

Raport științific final (2022 - 2024)

Competiția:	Proiect experimental demonstrativ - PED2021
Nr. contract:	616PED/2022
Cod proiect:	PN-III-P2-2.1-PED-2021-2709
Domeniul de cercetare:	
Titlul :	Noi biomarkeri de tomografie în coerență optică identificați prin deep learning pentru stratificarea riscului la pacienții cu degenerescență maculară legată de vârstă
Acronim:	DeLArMaD
Data începere proiect:	20 Iunie 2022
Data finalizare proiect:	20 Iunie 2024
Durata (luni):	24
Buget total:	600.000 RON
Sursa 1 Bugetul de stat	600.000 RON
Sursa 2 Alte surse atrase (cofinanțare): 0	
Pagina web proiect:	
Instituția coordonatoare:	Universitatea de Medicină și Farmacie Iuliu Hațieganu
Director de proiect:	Prof. Simona Delia Nicoara
Partener 1 proiect (P1):	Universitatea Tehnică din Cluj-Napoca

Cuprins

0.1	Obiectivele proiectului	2
0.2	Gradul de maturitate tehnologică a rezultatelor cercetării	3
0.3	Rezultate științifice obținute	5
0.4	Impactul rezultatelor obținute	10
0.5	Exploatarea și diseminarea rezultatelor	11

0.1 Obiectivele proiectului

Obiectivul 1. Antrenarea și evaluarea *screening-ului* bazat pe învățare profundă (DL): Arhitecturi bazate pe rețele neuronale convoluționale (CNN) și rețele de capsule (CapsNet) vor fi antrenate pentru a clasifica scanările de tomografie în coerentă optică (OCT) ale unui pacient, colectate într-o singură vizită, ca urgente sau non-urgente. Această clasificare va ajuta la identificarea pacienților care necesită tratament imediat.

Am utilizat învățarea profundă pentru a clasifica afecțiunile ale retinei din imagini OCT, Angio OCT, și fund de ochi. Am estimat necesitatea tratamentului la pacienți cu DMLV [16]. Am construit sisteme support decizional care semnalizează medicului specialist biomarkeri relevanți (e.g. nivel de fluid [4]) sau vizualizarea 3D a neovascularizării [1].

Obiectivul 2. Antrenarea, evaluarea și explicarea diagnosticului bazat pe DL ca normal sau stadii ale DMLV: Modelele vor fi antrenate utilizând datele pacienților, inclusiv pe baza scanărilor OCT, pentru a diagnostica condițiile normale și diferitele stadii ale degenerescenței maculare legate de vârstă (AMD) - incipient, intermediar sau avansat. Pentru a colecta date relevante pentru instruire, pacienții cu diferite stadii AMD vor fi monitorizați lunar. Diagnosticul ar trebui explicat în termeni de prezență și evoluție a biomarkerilor imagistici cunoscuți.

Am formalizat stadiile AMD în ontologia AMD [12]. Am construit modele de explicare a cazurilor medicale [11]. Pentru explicațiile destinate pacientului am dezvoltat o metodă de identificare a informațiilor medicale false existente pe Internet [14]. De asemenea, am evaluat capacitatea modelelor lingvistice mari de a răspunde întrebărilor unor pacienți legate de afecțiunea DMLV [21],[9]. Am îmbunătățit algoritmi de învățare de tip white-box pentru a genera axiome în logica de descriere din date de antrenament [22]. Am utilizat ansambluri de clasificatori pentru detectia retinopatiei diabetice din imagini ale fundului de ochi [23].

Obiectivul 3: Antrenarea, evaluarea și explicarea predicției bazate pe DL a conversiei de la stadiul intermediar la stadiul avansat.

Am evaluat explicațiile generate către pacient sau medicul specialist pe baza metricilor de evaluare a explicabilității analizate în [7] și pe baza ontologiei explicațiilor dezvoltate în [11]. Am construit o metodă care verifică dacă informațiile medicale transmise pacientului sunt corecte din punct de vedere medical [14].

Obiectivul 4. Evaluarea eficacității tratamentului: Folosind modelele instruite pentru diagnostic și predicția conversiei, răspunsul DMLV neovascular (nAMD) la tratament va fi monitorizat. Metoda de evaluare trebuie să ofere explicații referitoare la evoluția biomarkerilor imagistici sau a altor caracteristici identificate prin modelele utilizate pentru Obiectivele 2 și 3.

