



Universitatea Națională de Știință și Tehnologie
POLITEHNICA București
ȘCOALA DOCTORALĂ ELECTRONICĂ
TELECOMUNICAȚII ȘI TEHNOLOGIA INFORMAȚIEI



Nr. Decizie 73 din 04.07.2024

REZUMAT

TEZĂ DE DOCTORAT

SISTEM INFORMATIC MEDICAL CU MODUL
AUTOMAT DE CLASIFICARE PATOLOGII

MEDICAL INFORMATION SYSTEM WITH
AUTOMATIC PATHOLOGY CLASSIFICATION
MODULE

Doctorand: **Ing. Ana-Maria Ștefan**

COMISIA DE DOCTORAT

Prof. Dr. Ing. Ion Marghescu

Universitatea Națională de Știință și Tehnologie POLITEHNICA București **Președinte**

Prof. Dr. Ing. Mihai Ciuc

Universitatea Națională de Știință și Tehnologie POLITEHNICA București **Conducător de doctorat**

Prof. Dr. Ing. Marius Dan Dobrea

Universitatea Tehnică „Gheorghe Asachi” din Iași **Referent**

Prof. Dr. Ing. Cristian Grava

Universitatea din Oradea **Referent**

Conf. Dr. Ing. Alina Sultana

Universitatea Națională de Știință și Tehnologie POLITEHNICA București **Referent**

BUCUREȘTI 2024

MULȚUMIRI

Elaborarea prezentei teze de doctorat nu ar fi fost posibilă fără suportul conducătorului științific al tezei de doctorat, domnul profesor universitar Dr. Ing. Mihai Ciuc. Îi mulțumesc domnului profesor pentru că mi-a oferit libertatea de a aborda această temă dificilă într-un mod personal și mi-a acordat oportunitatea de a duce cercetarea în orice direcție a fost necesar pentru a obține ce mi-am dorit.

De asemenea, doresc să-mi exprim gratitudinea față de Conferențiar Dr. Ing. Elena Ovreiu pentru îndrumarea și susținerea drumului meu către obținerea titlului de Doctor, dar și suportului oferit pe plan personal, fără de care nu aș fi pornit pe acest drum și care după mulți ani o pot numi prietenă.

Doresc să le mulțumesc pentru suport, echipei de îndrumare pentru suportul științific pe toată perioada școlii doctorale: Prof. Dr. Ing. Constantin Vertan, Dr. Ing. Elena Ovreiu, Dr. Ing. Alina Oprea și membrilor comisiei de evaluare a lucrării.

Țin să le mulțumesc și colegelor mele Dr. Ing. Silvia Ovreiu și Drd. Ing. Elena Paraschiv pentru colaborarea în elaborarea articolului pe care l-am realizat împreună.

Îi sunt recunoscătoare în mod special și îi mulțumesc colegului și prietenului meu MSc. Răzvan-Nicu Rusu pentru imensul ajutor pe care mi l-a oferit necondiționat, pentru toate sfaturile, criticile și ideile lui și pentru răbdarea înfinită, optimismul molipsitor și încrederea lui în mine. Toate aceste lucruri au contribuit și au influențat parcursul elaborării prezentei teze de doctorat și a obținerii rezultatelor prezentate în această lucrare.

De asemenea țin să îi mulțumesc pentru idei și implicare la elaborarea articolelor la care am lucrat împreună dar mai ales pentru că nu s-a dat niciodată bătut, nici atunci când părea că am dat de un "drum închis", colegului și prietenului meu Dr. Ing. Hassan El-khatib.

Doresc să-mi exprim gratitudinea față de cei care au pus baza carierei mele în Dezvoltare Digitală la MEDIST Imaging & POC. Îi mulțumesc CEO-ului, Dr. Bogdan Radu Niculescu pentru oportunitatea pe care mi-a oferit-o, de a coordona un departament întreg și de a susține educația noii generații de colegi și cercetători în domeniu. Îi mulțumesc lui MSc, MBE, Ing. Daniel Pop, pentru că mi-a fost mentor și exemplu de urmat și care mi-a îndreptat pașii în această direcție, având o încredere extraordinară în mine - că nu este nimic ce nu pot face.

Nu în ultimul rând, doresc să îi mulțumesc mamei mele fără de care nu aș fi ajuns aici, care mi-a fost mereu alături, pentru că m-a sprijinit, susținut și înțeles întotdeauna.

CUPRINS

Mulțumiri.....	i
Lista tabelelor	v
Lista figurilor	vii
Lista abrevierilor	xiii
1. Introducere	1
1.1. Prezentarea domeniului de doctorat	1
1.2. Scopul tezei de doctorat.....	2
1.3. Conținutul tezei de doctorat.....	2
2. Stadiul actual în cercetarea sistemelor de analiză a imaginilor medicale.....	5
2.1. State of the art – Aplicații automate de clasificare a imaginilor medicale....	6
2.2. Diagnostic automat cu ajutorul inteligenței artificiale	9
2.2.1. Rețele neuronale artificiale	9
2.2.2. Arhitecturi pentru clasificarea imaginilor	13
2.2.3. <i>Framework</i> -uri	25
2.2.4. Platforme pentru construirea modelelor de învățare automată	31
2.3. <i>State of the art</i> – Rețele neuronale pentru detectarea patologiilor.....	36
2.3.1. <i>State of the art</i> - algoritmi pentru detectarea patologiilor oculare.....	36
2.3.2. <i>State of the art</i> - algoritmi pentru detectarea patologiilor de piele.....	45
2.4. Baze de date folosite.....	52
3. Sisteme informatice.....	55
3.1. Sisteme informatice - noțiuni generale.....	55
3.1.1. Componentele unui sistem informatic	55
3.1.2. Beneficiile unui sistem informatic	56
3.1.3. Criterii de evaluare a unui sistem informatic	59
3.1.4. Tipuri de sisteme informatice într-o organizație	62
3.1.5. Etapele implementării unui sistem informatic.....	63
3.2. Sisteme informatice medicale.....	97
3.2.1. Modulele unui sistem informatic medical.....	98
3.2.2. Sisteme informatice medicale populare	100
4. Soluția propusă.....	107

4.1. Considerente generale – soluție.....	107
4.2. Prezentarea sistemului informatic ales.....	110
4.3. Construirea modelului de clasificare.....	114
4.3.1. Studiu de caz 1.....	116
4.3.2. Studiu de caz 2.....	119
4.3.3. Studiu de caz 3.....	142
4.4. Dezvoltarea sistemului informatic medical de tip CRM.....	152
4.4.1. Crearea arhitecturii sistemului	152
4.4.2. Dezvoltare de noi funcționalități	157
4.4.3. <i>Deployment</i>	173
4.4.4. Integrare	180
5. Rezultate, Discuții și Concluzii.....	183
5.1. Rezultate.....	183
5.2. Discuții.....	210
5.3. Concluzii.....	213
5.4. Contribuții personale.....	216
5.5. Direcții viitoare.....	219
Anexe	221
A.1 Anexa 1	221
A.2 Anexa 2	226
A.3 Anexa 3	234
A.4 Anexa 4	236
A.5 Anexa 5	237
A.6 Anexa 6	250
A.7 Anexa 7	256
A.8 Anexa 8	265
Bibliografie	277
Mulțumiri.....	i
Lista tabelelor	v
Lista figurilor	vii
Lista abrevierilor	xiii
1. Introducere	1

1.1. Prezentarea domeniului de doctorat	1
1.2. Scopul tezei de doctorat.....	2
1.3. Conținutul tezei de doctorat.....	2
2. Stadiul actual în cercetarea sistemelor de analiză a imaginilor medicale.....	5
2.1. State of the art – Aplicații automate de clasificare a imaginilor medicale....	6
2.2. Diagnostic automat cu ajutorul inteligenței artificiale	9
2.2.1. Rețele neuronale artificiale	9
2.2.2. Arhitecturi pentru clasificarea imaginilor	13
2.2.3. <i>Framework</i> -uri	25
2.2.4. Platforme pentru construirea modelelor de învățare automată	31
2.3. <i>State of the art</i> – Rețele neuronale pentru detectarea patologiilor.....	36
2.3.1. <i>State of the art</i> - algoritmi pentru detectarea patologiilor oculare.....	36
2.3.2. <i>State of the art</i> - algoritmi pentru detectarea patologiilor de piele.....	45
2.4. Baze de date folosite.....	52
3. Sisteme informatice.....	55
3.1. Sisteme informatice - noțiuni generale.....	55
3.1.1. Componentele unui sistem informatic	55
3.1.2. Beneficiile unui sistem informatic	56
3.1.3. Criterii de evaluare a unui sistem informatic	59
3.1.4. Tipuri de sisteme informatice într-o organizație	62
3.1.5. Etapele implementării unui sistem informatic.....	63
3.2. Sisteme informatice medicale.....	97
3.2.1. Modulele unui sistem informatic medical.....	98
3.2.2. Sisteme informatice medicale populare	100
4. Soluția propusă.....	107
4.1. Considerente generale – soluție.....	107
4.2. Prezentarea sistemului informatic ales.....	107
4.3. Construirea modelului de clasificare.....	112
4.3.1. Studiu de caz 1	114
4.3.2. Studiu de caz 2.....	117
4.3.3. Studiu de caz 3.....	140
4.4. Dezvoltarea sistemului informatic medical de tip CRM.....	150

4.4.1. Crearea arhitecturii sistemului	150
4.4.2. Dezvoltare de noi funcționalități	155
4.4.3. <i>Deployment</i>	171
4.4.4. Integrare	178
5. Rezultate, Discuții și Concluzii.....	181
5.1. Rezultate.....	181
5.2. Discuții.....	210
5.3. Concluzii.....	213
5.4. Contribuții personale.....	216
5.5. Direcții viitoare.....	219
Anexe	221
A.1 Anexa 1	221
A.2 Anexa 2	226
A.3 Anexa 3	234
A.4 Anexa 4	236
A.5 Anexa 5	237
A.6 Anexa 6	250
A.7 Anexa 7	256
A.8 Anexa 8	265
Bibliografie	277

Capitolul 1

Introducere

Teza de doctorat intitulată “Sistem informatic medical cu modul automat de clasificare patologii”, a fost elaborată în cadrul Facultății de Electronică, Telecomunicații și Tehnologia Informației din cadrul Universității de Știință și Tehnologie POLITEHNICA București și conține contribuții originale în domeniul științei automatice și calculatoarelor, dezvoltării digitale și electronice și tehnologiei informațiilor. Teza de doctorat abordează două subiecte. Primul subiect tratează sistemele de analiza a imaginilor medicale bazate pe rețele neuronale și dezvoltarea unor modele și clasificatori ce clasifică imaginile medicale în două clase: sănătos și bolnav și ulterior fiind capabile să indice și patologii existente pe baza imaginii obținute.

