, Issue 3, Pages 201–205, eISSN 1440-0960, doi: 10.1111/ajd.12740, <https://pubmed.ncbi.nlm.nih.gov/29094749/>;
- [42] P. Bourne, C. Rosendahl, J. Keir, A. Cameron, *BLINCK-A diagnostic algorithm for skin cancer diagnosis combining clinical features with dermatoscopy findings*, Dermatology Practical & Conceptual, Volume 2, 2012, Issue 2, Pages 202a12, eISSN 2160-9381, doi: 10.5826/dpc.0202a12, <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3663344/>;
- [85] N. Otsu, *A Threshold Selection Method from Gray-Level Histograms*, Transactions on Systems, Man, and Cybernetics, Volume 9, 1979, Issue 1, Pages 62-66, eISSN: 2168-2909, doi: 10.1109/TSMC.1979.4310076, <https://ieeexplore.ieee.org/document/4310076>;
- [116] ***, https://download.cnet.com/DermLite/3000-2129_4-76936578.html;
- [117] ***, <https://hub.fotofinder.de>;
- [118] ***, <https://apps.apple.com/us/app/skin-cancer-app-myskinpal-map-your-skin-moles/id955071565>;
- [119] ***, <https://apps.apple.com/ca/app/molescope/id1003576096>
- [120] ***, <https://appadvice.com/app/apreskin-you-track-your-moles-skin-cancers-melanoma/1131517287>;
- [121] ***, <https://apps.apple.com/us/app/derma-analytics/id1174696625>;
- [122] ***, <https://miiskin.com>;
- [123] ***, <https://apkpure.com/apd-skin-monitoring-app/apd.bii.wound>;
- [124] ***, <https://www.skinvision.com>;

- [125] A. Udrea, M. Tanase, D. Popescu, *Nonlinear deterministic methods for computer aided diagnosis in case of kidney diseases*, 9th International Conference on Informatics in Control, Automation and Robotics, Rome, Italy, Volume 1, 2012, Pages 511–516, <https://pdfs.semanticscholar.org/29ac/2b0f2fb8922584a0cf282db9b3eec02f431e.pdf>;
- [126] T. Maier, D. Kulichova, K. Schotten, R. Astrid, T. Ruzicka, C. Berking, A. Udrea, *Accuracy of a smartphone application using fractal image analysis of pigmented moles compared to clinical diagnosis and histological result*, Journal of the European Academy of Dermatology and Venereology, Volume 29, 2015, Issue 4, Pages 663-667, ISSN 1468-3083, doi: 10.1111/jdv. 12648, <https://pubmed.ncbi.nlm.nih.gov/25087492/>;
- [127]***, <https://skinmdnow.com/freeapp.html>;
- [162] U.K. Acharya, S. Kumar, *Directed searching optimized mean-exposure based sub-image histogram equalization for grayscale image enhancement*, Multimedia Tools and Applications, Volume 80, 2021, Issue 16, Pages 24005–24025, ISSN 1380-7501, doi: 10.1007/s11042-021-10855-7, <https://link.springer.com/article/10.1007/s11042-021-10855-7>;
- [163] H. Chugh, S. Gupta, M. Garg, D. Gupta, S. Juneja, H. Turabieh, Y. Na, Z. Kiros Bitsue, *Image Retrieval Using Different Distance Methods and Color Difference Histogram Descriptor for Human Healthcare*, Journal of Healthcare Engineering, Volume 2022, 2022, Pages 1-10, ISSN 2040-2295, doi:10.1155/2022/9523009, <https://www.hindawi.com/journals/jhe/2022/9523009/>
- [164] V. Rajinikantha, M. S. Couceirob, *RGB Histogram based Color Image Segmentation Using Firefly Algorithm*, Procedia Computer Science, Volume 46, 2015, Pages 1449-1457, ISSN 1877-0509, doi:10.1016/j.procs.2015.02.064, <https://www.sciencedirect.com/science/article/pii/S1877050915001283>;
- [167] G.Tzortzis, A. Likas, *The MinMax k-Means clustering algorithm*, Pattern recognition, Volume 47, 2014, Issue 7, Pages 2505-2516, ISSN 0031-3203, doi: 10.1016/j.patcog.2014.01.015, <https://www.sciencedirect.com/science/article/pii/S0031320314000338>;
- [168] X. Liu, L. Song, S. Liu, Y. Zhang, *A Review of Deep-Learning-Based Medical Image Segmentation Methods*, Sustainability, Volume 13, 2021, Issue 3: 1224, Pages 1-29, ISSN 2071-1050, doi: 10.3390/su13031224, <https://www.mdpi.com/2071-1050/13/3/1224>;
- [172] D. J. Bora, A. K. Gupta, *A new approach towards clustering based color image segmentation*, International Journal of Computer Applications, Volume 107, 2014, Issue 12, Pages 23-30, ISSN 0975 –8887, doi: 10.5120/18803-0329, <https://research.ijcaonline.org/volume107/number12/pxc3900329.pdf>;
- [173] M. R. Ferreira, F. D. A. De Carvalho, *Kernel fuzzy c-means with automatic variable weighting*, Fuzzy Sets and Systems, Volume 237, 2014, Pages 1–46, ISSN 0165-0114, doi: 10.1016/j.fss.2013.05.004, <https://www.sciencedirect.com/science/article/pii/S0165011413002054>;
- [174] K. Rajkumar, A. Yesubabu, K. Subrahmanyam, *Fuzzy clustering and Fuzzy C-Means partition cluster analysis and validation studies on a subset of CiteScore dataset*, International Journal of Electrical and Computer Engineering, Volume 9, 2019, Issue 4, Pages 2760-270, ISSN: 2088-8708, doi: 10.11591/ijece.v9i4.pp2760-2770, <https://www.mendeley.com/catalogue/4e436394-dd3c-3e2a-9a5f-1900ab10368a/>;
- [175] Z. H. Hoo, J. Candlish, D. Teare, *What is an ROC curve?*, Emergency Medicine Journal, Volume 34, 2017, Issue 6, Pages 357-359, ISSN 1472-0205, doi: 10.1136/emj-2017-206735, <https://emj.bmj.com/content/emj/34/6/357.full.pdf>;
- [176] N. A. Obuchowski, J. A. Bullen, *Receiver operating characteristic (ROC) curves: review of methods with applications in diagnostic medicine*. Physics in medicine and biology, 2018