Am dezvoltat o aplicație care ajută rezidenții în oftalmologie să identifice biomarkeri și să monitorizeze evoluția afecțiunilor. Aplicația alocă cazuri fiecărui rezident pe baza unor reguli pedagogice [10]. Am prezis evoluția acuității vizuale (e.g. pozitivă vs. negativă) la pacienți care au tratament și la cei fără tratament [17].

Obiectivul 5. Dezvoltarea unui program pentru injecțiile anti-VEGF: Utilizând modelele instruite pentru diagnostic și predicția conversiei, va fi elaborat un model pentru a prezice evoluția DMLV în funcție de diferite programe de injecție. Datele vor fi utilizate pentru a instrui modele capabile să anticipeze evoluția biomarkerilor cunoscuți sau noi, foarte predictivi. Pe baza modelului de încredere utilizat pentru luarea deciziilor, modelul va emite recomandări explicate.

Metoda dezvoltată pentru generarea planului de tratament este descrisă în [5]. Am dezvoltat o metodă pentru a genera recomandări pe baza cunoștințelor identificate și salvate în ontologie [2]. Am analizat capacitățile de predicție ale metodelor bazate pe IA în evoluția DMLV [19].

Obiectivul 6. Identificarea de noi biomarkeri și a relației lor cauzale cu DMLV. Prin interpretarea modelelor antrenate utilizate pentru atingerea obiectivelor 1, 2, 3 și 5, vor fi identificați noi biomarkeri OCT și tipare pentru evoluția DMLV.

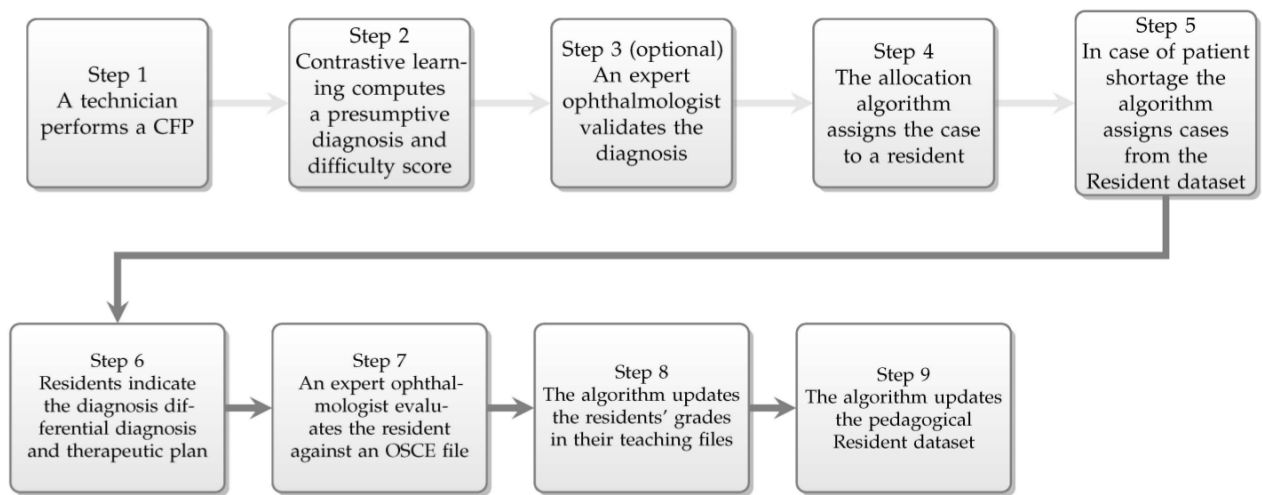


Figura 1: Algoritm de alocare a pacienților la rezidenți

#	Rule
r_1	Assign at least one case/day to each resident
r_2	Assign with priority patients presenting to the retina clinic, then, in case of shortage, CFPs from the Resident dataset
r_3	Assign one case from each of the 19 retinal conditions to each resident
r_4	Assign the case to the resident which has seen fewer cases from this retinal conditions, up to 3 cases
r_5	Assign the case to the resident with the lowest grade (performance score + difficulty score) until all residents obtain a grade ≥ 7 for every retinal condition
r_6	Assign the case to the resident with the oldest encounter for that specific condition
r_7	Assign the case to the resident with the lowest number of cases from that specific educational topic
r_8	Assign the case to the resident with the lowest number of cases from that specific retinal condition
r_9	Assign the case to the resident with the lowest number of cases from all the 19 retinal conditions