Cel de-al doilea subiect tratează dezvoltarea unui sistem informatic de tip CRM (Customer Relationship Management) pentru o instituție medicală de tip spital. Ambele subiecte tratate individual au fost combinate prin integrarea unui sistem de clasificare a imaginilor medicale direct în sistemul informatic, pentru optimizarea fluxului de lucru în beneficiul atât al membrilor echipei medicale cât și al pacienților, ce funcționează în timp real și poate da informația pe loc despre existența unei patologii dintr-o imagine sau un video achiziționate.

Structura tezei de doctorat este împărțită în 5 capitole după cum urmează:

În Capitolul 1 este prezentat domeniul tezei de doctorat și subiectele tratate ce vizează două domenii diferite și obiectivele tezei care contrepoște cele două domenii sub forma construirii unui sistem informatic complet nou.

În Capitolul 2 este prezentat stadiul actual în cercetarea sistemelor de analiză a imaginilor medicale, a aplicațiilor automate a imaginilor medicale împreună cu diagnosticarea automată cu ajutorul inteligenței artificiale. Sunt trecute în revistă arhitecturile și *framework*-urile actuale pentru clasificarea imaginilor, platformele pentru construirea de modele de învățare automată și rețele neuronale special construite pentru detecția patologiilor oculare și cutanate și bazele de date existente și ce vor fi folosite în teză.

În Capitolul 3 sunt prezentate sistemele informatice, noțiuni generale precum componentele, beneficiile, obiective, criteriile de evaluare ale unui sistem informatic, tipuri de sisteme informatice regăsite în instituții, etapele implementării unui astfel de sistem și obiectivele unui sistem informatic împreună cu noțiuni despre sistemele informatice medicale, modulele necesare și exemple ale unor sisteme informatice utilizate în instituții medicale.

În Capitolul 4 este prezentată soluția propusă în teză și considerentele generale ale soluției, prezentarea sistemului informatic ales, metodologia implementării atât a sistemului informatic medical cât și a modulului de detecție automată de patologii (crearea arhitecturii, dezvoltarea de noi funcționalități, *deployment* și integrare).

În Capitolul 5 sunt prezentate rezultatele obținute pe parcursul cercetării elaborării tezei de doctorat prezente, contribuțiile originale aduse, lista de lucrări publicate și direcții viitoare de cercetare și dezvoltare a temei tezei de doctorat.

Teză se finalizează cu capitolul de „Bibliografie” ce conține 237 de referințe bibliografice și cu anexarea lucrărilor publicate.

Contribuțiile aduse domeniului pe parcursul elaborării tezei de doctorat au fost diseminate în următoarele conferințe și reviste de specialitate:

1. [33] El-Khatib, H., **Ștefan, A.-M.**, & Popescu, D. (2023). Performance Improvement of Melanoma Detection Using a Multi-Network System Based on Decision Fusion. *Applied Sciences*, 13(18), 10536–10536. <https://doi.org/10.3390/app131810536>
2. [57] **Ștefan, A.-M.**; Rusu, N.-R.; Ovreiu, E.; Ciuc, M. Advancements in Healthcare: Development of a Comprehensive Medical Information System with Automated Classification for Ocular and Skin Pathologies—Structure, Functionalities, and Innovative Development Methods. *Appl. Syst. Innov.* 2024, 7, 28. <https://doi.org/10.3390/asi7020028>
3. [58] **Ștefan, A.-M.**; Rusu, N.-R.; Ovreiu, E.; Ciuc, M. Empowering Healthcare: A Comprehensive Guide to Implementing a Robust Medical Information System - Components, Benefits, Objectives, Evaluation Criteria, and Seamless Deployment Strategies. *Applied System Innovation*. 2024; 7(3):51. <https://doi.org/10.3390/asi7030051>
4. [59] **Ana-Maria ȘTEFAN**, Elena OVREIU, Mihai CIUC, "Comparative analysis of web-based machine learning models", *Romanian Journal of Information Technology and Automatic Control*, ISSN 1220-1758, vol. 34(2), pp. 49-63, 2024. <https://doi.org/10.33436/v34i2y202404>
5. [89] **Ștefan, A.-M.**, Paraschiv, E.-A., Ovreiu, S., & Ovreiu, E. (2020). A Review of Glaucoma Detection from Digital Fundus Images using Machine Learning Techniques. 2020 International Conference on E-Health and Bioengineering (EHB). <https://doi.org/10.1109/ehb50910.2020.9280218>
6. [206] El-khatib, H., **Ștefan, A.-M.**, & Popescu, D., Melanoma Automated Detection System Integrated with an EHR Platform – UPB Scientific Bulletin Series C: Electrical Engineering and Computer Science 2024. Vol. 86, Iss. 1, 2024. ISSN 2286-3540

Capitolul 2.

Stadiul actual în cercetarea sistemelor de analiză a imaginilor medicale

Diagnosticul medical a luat o întorsătură neașteptată, cu ajutorul inteligenței artificiale; de la roboți la sisteme automate de diagnostic, la telemedicină, producere de medicamente, monitorizare, sisteme inteligente (proteze cu sisteme bazate pe interfața creier mașină) și multe altele.

Cu ajutorul inteligenței artificiale, sistemul medical și fluxul de lucru va fi optimizat la maxim. Timpul de diagnosticare va fi scurtat, diagnosticul va fi mai sigur și bazat pe o bază mult mai mare de exemple (ceea ce se traduce printr-o experiență mai mare a evaluatorului) și patologii diagnosticate precoce. Mai multe spitale au implementat algoritmi de inteligență artificială pentru îmbunătățirea fluxului (Ex.: Clinica Mayo din Minnesota). Sistemele existente pentru diagnosticare automată sunt diverse și din ce în ce mai multe; acestea folosesc imagini provenite de la CT (computer tomograf), RMN (rezonanță magnetică nucleară), radiografii și ecografii.

Machine Learning (ML) este o arie a științei calculatoarelor care se ocupă cu analiza și interpretarea modelelor, structurilor în volume largi de date pentru sarcini precum învățare și suport decizional cu minimă intervenție din partea expertului uman. ML permite utilizatorilor să introducă volume mari de date într-un algoritm computerizat care le va analiza și va genera decizii și recomandări. Algoritmii învață inclusiv din funcția de eroare, și o folosește ca intrare pentru optimizarea acestuia. *Deep learning* reprezintă o metodă a *machine learning*-ului bazată pe reprezentarea arhitecturală a modului în care creierul biologic învață.

Rețelele neuronale artificiale învață progresiv să îndeplinească anumite sarcini din exemple date. De exemplu, în sistemele pentru recunoașterea diverselor instanțe, rețeaua primește la intrare elemente etichetate, iar aceasta învață să le recunoască comparându-le cu instanțele cunoscute. Similar cu rețelele biologice, neuronii sunt conectați între ei și

transmit informația de la unul la altul; fiecare dintre aceștia are o stare (care poate fi 0 sau 1) și o pondere, care se poate modifica pe parcurs ce algoritmul învață. Rolul este de a crea algoritmi de rețele neuronale care învață la fel cum o face creierul biologic. Avantajul acestor rețele artificiale este că se pot accesa abilități specifice care se depărtează de la capacitățile biologice cum ar fi propagarea inversă (*back-propagation*) și optimizarea rețelei pentru a obține la ieșire informația necesară [15]. Rețelele neuronale profunde sunt rețele cu un număr de straturi între intrare și ieșire [16] iar fiecare strat calculează probabilitatea fiecărei ieșiri. Modele de învățare profundă sunt specializate pentru o sarcină specifică ce se rezumă la exemple specifice în funcție de sarcină. Un model anume nu poate fi antrenat pe un alt set de date (pașii de implementare sunt exemplificați în Figura 2.11 și Figura 2.12).

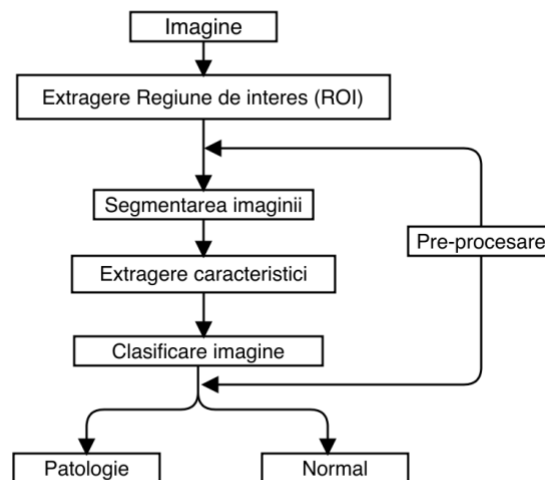


Figura 2.11 Pași de implementare pentru clasificarea imaginilor.

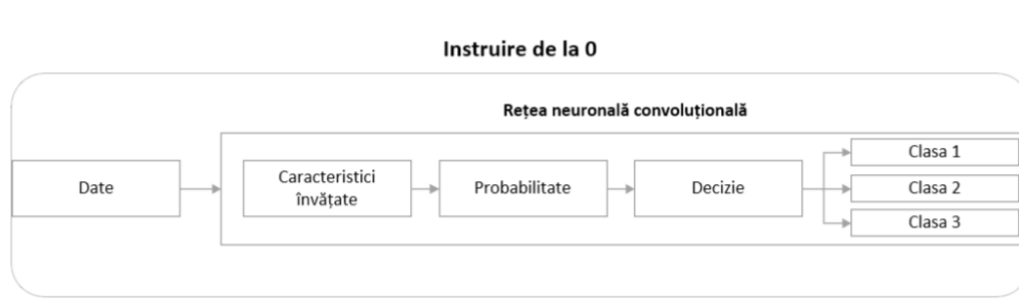


Figura 2.12 Pași pentru sarcina de instruire.