- Mar Volume 63, Issue 7, Pages 07TR01, ISSN 1361-6560, doi: 10.1088/1361-6560/aab4b1,
<https://dx.doi.org/10.1088/1361-6560/aab4b1>;
- [177] D. İlhan Topcu, H. Can Çubukçu, *Optimization of patient-based real-time quality control based on the Youden index*, Clinica Chimica Acta, Volume 534, 2022, Pages 50-56, ISSN 0009-8981, doi: 10.1016/j.cca.2022.06.028,
<https://www.sciencedirect.com/science/article/pii/S0009898122012189>;
- [178] M. W. Browne, *Cross-validation methods*, Journal of mathematical psychology, Volume 44, 2000, Issue 1, Pages 108-132, ISSN 0022-2496, doi: 10.1006/jmps.1999.1279,
<https://www.sciencedirect.com/science/article/pii/S0022249699912798>;
- [179] C. Bergmeir, R. J. Hyndman, B. Koo, *A note on the validity of cross-validation for evaluating autoregressive time series prediction*, Computational Statistics & Data Analysis, Volume 120, 2018, Pages 70–83, ISSN 0167-9473, doi: 10.1016/j.csda.2017.11.003,
<https://www.sciencedirect.com/science/article/pii/S0167947317302384>;
- [180] F. M. Bayer, F. Cribari-Neto, *Model selection criteria in beta regression with varying dispersion*, Communications in Statistics-Simulation and Computation, Volume 46, 2017, Issue 1, Pages 729-746, ISSN 1532-4141, doi: 10.1080/03610918.2014.977918,
<https://doi.org/10.1080/03610918.2014.977918>;
- [181] N. Khasawneh, M. Fraiwan, L. Fraiwan, B. Khassawneh, A. Ibnian, *Detection of COVID-19 from Chest X-ray Images Using Deep Convolutional Neural Networks*, Sensors, Volume 21, 2021, Issue 17, Pages 5940, doi: 10.3390/s21175940, ISSN 1424-8220,
<https://europepmc.org/articles/PMC8434649>;
- [182] H. Ullah, M. Bhuiyan, *Performance Evaluation of Feed Forward Neural Network for Image Classification*, Journal of Science and Technology, Volume 10, 2018, Issue 1, Pages 19-27, doi:10.30880/jst.2018.10.01.004
https://www.researchgate.net/publication/325258560_Performance_Evaluation_of_Feed_Forward_Neural_Network_for_Image_Classification;
- [183] L. Abdel-Ilah, H. Šahinbegović, *Using machine learning tool in classification of breast cancer*, International Conference on Medical and Biological Engineering (CMBEBIH), Sarajevo, Volume 62, 2017, Pages 3-8, ISBN 978-981-10-4166-2, doi: 10.1007/978-981-10-4166-2_1,
https://link.springer.com/chapter/10.1007/978-981-10-4166-2_1;
- [184] R. Kaur, H. GholamHosseini, R. Sinha, M. Lindén, *Melanoma Classification Using a Novel Deep Convolutional Neural Network with Dermoscopic Images*, Sensors, Volume 22, 2022, Issue 3: 1134, doi:10.3390/s22031134, ISSN 1424-8220,
<http://europepmc.org/article/MED/35161878>;
- [185] D. S. K. Karunasingha, *Root mean square error or mean absolute error? Use their ratio as well*, Information Sciences, Volume 585, 2022, Pages 609-629, ISSN 0020-0255, doi: 10.1016/j.ins.2021.11.036,
<https://www.sciencedirect.com/science/article/pii/S0020025521011567>;
- [186] A. Alexandridis, E. Chondrodima, *A medical diagnostic tool based on radial basis function classifiers and evolutionary simulated annealing*, Journal of biomedical informatics, Volume 49, 2014, Pages 61-72, ISSN 1532-0464, doi:10.1016/j.jbi.2014.03.008,
<https://www.sciencedirect.com/science/article/pii/S1532046414000653>;
- [187] A. H. Fath, F. Madanifar, M. Abbasi, *Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems*, Petroleum, Volume 6, 2020, Issue 1, Pages 80-91, ISSN 2405-6561, doi:10.1016/j.petim.2018.12.002,
<https://www.sciencedirect.com/science/article/pii/S2405656118301020>;