Figura 2: Exemple de reguli pentru alocarea pacienților la rezidenți

Am dezvoltat un sistem care extrage automata a relațiilor cauzale din articole științifice legate de DMLV [3], [18]. Am analizat posibili biomarkeri în imaginile OCT [8]. Am extins vizualizarea în afecțiunile de tip vitrectomie și lensectomie pentru a facilita identificarea biomarkerilor [13]. Am utilizat învățarea de tip contrastiv pentru a identifica zonele cu potențiali biomarkeri [15]. Am dezvoltat algoritmi pentru segmentarea retinei [24]. Am detectat biomarkeri din imagini OCT [29], [30].

0.2 Gradul de maturitate tehnologică a rezultatelor cercetării

Modulele bazate pe Inteligența Artificială dezvoltate au fost incluse într-o *aplicație personalizată de sistem de instruire a rezidenților în oftalmologie*. Sistemul dezvoltat alocă rezidenților pacienții care vin în clinică, urmărind ca fiecare rezident pe parcursul unui an de studiu să interacționeze cu diverse boli ale retinei. Alocarea pacienților se realizează conform pașilor din Fig. 1. Alocarea are loc pe baza unor reguli specificate de agentul uman și exemplificate în Fig. 2.

Aplicația este descrisă la <https://users.utcluj.ro/chiorana/resident.html>. și oferă două fluxuri de procesare: pentru rezidenți respectiv pentru medici specialiști în oftalmologie. În fluxul pentru rezidenți, diagnosticarea unui caz se realizează pe baza unor fișe specifice pentru afecțiunea aleasă de către rezident pentru cazul curent. Rezidenții pot marca biomarkerii direct pe imaginea de fund de ochi (Fig. 3). Medicul specialist evaluează fiecare caz finalizat de către rezidenți pe baza unei fișe de evaluare. Punctajul este acordat în funcție de corectitudinea diagnosticului și a identificării biomarkerilor (Fig. 4). Atât rezidenții cât și medicul specialist pot urmări evoluția proprie, respectiv a studenților, globală dar și detaliată la nivelul fiecărei condiții (Fig. 5).

Aplicația a fost testată într-un experiment cu 4 rezidenți de-a lungul a 4 săptămâni, în care au




Figura 3: Rezidenții pot semnaliza biomarkeri sau vizualiza imagini anterioare ale aceluiași pacient

Resident diagnosis: Central retinal vein occlusion

Predicted diagnosis: Central retinal vein occlusion

Insert date: 2023-06-28 18:15:05

Expert diagnosis: Central retinal vein occlusion

Feedback from expert: [checkmark]

Difficulty: 1 Score: 17 of 22 Grade: 7.73

[Show evaluation file](#)

Resident diagnosis: Normal

Predicted diagnosis: Optic disc edema

Insert date: 2023-06-28 18:15:05

Expert diagnosis: Age-Related Macular Degeneration (AMD)

Feedback from expert: Incorrect diagnosis - review AMD

Difficulty: 1 Score: 0 of 0 Grade: 0

[Show evaluation file](#)

Evaluation file - Central retinal vein occlusion Date: 2023-07-04 19:15:23

Correct diagnosis (calculate score) Incorrect diagnosis (0 points)

Clinical fundus signs:

<input checked="" type="checkbox"/> Collateral vascular shunt at the optic disc <input type="checkbox"/> Cotton-wool spots <input checked="" type="checkbox"/> Hard exudates <input checked="" type="checkbox"/> IRMA <input checked="" type="checkbox"/> Iris neovascularization <input checked="" type="checkbox"/> Ischemic central retinal vein occlusion <input checked="" type="checkbox"/> Macular edema <input type="checkbox"/> Macular ischemia <input type="checkbox"/> Microaneurysms <input checked="" type="checkbox"/> Neovascularization elsewhere <input type="checkbox"/> Neovascularization of the disc	<input type="checkbox"/> Non-ischemic central retinal vein occlusion <input checked="" type="checkbox"/> Optic disc edema <input checked="" type="checkbox"/> Panretinal venous dilatation and tortuosity <input type="checkbox"/> Preretinal hemorrhage <input checked="" type="checkbox"/> Retinal hemorrhages <input checked="" type="checkbox"/> Retinal vessel wall sheathing <input checked="" type="checkbox"/> Salus sign <input checked="" type="checkbox"/> Sclerosed veins <input type="checkbox"/> Telangiectatic vessels <input type="checkbox"/> Tractional retinal detachment <input checked="" type="checkbox"/> Vitreous hemorrhage
----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Resident scored [13] points of a total of 22