Antrenarea unei rețele neuronale se face în două faze. O fază prin care datele de intrare trec înainte prin rețea și o fază în care gradientii și ponderile sunt actualizate. Transferul de cunoștințe poate fi utilizat pentru a utiliza cunoștințele obținute în rezolvarea unei noi probleme. Foarte util în cazul în care pentru o anumită problemă nu există suficiente informații și deci în abordarea clasică rețeaua nu ar avea o acuratețe satisfăcătoare (pașii sunt descriși în Figura 2.13 [22-23]).




Figura 2.13 Pași pentru transferul de cunoștințe

Framework-urile populare utilizate pentru clasificarea de imagini sunt TensorFlow, Keras, Caffe, MATLAB, NVIDIA Caffe, PyTorch, MXNet, Chainer. Crearea de modele pentru învățarea automată se pot face cu ajutorul unor aplicații pentru construirea rapidă a lor și exportarea aceluși model pentru a fi folosit mai departe în diferite tipuri de platforme. S-au cercetat în prezenta teza Azure Machine Learning, Google Teachable, Google Cloud – Vertex AI, Salesforce Einstein Vision.

Focusul acestei teme de doctorat va fi studiul dezvoltării unui sistem informatic ce integrează aplicații de clasificare automată a imaginilor medicale pentru 2 dintre factorii principali ce cauzează decesul la nivel global: Diabetul¹ (103,294 decese) și Cancerul¹ (605.213 decese) [67]. Domeniul tezei de doctorat va fi focusată pe prelucrarea inteligentă a imaginilor medicale de retină și de piele. Se vor compara diverse sisteme de clasificare aplicate diverselor baze de date de imagini. În cazul patologieilor de piele vom studia două tipuri de cancer de piele (melanom și carcinom bazocelular) și alte două patologii ce prezintă leziuni la nivelul pielii des întâlnite ce netratate pot duce la cancer de piele (cheratoză actinică și cheratoză seboreică). În cazul diabetului, vom trata complicațiile datorate diabetului la nivel ocular: retinopatie diabetică, glaucom și catarctă. Detectarea timpurie a patologieilor acute prin intermediul unui astfel de sistem poate influența semnificativ rezultatele pacientului, poate reduce costurile asistenței medicale și poate promova măsuri preventive proactive. Totodată utilizarea unui astfel de sistem inovator aduce un plus asupra domeniului dezvoltării digitale din următoarele motive:

- Diagnostic mai rapid prin clasificarea automată a imaginilor poate accelera procesul de diagnostic prin identificarea și categorisirea rapidă a imaginilor medicale.
- Detectare precoce deoarece sistemul poate asista în detectarea timpurie a bolilor sau afecțiunilor, putând duce la rezultate mai bune în tratament.
- Consistență pentru că sistemele automate oferă analize consistente și standardizate ale imaginilor medicale, reducând probabilitatea erorilor umane.
- Economisire a timpului pentru profesioniștii din domeniul sănătății ce prin automatizarea analizei imaginilor, permițându-le să se concentreze mai mult pe îngrijirea pacienților.
- Acces rapid la imagini etichetate în cadrul SIM poate ajuta medicii să ia decizii informate rapid.
- Colectarea de informații prin clasificarea automată a imaginilor oferă date valoroase pentru cercetare medicală și analize, ajutând la identificarea tendințelor, corelațiilor și eficacității tratamentului.

¹ Situație la 18.01.2023

- Gestionarea sănătății populației prin datele colectate din clasificarea imaginilor pot fi folosite pentru gestionarea sănătății populației și strategiile de prevenție.
- Gestionarea volumelor mari de date pentru că unitățile medicale pot gestiona și clasifica eficient un volum mare de imagini medicale pe măsură ce baza de pacienți și de date cresc.
- Adaptabilitate deoarece sistemul poate fi personalizat pentru specialități medicale specifice.
- Automatizarea proceselor prin automatizarea clasificării imaginilor reduce necesitatea analizei manuale laborioase a imaginilor, economisind potențial costuri de muncă.
- Optimizarea fluxului de lucru ce duce la creșterea eficienței ce poate duce la economii de costuri și optimizarea resurselor.
- Securitatea datelor pentru că SIM pot asigura accesul securizat și controlat la datele pacienților, inclusiv imaginile medicale, menținând confidențialitatea acestora.
- Criptarea datelor sensibile din imagini pot fi criptate pentru a proteja informațiile pacientului.
- Alerte și notificări generate de sistem pentru constatările critice în imaginile medicale, asigurând o acțiune promptă.
- Integritate cu module de clasificare a imaginilor pot fi integrate cu alte sisteme IT din domeniul sănătății, creând un ecosistem medical coeziv.
- Acces la distanță pentru ca medicii să poată accesa și colabora la imagini medicale de la distanță, îmbunătățind accesibilitatea serviciilor de sănătate, în special în telemedicină.
- Consecvență și calitate prin clasificarea automată a imaginilor asigură un standard consecvent și de înaltă calitate în analiza imaginilor, reducând variațiile între diferiți profesioniști din domeniul sănătății.
- Conformitate cu reglementările în vigoare, SIM cu capacități de clasificare a imaginilor pot ajuta organizațiile din domeniul sănătății să se conformeze reglementărilor și standardelor referitoare la gestionarea imaginilor medicale.

În concluzie, importanța detectării timpurii a patologiilor cu ajutorul inteligenței artificiale constă în potențialul de a îmbunătăți rezultatele tratamentului, a reduce costurile medicale și a îmbunătăți în ansamblu bunăstarea indivizilor prin abordarea patologiilor înainte ca acestea să progreseze la stadii avansate [82]. Pentru testarea de algoritmi s-au căutat baze de date publice ce conțin imagini biomedicale [33], [206], [57-59].

- a. ORIGA (*Online Retinal Fundus Image Dataset for Glaucoma Analysis and Research*) – este o bază de date publică ce conține 168 imagini funduscopice color de retină a polului posterior cu glaucom și 482 imagini fără patologii [138].
- b. Messidor – este o bază de date pentru retinopatie diabetică ce conține 1200 imagini de retină (cu glaucom și fără) ce sunt etichetate de experți, 800 din acestea au fost achiziționate cu pupila dilatată [139].

- c. EyePacs – este o bază de date disponibilă de la Kaggle ce conține 35,126 imagini de retină de retinopatie diabetică obținute în urma programelor de screening [140].
- d. HRF (*High-Resolution Fundus Image Database*) este o bază de date ce conține 15 imagini fundoscopice fără patologii și 15 imagini cu glaucom și 15 cu retinopatie diabetică ce este asigurată de Laboratorul CS5 din cadrul departamentului de oftalmologie al Universității Friedrich-Alexander Erlangen-Nuremberg și de Universitatea de Tehnologie Brno – departamentul de Inginerie Biomedicală [141].
- e. ISIC (*International Skin Imaging Collaboration*) – conține 93.083 imagini ale leziunilor de piele și a fost dezvoltată pentru testarea algoritmilor pentru detectarea melanomului [142].
- f. Baza de date de imagini cu patologii multiple (cataractă, glaucom și retinopatie diabetică). Baza de date disponibilă pe Kaggle conține 601 imagini împărțite în 5 clase [143].
- g. RIM-ONE – bază de date ce conține imagini de retină obținute din imagini de fundoscopie oculară 200 imagini de glaucom și 255 fără patologii [144], [145].
- h. DermIS - această bază de date este cea mai cuprinzătoare bază de date ce conține imagini dermatologice despre aproape toate tipurile de afecțiuni cutanate [146].
- i. MED-NODE - conține 170 de imagini (70 ce prezintă melanom și 100 fără normală) [147].
- j. PH² - conține 40 de imagini dermatoscopice ce reprezintă melanom și 80 imagini ce nu prezintă patologii [148].
- k. Suplimentar a mai fost obținut un set de imagini de la Spitalul Academic Ponderas, ce conține 32 de imagini ale pacienților cu glaucom și 34 de imagini ale pacienților fără patologii.

Capitolul 3.

Sisteme informatice

3.1 Sisteme informatice noțiuni generale

Un sistem informatic este o combinație de *software*, *hardware* și rețele de comunicații pentru a colecta, procesa, stoca și distribui date în vederea utilizării acestora în fluxuri de lucru și pentru facilitarea deciziilor și optimizarea proceselor. [149] Datele se transformă în informații în momentul în care sunt prelucrate pentru a sta la bază luării unei decizii. Sistemele informatice pot varia în mod considerabil în ceea ce privește complexitatea și funcționalitatea, de la sisteme simple la sisteme enterprise complexe precum software-ul de Management al Relațiilor cu Clienții (CRM) sau sistemele de Planificare a Resurselor (ERP) [57].

3.1.1 Componentele unui sistem informatic

Dintr-o perspectivă socio-tehnică, sistemele informatice sunt formate din următoarele componente - Resurse umane, Echipamente, *Software*, Date, Proceduri, Rețea, Securitate, Analiză, Control, Mediu. Toate aceste componente lucrează împreună pentru a crea un sistem informatic coerent și funcțional care susține obiectivele și scopurile unei organizații. Proiectarea și integrarea acestor componente sunt cruciale pentru succesul sistemului în furnizarea de informații precise, la timp și relevante pentru a susține luarea deciziilor și procesele operaționale.

3.1.2 Beneficiile și obiectivele unui sistem informatic

Sistemele informatice oferă o gamă largă de beneficii pentru organizații din toate domeniile. Aceste beneficii contribuie la îmbunătățirea eficienței, luării deciziilor, comunicării și performanței generale. Unele avantaje cheie ale sistemelor informatice includ:

- Îmbunătățirea procesului de decizie
- Creșterea eficienței și productivității
- Comunicare eficientă
- Informații disponibile în timp real
- Îmbunătățirea gestionării clienților
- Analiză și raportare
- Planificare strategică
- Gestionarea resurselor
- Conformitate
- Inovare
- Acces la distanță
- Facilitarea gestionării documentației
- Extindere [151-159]

În ansamblu, beneficiile sistemelor informatice sunt numeroase și contribuie la succesul strategic, operațional și financiar al organizațiilor. Ele joacă un rol vital în operațiunile moderne ale afacerilor și sunt esențiale pentru menținerea competitivității în era digitală de astăzi.