- [188] M. R. Bonyadi, Q. M. Tieng, D. C. Reutens, *Optimization of Distributions Differences for Classification*, IEEE Transactions on Neural Networks and Learning Systems, Volume 30, 2018, Issue 2, Pages 511-523, eISSN 2162-2388, doi: 10.1109/TNNLS.2018.2844723, <https://ieeexplore.ieee.org/document/8401711>;
- [189] Z. Tembusai, H. Mawengkang, M. Zarlis, *K-Nearest Neighbor with K-Fold Cross Validation and Analytic Hierarchy Process on Data Classification*, International Journal of Advances in Data and Information Systems, Volume 2, 2021, Issue 1, Pages 1-8, ISSN 2721-3056, doi: 10.25008/ijadis.v2i1.1204, <https://media.neliti.com/media/publications/396954-k-nearest-neighbor-with-k-fold-cross-val-1a5c3b3f.pdf>;
- [212] A. Tyagi, K. Miller, M. Cockburn, *e-Health Tools for targeting and improving melanoma screening: a review*, Journal of skin cancer, Volume 2012, 2012, Pages 1-8, ISSN 2090-2913, doi: 10.1155/2012/437502 <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3530856>;
- [213] A. N. MacLellan, E. L. Price, P. Publicover-Brouwer, K. Matheson, T. Y.Ly, S. Pasternak, N. M. Walsh, C. J. Gallant, A. Oakley, P. R. Hull, R. G. Langley, *The use of noninvasive imaging techniques in the diagnosis of melanoma: a prospective diagnostic accuracy study*, Journal of the American Academy of Dermatology, Volume 85, 2021, Issue 2, Pages 353-359, ISSN 0190-9622, doi: 10.1016/j.jaad.2020.04.019, <https://www.sciencedirect.com/science/article/pii/S0190962220305594>;

Axa prioritară 6- Educație și competențe

Titlul proiectului: „Program pentru creșterea performanței și inovării în cercetarea doctorală și postdoctorală de excelență - PROINVENT”

Contract nr: 62487/03.06.2022 POCU/993/6/13 - Cod SMIS: 153299

Punctele de vedere exprimate în lucrare aparțin autorului și nu angajează Comisia Europeană și Universitatea „Dunărea de Jos” din Galați, beneficiara proiectului.