Figura 4: Evaluarea de către medicul specialist a cazurilor finalizate de rezidenți

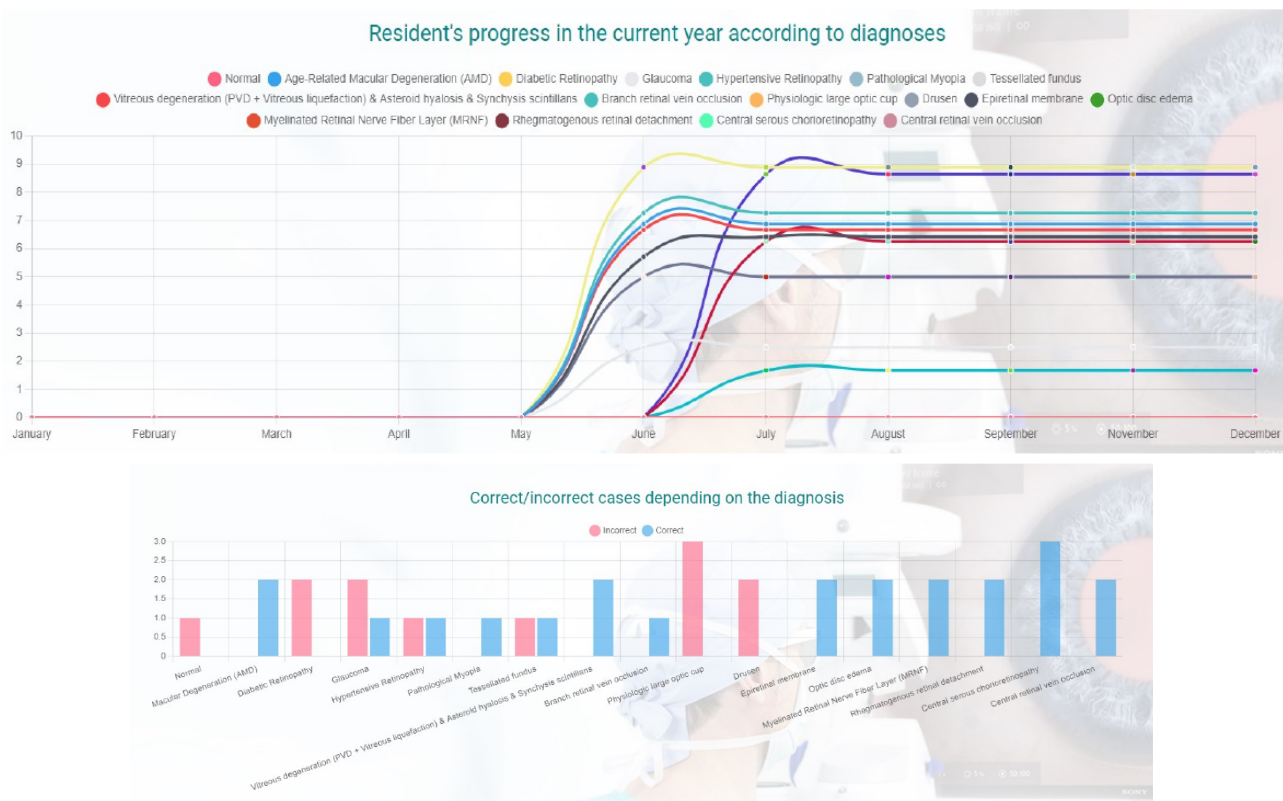


Figura 5: Monitorizarea evolutiei rezidentilor

primit cazuri dintr-un set prestabilit de 200 de imagini. Evaluarea medicului specialist s-a realizat pe parcursul experimentului. La finalizarea experimentului s-a organizat un Workshop în cadrul căruia s-au analizat împreună cu toți participanții rezultatele. Feedbackul a fost unul pozitiv, atât din punct de vedere al funcționalităților oferite, cât și al impactului pozitiv asupra învățării. Din perspectiva medicului specialist, avantajul major a venit din identificarea tipurilor de erori realizate în special la nivelul modificărilor din imagini. Aplicația a fost folosită începând cu luna Octombrie 2023 până în Martie 2024 pe cazuri reale din practica Spitalului Județean, cu un grup de 4 rezidenți. Astfel, fiind testată în condiții clinice pe cazuri reale, nivelul atins de aplicație este TRL 6.

0.3 Rezultate științifice obținute


Dezvoltarea unei ontologii pentru DMLV. Ontologia formalizează biomarkeri pentru degenerescența maculară legată de vârstă [12]. Biomarkeri sunt formalizați în logica de descriere conform definițiilor din protocoalele medicale utilizate în diagnosticul și tratamentele aplicate pentru DMLV. Exemple de astfel de definiții apar în Fig. 6. Dezvoltarea ontologiei s-a bazat pe ontologiile medicale existente precum Anatomy ontology, Human Disease, Experimental Factor Ontology, SNOMED, BiologicalSpatial Ontology, Relation ontology, Symptom ontology. Având această ontologie se pot formaliza biomarkerii din imaginile OCT sau fund de ochi (Fig. 7).

Identificarea provocărilor utilizării IA în cadrul clinic. Cercetarea [19] include și o analiză a provocărilor legate de utilizarea instrumentelor bazate pe IA în practică. Aceste provocări includ: (i) insuficiența datelor pentru pacienții cu AMD, care au avut mai multe vizite de urmărire; (ii) varietatea dispozitivelor și a protocoalelor de achiziție a imaginilor OCT; (iii) calitatea adnotării datelor (e.g. în diagnosticare, acuratețea medie a experților medicali variază între 80% și 90%, în timp ce rata medie de eroare între radiologi este în jur de 30%. Numărul de anotații necesari pentru a obține etichete