3.1.3 Criterii de evaluare a unui sistem informatic.

Criteriile de evaluare pentru un sistem informatic sunt standardele și măsurile utilizate pentru a evalua eficacitatea, eficiența, calitatea și performanța generală a sistemului, cum ar fi funcționalitate, ușurința în utilizare, performanța, scalabilitate, fiabilitate, securitate, interoperabilitate, flexibilitate, costuri reduse, întreținere și asistență, integrarea cu obiectivele de afaceri, adaptarea la schimbare, raportare și analiză, instruire, documentație, durabilitatea [160-163]

3.1.5 Etapele implementării unui sistem informatic

Un sistem informatic parcurge o serie de etape în implementarea sa pentru a servi obiectivelor cărora îi este destinat. Aceste etape fac parte dintr-o metodologie dezvoltată în 1960 pentru gestionarea implementării proiectelor *software* complexe – SDLC (*System*

Development Life Cycle) care este o abordare structurată și sistematică pentru proiectarea, dezvoltarea, testarea, implementarea și menținerea aplicațiilor sau sistemelor software.

Ea conturează diferitele etape și activități implicate în crearea și gestionarea *software*-ului, de la conceptul inițial la implementarea finală și întreținerea continuă. SDLC oferă un cadru care ajută la asigurarea finalizării proiectelor *software* în mod eficient, la timp și în cadrul bugetului, respectând în același timp cerințele de calitate și performanță. Principalele etape sau faze ale SDLC includ în mod obișnuit Planificare, Analiză, Proiectare, Dezvoltare, Testare, Implementare, Mentenanță, Evaluare. Există diferite metode și modele pentru implementarea SDLC, inclusiv modelul Waterfall, metodologiile Agile (cum ar fi Scrum și Kanban) și modelele iterative. Fiecare abordare are propriul set de principii, practici și beneficii, iar organizațiile pot alege cea care se potrivește cel mai bine cu cerințele proiectului, dinamica echipei și cultura organizațională. În ansamblu, SDLC oferă un cadru structurat care ghidează proiectele de dezvoltare *software* printr-o serie de etape bine definite, asigurând dezvoltarea, testarea și implementarea software-ului într-un mod sistematic și controlat [173], [58].

3.2.1 Modulele unui sistem informatic medical

Un sistem informatic medical este construit în mod tipic din mai multe module interconectate care servesc funcții specifice în cadrul unei organizații medicale. Aceste module facilitează gestionarea informațiilor despre pacienți, optimizează procesele și îmbunătățesc furnizarea de servicii medicale. În timp ce modulele specifice pot varia în funcție de designul sistemului și nevoile organizației, cele uzuale sunt următoarele:

- Electronic Health Record (EHR) este componenta centrală, stocând și gestionând în format digital înregistrările medicale ale pacienților. Include informații precum istoricul medical, diagnosticurile, tratamentele, medicamentele, rezultatele testelor de laborator și altele.
- Modul înregistrare pacienți gestionează înregistrarea pacienților, detaliile demografice și informațiile privind asigurarea
- Modul de programări permite gestionarea programărilor pacienților cu furnizorii de îngrijire medicală, incluzând alerte și notificări.
- Modul financiar: permite gestionarea proceselor financiar-contabile a cererilor de asigurare și tranzacțiilor financiare legate de serviciile prestate.
- Sistemul de informații de laborator (LIS) gestionează activitățile de efectuare a testelor de laborator, rezultatele acestora și raportarea. Se integrează cu echipamentele de diagnostic și automatizează procesele de laborator.
- Sistemul de Informații Radiologice (RIS) gestionează activitățile de radiologie și imagistică, procedurile și rezultatele acestora, adesea integrate cu sistemele de arhivare și comunicare a imaginilor (PACS).
- Modul gestionare farmaceutic gestionează activitățile de comandă a medicamentelor, dispensarea și controlul stocului. Poate include verificări ale interacțiunilor medicamentoase și istoricul acestora.

- Modul telemedicină facilitează consultațiile la distanță, vizitele virtuale și monitorizarea pacienților prin telemetri.
- Modul pentru îngrijirea pacienților și asistență medicală susține activitățile de asistență medicală, planurile de îngrijire a pacienților și documentarea acestora.
- Modul de gestionare intervenții ajută la programarea intervențiilor, evaluările preoperatorii și coordonarea îngrijirii postoperatorii.
- Modul imagistică medicală facilitează gestionarea imaginilor medicale, integrarea cu laboratoarele radiologice și facilitează vizualizarea și partajarea imaginilor.
- Modul de inventar facilitează gestionarea stocurilor, datele de expirare și a lanțului de aprovizionare.
- Modul resurse umane și salarizare facilitează gestionarea înregistrărilor angajaților, programarea, procesarea salariilor și gestionarea forței de muncă.
- Modul analiză și raportare facilitează furnizarea de analiză a datelor, raportare și metrice de performanță pentru luarea deciziilor informate și evaluarea proceselor din domeniul sănătății.
- Modul portal pacienți oferă pacienților acces la înregistrările medicale, programarea de consultații, comunicarea cu furnizorii de îngrijire medicală și resurse educaționale.
- Modul administrativ și de management susține sarcinile administrative, alocarea resurselor și gestionarea generală a sistemului.
- Modul aplicații mobile permite accesul la informații despre pacienți, programări și comunicare prin dispozitive mobile [189-192].

Aceste module lucrează împreună pentru a crea un sistem informatic medical cuprinzător care îmbunătățește îngrijirea pacienților, optimizează eficiența operațională și susține furnizorii de îngrijire medicală în oferirea de servicii de înaltă calitate.

Capitolul 4.

Soluția propusă

Industria medicală este o afacere mare. În SUA în anul 2021 cheltuielile cu asistență medicală a atins 4.3 trilioane de dolari care înseamnă 12.914 de dolari de persoană [200] iar în Uniunea Europeană 964 bilioane de dolari. [201]

Dacă sistemul medical începe să fie din ce în ce mai mult privit ca pe o afacere și sistemele de furnizare de servicii medicale ar trebui să gândească în termeni de afacere. Acest obiectiv se poate realiza prin implementarea unui sistem de gestionare a relației cu clienții (utilizat de obicei în zona de business – vânzări). Tipul de sistem de numește CRM tehnologie pentru gestionarea tuturor relațiilor și interacțiunilor companiei cu clienții și potențialii clienți. Utilizând acest tip de sistem informatic, satisfacția clientului crește, are parte de o experiență premium, va avea acces la toate informațiile legate de sănătatea acestuia la degetul mic (pe telefon, tabletă sau calculator) – *on the go*. Scopul este simplu: îmbunătățirea relațiilor de afaceri pentru dezvoltarea afacerii. Un sistem CRM ajută companiile să rămână conectate la clienți, să eficientizeze procesele printr-un tip mai scurt de realizare a acestora și să îmbunătățească profitabilitatea, prin campanii de marketing *target-ate* în funcție de pacient și de afecțiunea acestuia, de atragere pacienți printr-o experiență premium a furnizării de servicii medicale. Acest sistem poate îngloba oricâte module și se poate construi precum un *puzzle* pentru a putea interconecta obiectele, înregistrările și opțiunile necesare din fiecare modul și pot fi conectate la modulele de raportare, analiză și interconectare cu alte platforme.

Implementarea unui astfel de sistem oferă posibilitatea implementării unei interfețe comune pentru toate procesele existente fluxurilor de lucru dintr-o instituție medicală. Echipele lucrează împreună pe același flux și au acces la același tip de informații în timp real. În cele din urmă, alegerea între aceste sisteme CRM depinde de nevoile specifice, bugetul și nivelul de personalizare și scalabilitate necesare. În această

lucrare s-a ales Salesforce pe baza flexibilității sale, a modului de operare și a experienței dezvoltatorului.

Soluția propusă în această lucrare constă în folosirea unui sistem informatic ce integrează o aplicație de clasificare automată a imaginilor medicale. Sistemul informatic ales pentru acest proiect a fost platforma Salesforce, care este o companie dezvoltatoare de produse *software* în *cloud* care este lider mondial în domeniul sistemelor informatice de tip CRM (*Customer Relationship Management* – o viziune 360 asupra clienților și o viziune globală asupra proceselor de lucru și a informațiilor utile tuturor fluxurilor de lucru). Acest sistem prezintă un mare avantaj fiind un SaaS (*Software as a Service*), ce permite utilizatorilor să se conecteze și să utilizeze aplicații bazate pe *cloud* prin intermediul internetului în *browser*. Salesforce activează din 1999 și a fost fondată de un fost director executiv de la Oracle. Salesforce (SF) are o bază largă de utilizatori în diferite industrii iar prin structura bazată pe *cloud* permite utilizatorilor să acceseze platforma de oriunde, făcându-l o soluție flexibilă pentru organizații de toate dimensiunile. Salesforce a avut un rol semnificativ în transformarea modului în care afacerile gestionează relațiile cu clienții și a devenit un lider în operațiunile moderne ale afacerilor.

Infrastructura Salesforce se referă la tehnologia, arhitectura și resursele care susțin funcționarea platformei ce cuprinde componentele *software*-ul, rețelele, bazele de date și centrele de date care lucrează împreună pentru a asigura disponibilitatea, performanța, scalabilitatea și securitatea serviciilor Salesforce. În ansamblu, infrastructura SF oferă baza pentru livrarea serviciilor sale CRM și în *cloud*. Combinarea tehnologiei avansate, scalabilității, securității și redundanței asigură că clienții pot accesa și utiliza capacitățile SF în mod fiabil și în siguranță. Platforma Salesforce va fi customizată ca sistem informatic medical. Am ales SIM deoarece acesta are un domeniu larg ce cuprinde întregul istoric al pacientului, inclusiv date medicale și clinice, dar includ și informații de la alți furnizori de servicii de sănătate și surse. SIM sunt proiectate pentru a fi accesibile pentru o varietate de utilizatori autorizați, inclusiv pacienții însăși.