Sample of definitions and classifications scales for AMD	
	Epidemiological classification (Wisconsin grading)
$EarlyAMD^W$	$\equiv AMD \sqcap \exists hasBiomarker.(LargeDrusen \sqcup RetinalPseudodrusen \sqcup PigmentaryAbn)$
$LateAMD^W$	$\equiv NeovascularAMD \sqcup GeographicAtropy$
	Basic clinical classification
$NoAgeingChanges^C$	$\equiv \forall hasDrusen.\perp \sqcap \forall hasAbn.\neg PigmentaryAbn$
$NormalAgeingChanges^C$	$\equiv \forall hasDrusen.SmallDrusen \sqcap \forall hasAbn.\neg PigmentaryAbn$
$EarlyAMD^C$	$\equiv AMD \sqcap \exists hasBiomarker.MediumDrusen \sqcap \forall hasAbnormalities.\neg PigmentaryAbnormalities$
$IntermediateAMD^C$	$\equiv AMD \sqcap (\exists hasBiomarker.LargeDrusen \sqcap \exists hasAbnormalities.\neg PigmentaryAbnormalities)$
$LateAMD^C$	$\equiv NeovascularAMD \sqcup GeographicAtropy$
	AREDS simplified severity scale points
$Severity_0$	$\equiv \forall hasBiomarker.\neg LargeDrusen \sqcup \forall changes.\neg Pigment$
$Severity_1$	$\equiv \exists hasBiomarker.\neg LargeDrusen \sqcup (= 1)changes.Pigment$
$Severity_4$	$\equiv (> 1)hasBiomarker.LargeDrusen \sqcap (> 1)changes.Pigment \sqcap$

Figura 6: Clasificarea severității bolii DMLV in logica de descriere

$$\begin{aligned}
 f_3 : hasDisease.WetAMD \sqcap \exists hasBM.(Type2CNVM \sqcap isAbove.RPE \sqcap \exists hasAdjacentBM.SRF \sqcap \forall hasAdjacentBM.SRF) & \quad (1) \\
 f_3 : \exists hasBM.(Exudate \sqcap isLocated.Nasal) & \\
 Type1CNVM \sqsubseteq CNVM \sqcap \exists isBeneath.RPE \sqcap & \\
 \exists appear.(Fibrovascular \sqcup HemorrhagicPigmentEpithelialDetachment) & \quad (2) \\
 Type2CNVM \sqsubseteq CNVM \sqcap \exists isAbove.RPE \sqcap \exists hasAdjacentBM.SRF & \quad (3)
 \end{aligned}$$