Totodată acestea sunt proiectate pentru interoperabilitate. Ele permit schimbul de date despre pacienți între diferite organizații și sisteme de îngrijire medicală, spre deosebire de EMR de exemplu, sistem care este limitat la o singură instituție și nu permite o partajare facilă cu terți. Acest lucru este crucial pentru furnizarea de îngrijire coordonată, în special pentru pacienții care consultă mai mulți specialiști sau au nevoie de îngrijire în diferite medii. Suplimentar accesul pacienților la propriile date se face printr-un portal ce le permite și programarea de consultații, partajarea de informații etc. Soluția propusă aduce beneficii suplimentare din punctul de vedere al existenței unui sistem de detecție automată a patologiilor într-un sistem de tip SIM care conține toate fluxurile de lucru pentru membrii echipelor medicale în același loc:

- Îmbunătățirea rezultatelor pacientului
- Prevenirea progresiei bolii
- Costuri reduse de asistență medicală
- Gestionarea sănătății populației
- Flux de lucru eficientizat
- Informații bazate pe date

- Cercetare și Dezvoltare [80-81], [171], [202-204]

În esență, detectarea timpurie a patologiilor prin sisteme automate integrate într-un SIM nu numai că îmbunătățește îngrijirea medicală individuală a pacientului, dar are și implicații mai largi pentru sănătatea publică, eficiența asistenței medicale, scăderea costurilor și promovează cercetarea medicală. Aceasta reprezintă un pas semnificativ către gestionarea proactivă și personalizată a sănătății.

4.3 Construirea modelului de clasificare

În urma cercetării realizate în vederea optimizării procesului de clasificare sunt necesari niște pași, printre care metode de pre-procesare a imaginilor medicale, cum ar fi extragerea regiunii de interes, eliminarea artefactelor (fire de păr, picături de apă etc.), extragerea discului optic, segmentarea imaginii, extragerea de caracteristici, eliminarea zgomotului/artefactelor (cum ar fi părul în cazul imaginilor de piele sau oasele în cazul radiografiilor), morfologie (netezirea marginilor), augumentarea imaginilor, redimensionarea imaginilor, binarizare, ajustarea/ corectarea luminozității, îmbunătățirea intensității și a contrastului imaginilor [207-212].

Toate aceste metode îmbunătățesc modul de prelucrare al datelor cu pierderi minime de informație. În acest capitol vom evalua instrumentele pentru crearea un model de clasificare automată a imaginilor medicale. Pentru construirea modelelor atât pentru clasificarea imaginilor de piele cât și a celor oculare, vom folosi bazele de date prezentate în Capitolul 2. Acestea au fost create folosind atât imagini achiziționate în cadrul realizării fundoscopiei și imagini achiziționate folosind o cameră foto și a fost ales cel care a performat cel mai bine, care este cel mai versatil (performează bine pe orice bază de date de imagini medicale) din punct de vedere al acurateții, scorului F1 dar și a versabilității integrării ulterioare în platforme externe. Pentru evaluarea modelelor de clasificare automată am utilizat acuratețea și scorul F1 deoarece acesta ia în considerare și rezultatele fals negative și pe cele fals pozitive. Expresiile pentru indicatorii de performanță sunt exemplificate în tabelul 4.2.

Tabelul 4.2 Expresiile pentru indicatorii de performanță

Indicatori de performanță	Formula
Precizie	$\frac{TP}{TP + FP}$
Recall	$\frac{TP}{TP + FN}$
Acuratețe	$\frac{TP + TN}{TP + FP + FN + TN}$
Scor F1	$2 \cdot \frac{Precizie \cdot Recall}{Precizie + Recall} = \frac{2TP}{2TP + FP + FN}$

TP = numărul de rezultate pozitive reale; FP = numărul de rezultate pozitive false; TN = numărul de rezultate negative reale; FN = numărul de rezultate negative false.

- **Acuratețea** – indicator de performanță a unui sistem ce măsoară performanța în detectarea patologiilor (proporția claselor identificate corect)
- **Scorul F1** – indicator de performanță ce măsoară performanța sistemului în raport cu rezultatele fals pozitive și fals negative
- **Sensibilitate/Recall** – indicator de performanță ce măsoară proporția detecției corecte a patologiei (TP). Această metrică se focusează pe minimizarea rezultatelor fals negative ce este foarte important pentru a nu rata cazuri de detectate incorect
- **Specificitate** – indicator de performanță ce măsoară propoortia detecției corecte a non-patologiei (TN). Această metrică este importantă pentru a reduce alarmele false și investigații suplimentare inutile [33], [206], [57-59], [213-218]. S-au realizat trei studii de caz pentru construirea și evaluarea modelelor de clasificare.

4.3.1 Studiul de caz 1.

În cadrul acestui studiu s-a construit o aplicație *web* ce rulează în *browser* și care permite încărcarea de imagini medicale în baza cărora modelul construit clasifică imaginea într-una din cele două clase: imagine normală fără patologii sau glaucom. Resurse folosite utilizate au fost Google Colaboratory, Tensor Flow Core, Keras, Streamlit și bază de date de imagini – ACRIMA ce conține 428 de imagini ce conțin glaucom și 428 imagini ce nu conțin nicio patologie. Imaginile au fost împărțite în trei categorii: instruite, validare și testare. Modelul construit a avut o acuratețe și un scor F1 de 0.8452.

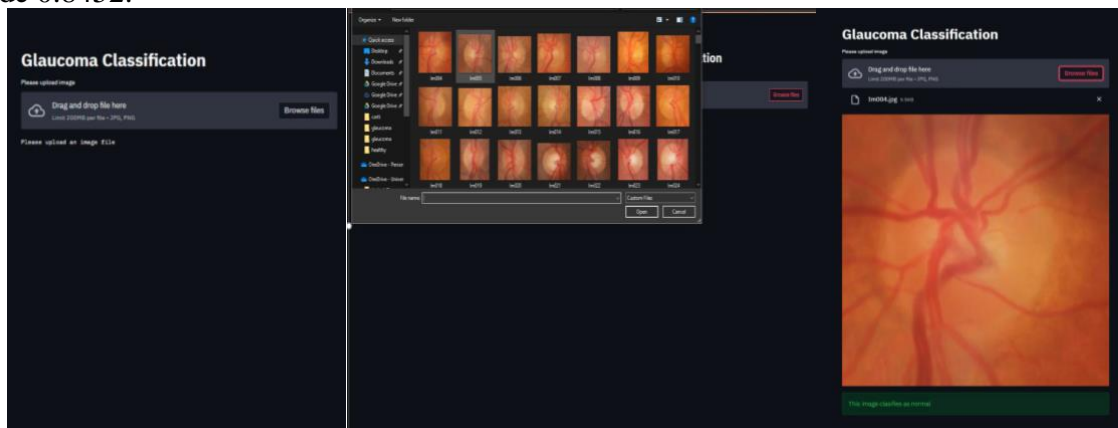


Figura 4.6 Încărcarea imaginii și obținerea rezultatului

S-a cercetat diverse moduri de integrare a acestei aplicații într-un sistem informatic, dar având în vedere compatibilitatea *framework*-urilor, securității și limbajelor de programare distincte, o integrare de acest tip nu a fost posibilă, mai ales că nu este vorba de date, ci de imagini.

4.3.2 Studiu de caz 2

În cadrul acestui studiu [33] am evaluat performanța celor patru instrumente *web-based* (Google Teachable Machine, Azure Machine Learning, Google Vertex AI și Salesforce Einstein Vision) pentru crearea de modele pentru detecția automată a patologiilor și a unui

clasificator construit în MATLAB pe baza fuziunii deciziilor mai multor rețele neuronale convoluționale (DarkNet-53, DenseNet-201, GoogleNet, Inception-V3, InceptionResNet-V2, ResNet-50, ResNet-101 și Xception). Studiul de caz a fost efectuat strict pentru detectarea melanomului. Comparația a fost făcută pe baza rezultatelor obținute a scorului F1 deoarece este mai eficient decât acuratețea întrucât ia în considerare numărul de FN și FP. Bazele de date utilizate pentru testarea adaptabilității sistemelor cât și pentru antrenarea lor sunt ISIC 2020 și DermIS. Modelul are o acuratețe și un scor F1 de 0.9550 pe baza de date DermIS și 0.9350 pe baza de date ISIC. În urma cercetării realizate, integrarea între MATLAB și un sistem informatic s-a dovedit a fi imposibilă la momentul cercetării.

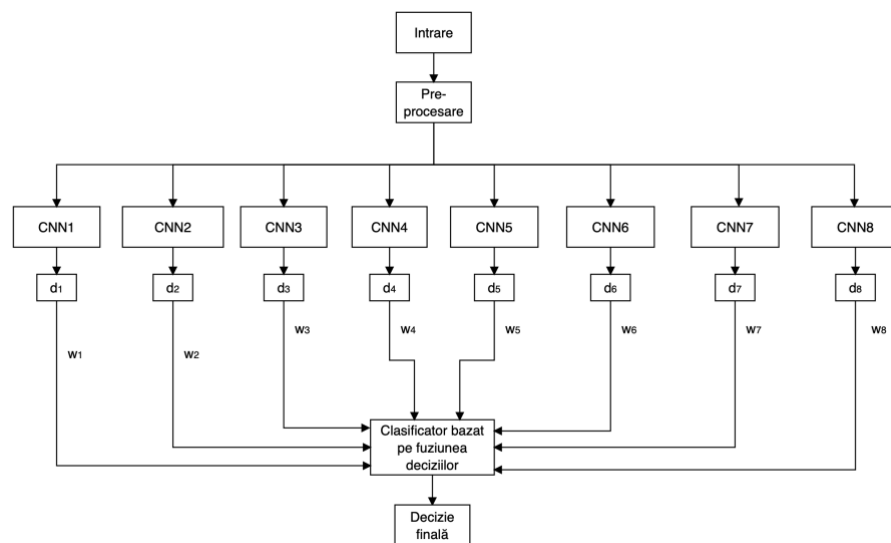


Figura 4.14 Arhitectura sistemului propus

Tabelul 4.5. Rezultate experimentale pentru clasificatorul de fuziune a deciziilor vs. alte clasificatoare vs. aplicațiile automate.