$Pseudocysts \sqsubseteq \exists hasShape.Circular \sqcap \exists hasReflection.hyporeflective$

Figura 7: Utilizarea ontologies AMD pentru adnotarea imaginilor




Figura 8: Procesarea imaginilor: egalizare adaptiva, normalizare culori, filtru gaussian




Figura 9: Procesarea imaginilor fundului de ochi: eliminarea discului optic și a vaselor de sânge

corecte cu o siguranță de 95%. Pentru o rată de eroare de 20%, sunt necesari 10 evaluatori, în timp ce pentru o rată de eroare de 30%, numărul de evaluatori ar trebui să fie cel puțin 25). (iv) lipsa validării clinice; (v) opacitate. Analiza acestor provocări și posibile soluții sunt discutate în [19].

Detectarea severității retinopatiei diabetice din imagini ale fundului de ochi. Metoda propusă are trei etape [23]. În prima etapă, imaginile disponibile sunt procesate prin: egalizare adaptivă, normalizare a culorii, filtru Gaussian, îndepărtarea discului optic și a vaselor de sânge (Fig. 8). Ulterior se elimină din imagine discul optic și vasele de sânge (Fig. 9). În a doua etapă, imaginile sunt segmentate în funcție de biomarkerii relevanți și sunt extrase caracteristici din imaginile fundului de ochi (Fig. 10). În a treia etapă, se aplică ansamblu de clasificatori și se evaluează încrederea în rezultatul obținut prin învățarea automată.

Segmentarea fluidului pentru DMLV din imagini OCT. Obiectivul a constat în identificarea biomarkerilor pentru condiția DMLV prin segmentarea imaginilor de tomografie cu coerență optică (OCT) a retinei. Am propus o soluție originală hibridă care combină segmentarea retiniană bazată pe învățare adâncă cu clasificarea imaginii bazată pe caracteristici [4]. Metoda este utilizată pentru a distinge între o anumită zonă de fluid și zonele retiniene învecinate. În acest context, efectuăm o analiză comparativă a diferitelor tehnici de segmentare semantică, care oferă rezultate pentru segmentarea stratului retinian. Din cauza reprezentării reduse a unor fluide în setul de date de referință considerat, abordăm și îmbunătățim recunoașterea lor prin clasificarea texturii bazată pe regiuni de interes (Fig 11).

Identificarea membranei neovasculare prin metode clasice de procesare de imagini Obiectivul a fost identificarea zonei în care apare membrana neovasculară folosind metode de procesare de imagini binare, bazate pe algoritmi de binarizare și extragere de contururi.

Prezicerea planurilor de tratament pentru pacienții cu DMLV. Arhitectura utilizată pentru prezicere apare în Fig. 13 [5], [16]. Pentru facilitarea explicațiilor, sistemul este extins cu funcționalități de vizualizare (Fig. 14 și 15).




Fig. 8. Segmentation result of soft exudates (areas in pink)




Fig. 9. Segmentation result of hard exudates (neon green areas)




Fig. 7. Segmentation result with and without blood vessels (dark green areas)

Figura 10: Identificarea biomarkerilor: *hard exudates* sau *soft exudates*




Figura 11: Segmentarea imaginilor OCT: sunt identificate straturile retinei și zonele cu fluid




Figura 12: Identificarea membranei neovasculare in imagini OCT (a) imaginea originala, (b) masca cu valoarea de adevăr; (c) masca prezisă albastru - true positive, verde false positive, rosu - false negative

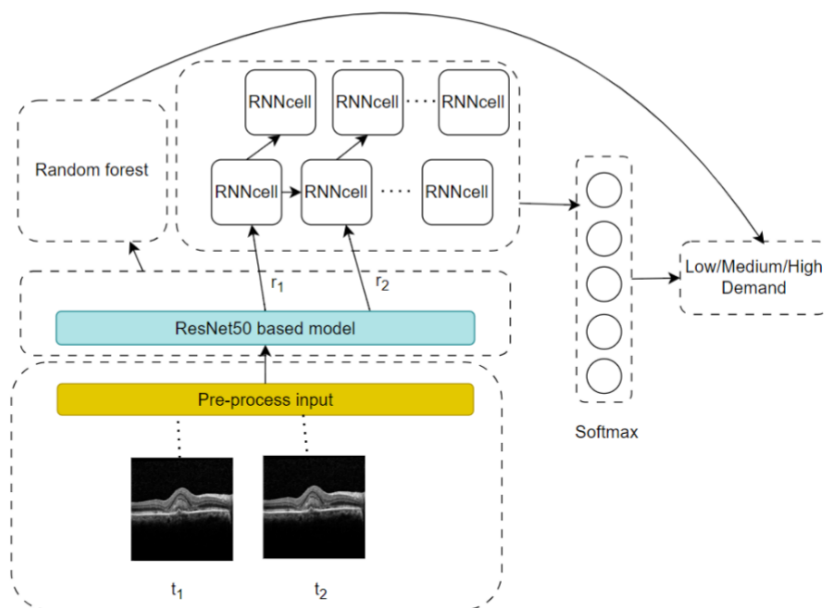


Figura 13: Arhitectura utilizată în prezicerea tratamentului pentru pacienții cu DMLV


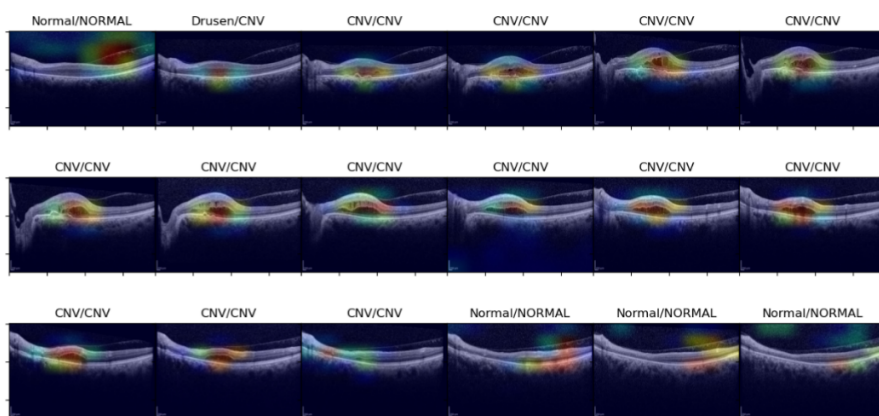


Fig. 3. Confusion matrix for NEH-model D1 test set

Figura 14: Vizualizare de tip Grad-cam a modelului a unui pacient cu CNV

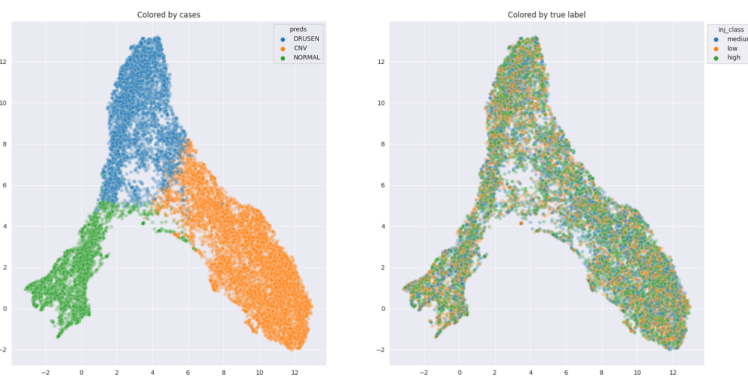


Figura 15: Vizualizare 2D UMAP a modelului invatat. Fiecare B-scan este colorat cu clasa corespunzatoare celei mai probabile predicții (stanga). Colorarea este în funcție de nevoia de tratament CNV (dreapta)




Figura 16: Vizualizarea 3D a zonei neovasculare și compararea a două scanări la intervale diferite

Lucrare	Citari	Exemple
[19]	8	Mares, V., Nehemy, M.B., Bogunovic, H., Frank, S., Reiter, G. S., Schmidt-Erfurth, U. AI-based support for optical coherence tomography in age-related macular degeneration. Int J Retin Vitro 10, 31 (2024).
[20]	1	
[17]	1	