Metode de clasificare	Bază de date	Acuratețe	Scor F1
Google Teachable Machine	DermIS	0.7800	0.7786
	ISIC	0.7600	0.7597
Google Vertex AI	DermIS	0.8333	0.8331
	ISIC	0.7400	0.7370
Microsoft Azure Machine Learning	DermIS	0.7967	0.7966
	ISIC	0.8200	0.8200
Salesforce Einstein	DermIS	0.8033	0.8025
	ISIC	0.7933	0.7900
Clasificatorul propus bazat pe fuziunea deciziilor	DermIS	0.9550	0.9550
	ISIC	0.9350	0.9350

4.3.3 Studiu de caz 3.

Continuând studiul de caz 1, unde performanța unui clasificator *custom* bazat pe fuziunea deciziilor mai multor arhitecturi CNN este superioară modelelor *web-based*, dar

care în urma studiului extins realizat, nu s-a găsit nicio variantă fiabilă de integrare cu o altă platformă. Așadar se va extinde cercetarea pe mai multe baze de date pentru verificarea adaptabilității acestora. Am efectuat un studiu de caz în care am comparat modelele între ele, atât pe baze de date pentru patologii oculare cum ar fi ORIGA, Messidor, EyePacs, HRF și Ponderas și pe baze de date ce conțin leziuni cutanate cum ar fi ISIC, DermIS, MED-NODE, PH², creând atât modele cu câte două ținte (sănătos sau bolnav) dar și cu trei sau patru ținte (sănătos sau una dintre patologii investigate).

Pe baza rezultatelor obținute în cele două studii și a cercetărilor suplimentare ce au fost efectuate, fiecare aplicație prezintă avantaje și dezavantaje dar având în vedere cerințele proiectului, construirea modelului pentru detectarea automată a patologiilor pe care îl vom integra cu platforma Salesforce este Google Teachable deoarece modelul creat trebuie să fie compatibil cu SFDC, în plus modelul are o acuratețe destul de bună pe o gamă largă de imagini achiziționate în diverse moduri și este adaptabil multor patologii întâlnite. Pentru crearea arhitecturii sistemului informatic medical cu modul automat de clasificare de patologii, s-au creat mai multe obiecte, câmpuri, console, *layout*-uri, rapoarte, grafice pentru ca fluxul de lucru să fie urmat. S-au creat obiecte pentru a putea înmagazina la nivel de bază de date toate informațiile relevante despre pacienți, echipamente, rezultate etc. [59].

Tabel 4.6 Precizia modelelor încercate

Model	Patologie	Acuratețe	F1	Medie Acuratețe
Azure Machine Learning	Glaucom	0.9631	0.963	94%
	Cataractă	0.9024	0.9024	
	Retinopatie diabetică	0.9651	0.9645	
Google Teachable	Glaucom	0.9713	0.9712	96%
	Cataractă	0.9675	0.9674	
	Retinopatie diabetică	0.9476	0.9462	
Google Cloud – Vision AI	Glaucom	0.9836	0.9836	98%
	Cataractă	0.9878	0.9878	
	Retinopatie diabetică	0.9825	0.9822	
Einstein Vision	Glaucom	0.9188	0.9179	90%
	Cataractă	0.8740	0.8735	
	Retinopatie diabetică	0.9083	0.908	
Azure Machine Learning	Melanom	0.9024	0.9024	93%
	Cheratoză actinică	0.9351	0.9352	
	Cheratoză seboreică	0.9579	0.9576	
	Carcinom bazocelular	0.9291	0.929	
Google Teachable	Melanom	0.9451	0.9451	96%
	Cheratoză actinică	0.9457	0.9456	
	Cheratoză seboreică	0.9828	0.9827	
	Carcinom bazocelular	0.9866	0.9865	
Google Cloud – Vision AI	Melanom	0.9776	0.9776	96%
	Cheratoză actinică	0.9524	0.9523	
	Cheratoză seboreică	0.9713	0.9711	
	Carcinom bazocelular	0.9655	0.9654	
Einstein Vision	Melanom	0.9184	0.9184	91%
	Cheratoză actinică	0.9199	0.9198	
	Cheratoză seboreică	0.9195	0.9191	
	Carcinom bazocelular	0.9004	0.9002	

Capitolul 5.

Rezultate, Concluzii, Contribuții personale și Direcții viitoare

5.1 Rezultate

5.1.1 Implementarea sistemului informatic medical

5.1.1.1 Structura sistemului medical dezvoltat

Pentru atingerea obiectivelor propuse s-a pornit de la un sistem informatic de tip CRM ce asigură urmărirea fluxului de lucru de bază și prelucrarea datelor într-o instituție ce interacționează cu clienți Figura 5.1. Ulterior platforma a fost modificată și dezvoltată atât pe verticală cât și pe orizontală, obținându-se un sistem informatic nou medical ce integrează soluții de clasificare automată a imaginilor medicale utilizând inteligența artificială precum și aplicații și funcționalități nou dezvoltate ce răspund urmării unui flux de lucru complex într-o instituție medicală. Noul sistem informatic obținut „Ana Medical” dezvoltat de către autoarea tezei care îndeplinește obiectivele propuse și asigură funcționarea și integrarea modulelor de aplicații ce îl compun, precum și funcționalităților nou create pentru optimizarea fluxului de lucru sau îmbunătățirea experienței utilizatorului final. Structura obiectelor sistemului informatic este exemplificată în Figura 5.2.

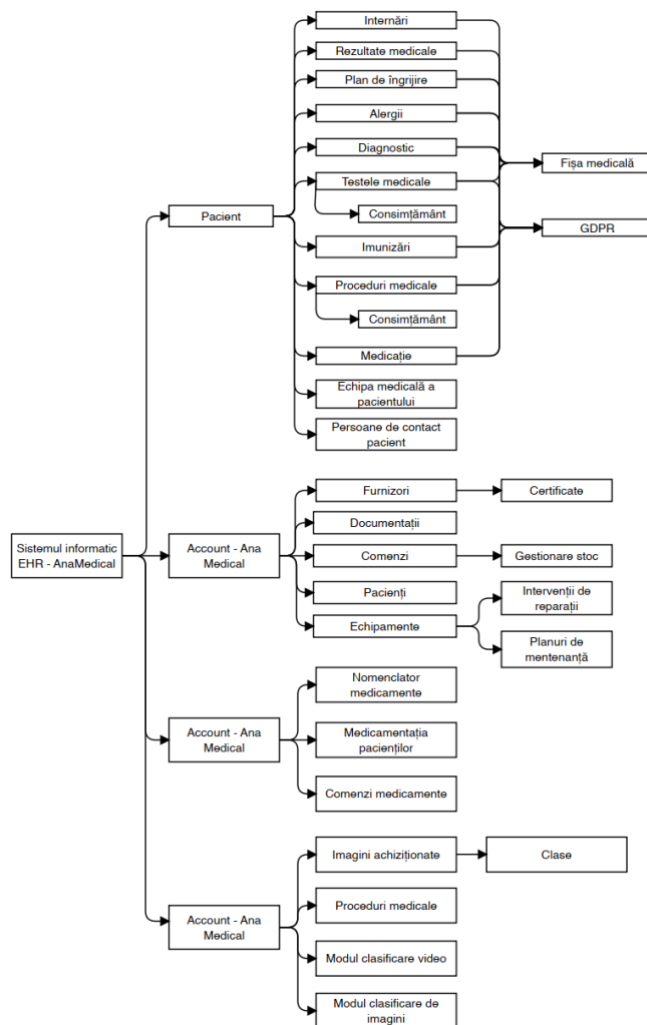


Figura 5.2 Structura sistemului Ana Medical [57]

Sistemul informatic este structurat în mai multe module (console) (Figura 5.3).

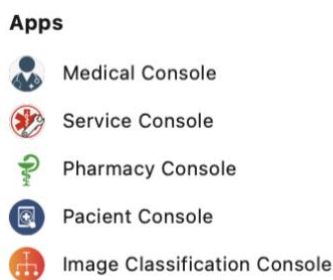


Figura 5.3 Modulele sistemului Ana Medical

- a. **Medical Console** - Consola este dedicată echipei medicale care se ocupă de fluxul de pacienți și de interacțiunile cu aceștia din punct de vedere medical. Dependente de acest obiect sunt următoarele informații despre pacient:
 - *Patient Encounters* – Spitalizările pacientului

- *Patient Results* – Rezultatele analizelor și procedurilor medicale
- *Patient Care Plans* – planurile de îngrijire ale pacienților
- *Patient Allergies* – alergiile pacienților
- *Patient Diagnosis* – diagnosticurile pacientului
- *Patient Medical tests* – testele medicale ale pacientului
- *Patient Immunizations* – vaccinurile pacientului
- *Patient Procedures* – procedurile pacientului
- *Patient Medication List* – tratamentul medicamentos pe care îl urmează pacientul
- *Patient Teams* – echipa medicală a pacientului
- *Contact Persons* – persoanele de contact ale pacientului

Aceste informații despre pacient sunt grupate în *Related List* – uri (ce au formată o legătură între pacient și nomenclatorul specific). *Related list* - ul este o componentă ce arată o listă de înregistrări înrudite pe baza unui obiect specific. La nivelul înregistrării unui pacient se regăsesc o serie de informații despre acesta:

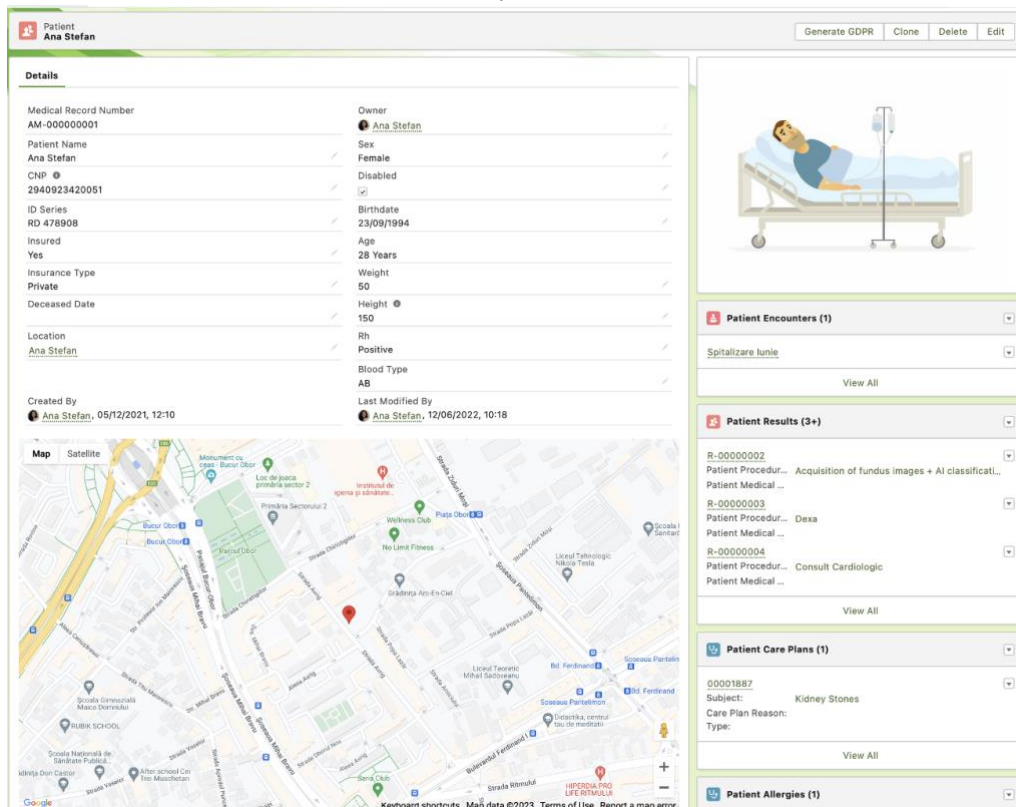


Figura 5.6 Interfața platformei la nivelul obiectului de Pacient

La nivelul acestui obiect, se generează mai multe formulare, cum ar fi GDPR-ul (*General Data Protection Regulation*), pentru a se putea prelucra datele personale din sistem, pentru procedurile și testele medicale se generează un formular de consimțământ informat al pacientului dar și fișa medicală a pacientului cu informațiile generate pe parcursul spitalizării acestuia în instituția medicală (Figura 5.7).

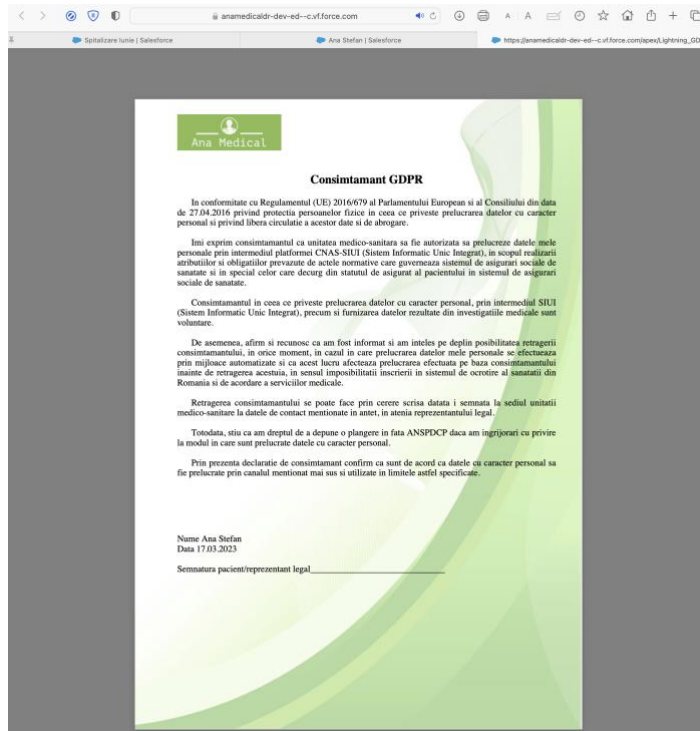


Figura 5.7 Formular de consimțământ.

Toate aceste obiecte ajută la gestionarea fluxurilor din instituția medicală, cum ar fi comanda de medicamente, trimiterea de notificări către echipele ce au roluri diferite în îngrijirea pacientului, crearea înregistrări în momentul în care unul din membrii trebuie să efectueze o procedură medicală sau să preleveze anumite analize, acestea apar programate pentru o gestionare facilă și existența unui flux de norificări la finalizarea anumitor activități, la primirea rezultatelor medicale etc.

b. **Service Console** - consola este dedicată echipei tehnice a spitalului (ingineri medicali) care se ocupă echipamentele medicale – mentenanță, calibrare, setări, utilizare s.a.m.d. Consola de Service este formată din mai multe obiecte:

I. **Account** - Conține informațiile despre instituția medicală – “Ana Medical”

Acest obiect conține *Related List*-uri către alte obiecte relevante:

- a. **Business Licenses** – obiect ce conține informații despre certificatele fiscale ale instituției și nu numai:
- b. **Providers** – informații despre furnizorii instituției (adresă, site, contact, informații fiscale):
- c. **Patients** – listă de pacienți a insituției
- d. **Account Assets** – lista de echipamente a insituției

II. **Assets** – un asset este un echipament deținut de instituția medicală. Acesta conține informații cu imagini despre produs, imagini clinice, video-uri despre echipament, *hands-on*, etc, documente despre echipament (*product tree*, manuale de service, declarația de conformitate a echipamentului etc.).

III. **Maintenance Plans** - la nivelul unui echipament se creează planuri de mentenanță pentru baza de echipamente instalată, iar la nivelul acestor înregistrări se pot crea automat intervenții asupra respetivelor echipamente în funcție de anumite criterii.

- IV. **Work Orders** - inginerii medicali responsabili de reviziile pe echipamente, realizează intervenția și generează un raport despre respectiva intervenție:
- V. **Work Types** - tipurile de intervenții ce pot fi realizate pe echipamentele medicale
- c. **Pharmacy Console** - consola este dedicată echipei ce se ocupă de farmacia spitalului care se ocupă de fluxul de achiziție de medicamente. Consola de Farmacie este formată din mai multe obiecte:
- i. *Orders* – pentru comandarea de medicamente
 - ii. *Stock* – stocul de echipamente al instituției
 - iii. *Medication List* – nomenclatorul de medicamente
 - iv. *Patient Medication List* – obiect de legătură între nomenclatorul de medicamente și medicamentele administrate pacienților. Obiecte ce ne ajută la gestionarea tirajului de medicamente.
- d. **Patient Console** - consola este dedicată pacienților. Acesta este portalul prin care pacienții și pot vizualiza rezultatele, planurile de tratament, istoricul medical etc. Consola de Pacient este formată dintr-un singur obiect – *Patiens*, și în funcție de pacientul care se loghează, conține o singură înregistrare despre un singur pacient cu informațiile relevante pentru acesta. La scanarea QR codului de pe orice document medical generat de instituție, se face trimitere directă în această consolă a pacientului.



Figura 5.39 Codul QR și modul acestuia de funcționare

- e. **Image Clasification Console** - consola este dedicată echipei de ingineri medicali specializați în Inteligență Artificială. Consola conține, obiectele necesare pentru achiziția și procesarea de imagini medicale. Procedurile medicale realizate pentru un pacient, imaginile achiziționate și clasele pentru clasificare. Fiecare clasă conține fie imaginile achiziționate fie o arhivă ce conține imaginile achiziționate. Se pot încărca ambele variante concomitent.

Modul detecție **patologii de piele** - Așa cum este exemplificat și în [33] doar că s-au utilizat mai multe clase de imagini și anume Melanom, Cheratoză actinică, Cheratoză seboreică, Carcinom bazocelular și clasă de imagini fără patologii. **Soluție video** – aplicația de clasificare custom pentru clasificarea în timp real a imaginilor de piele. Modul de funcționare al modulului se bazează pe camera unui computer sau dispozitiv mobil pe care este platforma sistemului informatic deschisă, aceasta cuprinde zona cu leziune și în timp real afișează una din cele patru clase pe care a fost instruit clasificatorul (Figura 4.45).




Figura 4.45 Modulul de clasificare video pentru leziuni cutanate [57]

Modul detecție patologii oculare – în care s-au utilizat pentru crearea modelului clase pentru Glaucom, Cataractă și Retinopatie diabetică. Soluție imagine - aplicația de clasificare *custom* pentru clasificarea imaginilor funduscopice achiziționate și stocate în baza de date. Modul de funcționare al modulului se bazează pe încărcarea unei imagini și primirea răspunsului ulterior în funcție de cele 3 patologii pe care este instruit modelul de clasificare (Figura 4.46).




Figura 4.46 Modulul de clasificare utilizând imagini pentru clasificarea patologiilor oculare [57]

5.2 Discuții

În această lucrare s-a mers pe două direcții de dezvoltare. Prima direcție a constat în crearea unui algoritm de clasificare a imaginilor medicale ce poate fi integrat cu succes într-un sistem informatic medical. Procesul a constat în cercetarea extinsă a domeniului de *machine learning*, *deep learning* și inteligență artificială pentru obținerea unui diagnostic automat, rețele neuronale și arhitecturile existente, cu diferențele dintre acestea și modurile în care pot fi utilizate pentru obținerea unui clasificator automat (focusul fiind pe clasificarea imaginilor funduscopice de retină și a leziunilor de piele) și a bazelor de date ce pot fi utilizate pentru instruirea clasificatorului, cercetarea *framework*-urilor existente pentru implementarea unui astfel de clasificator, platforme *web-based* pentru crearea de modele de clasificare ce pot fi ulterior integrate într-un modul de clasificare în cadrul unui sistem informatic medical și *state of the art* a aplicațiilor automate de clasificare imagini medicale. Cel mai bun rezultat dintre modelele *web-based* l-a avut Google Vertex AI dar cel mai versatil și mai flexibil model a fost Google Teachable Machine iar dintre algoritmele custom clasificatorul bazat pe fuziunea decizilor construit în MATLAB care la momentul cercetării nu s-a găsit o variantă viabilă de integrare cu un sistem informatic. Cea de-a doua direcție a constat în dezvoltarea unui sistem informatic medical, proces ce a constat în cercetarea extinsă a științei sistemelor informatice, a tipurilor acestora, a componentelor, a beneficiilor pe care le aduc și obiectivele pe care le îndeplinesc, a criteriilor de evaluare a acestora, a modului de planificare și etapele necesare implementării unui proiect de anvergură. Ulterior s-au evaluat sistemele informatice medicale și componentele acestora împreună cu cerințele specifice domeniului medical. Sistemul dezvoltat ajută la urmărirea majorității fluxurilor de lucru dintr-o instituție medicală ce are o platformă de acces pentru pacient, console separate pentru echipele de farmaciști, medici și ingineri medicali, cu modul separat de procesare și clarificare a imaginilor medicale atât în timp real cât și prin analizarea unei imagini pre-achiziționate extern sistemului. Sistemul implementat fiind unul nou ce permite extinderea funcționalităților multidisciplinar.

5.4 Contribuții personale

Contribuțiile personale sunt prezente în toate fazele de dezvoltare atât a sistemului informatic medical cât și a modului automat de detecție a patologiilor oculare și de piele. Dezvoltarea și implementarea unui sistem de informatic medical cu un modul integrat pentru detectarea automată a patologiilor implică mai multe etape cruciale pentru a asigura o implementare reușită a soluției, cum ar fi:

a. Identificarea nevoilor și planificarea:

- i. Identificarea obiectivelor specifice ale sistemului informatic și obiectivele integrării unui modul automat pentru detectarea patologiilor în SIM
- ii. Dezvoltarea unui plan de proiect care descrie domeniul de aplicare, cronologia, resursele și bugetul.

- iii. Crearea unei strategii gestionarea datelor, securitatea și integrarea cu sistemele existente, definirea tipurilor de patologii ce necesită a fi detectate și domeniul modulului de detectare.
 - iv. Stabilirea grupurilor țintă de utilizatori (furnizori de asistență medicală, administratori, pacienți) și cerințele lor.
- b. Proiectarea sistemului:**
- i. Proiectarea arhitecturii SIM, luând în considerare scalabilitatea, bazele de date, securitatea datelor și posibila interoperabilitatea acestuia cu alte sisteme sisteme de asistență medicală.
 - ii. Stabilirea fluxului de date și punctele de integrare între SIM și modulul automat de detectare a patologiilor, alegerea tehnologiilor, limbajele de programare și cadrele tehnologice care vor fi utilizate pentru dezvoltare.
- c. Integrarea datelor:**
- i. Stabilirea mecanismelor de integrare a datelor pentru a transfera în mod transparent datele pacientului, imaginile medicale și informațiile clinice relevante între SIM și modulul de detectare a patologiilor.
- d. Dezvoltarea sistemului informatic**
- i. Dezvoltarea funcționalităților și specificațiilor pe baza proiectării sistemului
 - ii. Implementarea structurilor de date, algoritmi și logica necesară
 - iii. Proiectarea unei interfețe intuitive și prietenoase pentru utilizatori pentru furnizorii de asistență medicală pentru a interacționa SIM și pentru a accesa rezultatele de detectare a patologiilor.
 - iv. Crearea de vizualizări și instrumente interactive pentru a afișa patologiile detectate și datele clinice relevante.
- e. Dezvoltarea modelului de învățare automată:**
- i. Dezvoltarea și/sau selectarea de algoritmi și modele de învățare automată potrivite pentru detectarea automată a patologiilor pe baza patologiilor alese și efectuarea unor studii de caz ce confirmă alegerea făcută.
 - ii. Colectarea și pregătirea un set complet de date cu imagini ale patologiilor pentru antrenament și validare, antrenarea și optimizarea modelul de învățare automată utilizând setul de date pentru a obține rezultate precise în vederea detecției.
- f. Integrarea și testarea:**
- i. Integrarea modelului de învățare automată și modulul de detectare a patologiilor în SIM
 - ii. Realizarea testelor pentru a asigura funcționarea precisă a modulului de detectare automată (teste de integrare, de sistem și UAT), efectuarea de teste globale pentru a valida fluxul de date, integrarea și funcționalitatea interfeței utilizatorului.
- g. Confidențialitatea și securitatea datelor:**
- i. Implementarea de măsuri de confidențialitate și securitate a datelor pentru a proteja informațiile despre pacienți și imaginile medicale.
 - ii. Asigurarea conformității cu regulamentele relevante privind protecția datelor, cum ar fi HIPAA sau GDPR.
- h. Implementarea sistemului:**

- i. Implementarea SIM complet integrat cu modulul de detectare automată a patologiilor în cadrul organizației de asistență medicală.
- ii. Configurarea bazelor de date și a componentelor de infrastructură, inserarea și modificarea datelor din sistem, monitorizarea performanței sistemului.

5.5 Direcții viitoare

Următorii pași pentru îmbunătățirea soluției modulului de detecție automată a patologiilor prezentate în teză includ înlocuirea paginilor Visualforce cu LWC, ceea ce reprezintă o soluție de dezvoltare mai provocatoare. Cu toate acestea, avantajul LWC constă în faptul că aplicația utilizează resursele *browser*-ului, nu resursele serverului. O altă direcție de îmbunătățire a soluției constă în integrarea diferitelor platforme cu sistemul informatic pentru utilizarea puterii de calcul prezente în alte platforme construite pentru implementarea unor soluții complexe, cum ar fi integrarea cu MATLAB și extinderea diagnosticării unor patologii diverse utilizând și alte tipuri de date altele decât imaginile medicale. Totodată pentru a utiliza această soluție în industria medicală, un alt instrument util ar fi un modul de telemedicină ce poate conecta pacienții, instituțiile medicale prestatoare de servicii și serviciile de asistență de urgență în vederea colectării în timp real a datelor în sistemul informatic. Un alt instrument util ar putea fi integrarea cu sistemul de analiză nativ Salesforce Tableau pentru analizarea datelor colectate pentru a identifica tendințe, modele și modificări în starea pacientului în timp, analitică predictivă pentru a prognoza riscuri potențiale de patologie pe baza datelor istorice și a profilurilor pacienților coroborat cu integrarea unor baze de date genetice pentru a îmbunătăți detecția patologiei prin luarea în considerare a predispozițiilor genetice și a mutațiilor.

Totodată, o altă direcție ar fi oportunitatea de a crește conștientizarea și educarea pacienților și pune la dispoziția acestuia resurse pentru a crește înțelegerea importanței detecției timpurii, a riscurilor potențiale ale diverselor patologii detectate târziu și a acțiunilor recomandate pentru tratarea acestora. Aceste idei pot contribui la îmbunătățirea capacităților și utilizabilității unui SIM care integrează detectarea automată a patologiei, îmbunătățind în cele din urmă îngrijirea pacienților, precizia diagnosticului și fluxurile de lucru medicale. În vederea extinderii utilizării sistemului informatic, este necesară dezvoltarea unui modul financiar-contabil, integrarea cu echipamente de achiziție imagini medicale sau echipamente de analiză, implementarea unor module de ofertare pentru pachete medicale și de asigurări de sănătate, implementarea unui modul de gestionare a datelor despre angajați și a unei console de marketing pentru a promova instituția și sistemul informatic construit. În cadrul studiilor post-doctorale, se dorește testarea sistemului într-o variantă beta, într-o instituție medicală. Rezumatul de față cuprinde într-o formă condensată conținutul capitolelor din teză. Numerotarea capitolelor, subcapitolelor și secțiunilor, a figurilor și tabelor corespund cu cele din teză. Bibliografia este selectivă cu lucrările prezente conform rezumatului.

Bibliografie

- [33] El-Khatib, H., **Ștefan, A.-M.**, & Popescu, D. (2023). Performance Improvement of Melanoma Detection Using a Multi-Network System Based on Decision Fusion. *Applied Sciences*, 13(18), 10536–10536. <https://doi.org/10.3390/app131810536>
- [57] **Ștefan, A.-M.**; Rusu, N.-R.; Ovreiu, E.; Ciuc, M. Advancements in Healthcare: Development of a Comprehensive Medical Information System with Automated Classification for Ocular and Skin Pathologies—Structure, Functionalities, and Innovative Development Methods. *Appl. Syst. Innov.* 2024, 7, 28. <https://doi.org/10.3390/asi7020028>
- [58] **Ștefan, A.-M.**; Rusu, N.-R.; Ovreiu, E.; Ciuc, M. Empowering Healthcare: A Comprehensive Guide to Implementing a Robust Medical Information System - Components, Benefits, Objectives, Evaluation Criteria, and Seamless Deployment Strategies. *Applied System Innovation.* 2024; 7(3):51. <https://doi.org/10.3390/asi7030051>
- [59] **Ana-Maria ȘTEFAN**, Elena OVREIU, Mihai CIUC, "Comparative analysis of web-based machine learning models", *Romanian Journal of Information Technology and Automatic Control*, ISSN 1220-1758, vol. 34(2), pp. 49-63, 2024. <https://doi.org/10.33436/v34i2y202404>
- [89] **Ștefan, A.-M.**, Paraschiv, E.-A., Ovreiu, S., & Ovreiu, E. (2020). A Review of Glaucoma Detection from Digital Fundus Images using Machine Learning Techniques. 2020 International Conference on E-Health and Bioengineering (EHB). <https://doi.org/10.1109/ehb50910.2020.9280218>
- [136] Ichim, L., & Popescu, D. (2020). Melanoma Detection Using an Objective System Based on Multiple Connected Neural Networks. *IEEE Access*, 8, 179189–179202. <https://doi.org/10.1109/ACCESS.2020.3028248>
- [147] Giotis, I., Molders, N., Land, S., Biehl, M., Jonkman, M. F., & Petkov, N. (2015). MED-NODE: A computer-assisted melanoma diagnosis system using non-dermoscopic images. *Expert Systems with Applications*, 42(19), 6578–6585. <https://doi.org/10.1016/j.eswa.2015.04.034>
- [153] Ragowsky, A., Ahituv, N., & Neumann, S. (1996). Identifying the value and importance of an information system application. *Information & Management*, 31(2), 89–102. [https://doi.org/10.1016/s0378-7206\(96\)01072-5](https://doi.org/10.1016/s0378-7206(96)01072-5)
- [206] El-khatib, H., **Ștefan, A.-M.**, & Popescu, D., Melanoma Automated Detection System Integrated with an EHR Platform – UPB Scientific Bulletin Series C: Electrical Engineering and Computer Science 2024. Vol. 86, Iss. 1, 2024. ISSN 2286-3540