Tabela 1: Citari ale lucrarilor publicate

Detectarea biomarkerilor pentru retinopatie diabetica din OCT. S-a validat abilitatea unor arhitecturi noi (EfficientNetV2B1, ConvNeXt) de a diferenția sănătos vs bolnav chiar și fără modificarea parametrilor preantrași ai acestora, ceea ce înseamnă că trăsăturile extrase de reprezentarea densă conțin informație relevantă pentru diagnosticare. S-a construit un model de identificare a prezenței unuia dintre biomarkerii: Foci hiperreflectivi, Detașare, edem fără a folosi date adnotate la nivel de pixel [29].

Detectarea automata a imaginilor cu adnotari incerte S-a dezvoltat o metoda de identificare automata a imaginilor cu adnotari incerte. In domeniul medical, adnotarea precisa a tuturor detaliilor, de ex prezenta tuturor biomarkerilor in toate imaginile dintr-un volum OCT este o provocare. Diagnosticul corect poate fi pus de catre specialistul uman pe baza analizei precise a unui subset de imagini din volum, inasa pentru invatarea unor modele automate, imagini imprecis adnotate pot afecta negativ calitatea finala a modelului. Metoda propusa adreseaza doua functionalitati: in primul rand, identificarea imaginilor incerte care ulterior ar putea fi readnotate de catre medic, si in al doilea rand, construirea unui model care nu e afectat de astfel de imagini incerte, chiar si fara reverificarea lor de catre specialist [6]. Metoda a fost testata pe un set de date naturale unde s-a modificat intentionat adnotarea, respectiv pe setul de date OCT folosit in [29].

Creearea unui model 3D a vaselor de sange cuprinse in zona de neovascularizare. Am reușit să izolam zona neovascularizată, să identificăm vasele de sânge și am construit modelul 3D al zonei de interes. De asemenea am calculat volumul acestora și am comparat două scanări ale aceluiași pacient la intervale diferite (Fig. 16) [1].

0.4 Impactul rezultatelor obținute

Articolele rezultate din proiect au, pana la momentul elaborarii prezentului raport, un numar cumulat de peste 10 citari. Tabelul 1 prezinta cateva astfel de exemple

Transfer de cunoștințe la operator economic. Prin intermediul Transilvania Digital Innovation Hub am aplicat pentru finanțarea proiectării unui chiosc de telemedicină în oftalmologie în perioada decembrie 2023-septembrie 2024. Cunoștințele dobândite în cadrul acestui proiect vor fi transferate la un operator economic pentru dezvoltarea unui astfel de chiosc. Dispozitivul medical de captare a imaginilor fundului de ochi achiziționat în cadrul proiectului va fi utilizat în proiectarea unui chiosc oftalmologic. Aplicația va fi proiectată conform standardului HIPAA și a noului regulament privind inteligența artificială (AI Act). Modulele de inteligență artificială vizate vor ajuta în identificarea dacă imaginile retinei (fund de ochi și OCT) au fost preluate corect, semnalizând cazurile de defocalizare, artefacte sau luminozitate prea mare. De asemenea, inteligența artificială va fi utilizată pentru semnalizarea unor posibile condiții ale retinei. Din punct de vedere tehnic este o problemă de clasificare binară a imaginilor retinei în două clase: ochi sănătoși//ochi cu posibile probleme.

Crearea unui centru de etichetare de imagini medicale. Prin intermediul Transilvania Digital Innovation Hub am obținut finanțare pentru înființarea unui centru de etichetare de imagini medicale în domeniul oftalmologic. Provocarile sunt legate de faptul că datele medicale trebuie etichetate conform unor metodologii și standarde de asigurare a calității. Etichetarea corectă se obține de către personal care va urma cursuri de certificare a calității de anotator de date medicale. Urmărim perfecționarea rezidenților, masteranzilor și doctoranzilor. De asemenea, evaluarea calității datelor este un o etapă necesară pentru a valida pașii de antrenare a algoritmilor de învățare. Viziunea legată de acest centru este de a crea un efect în lanț în dezvoltarea la nivel național a sistemelor bazate pe IA care utilizează date din domeniul medical. Experiența obținută în proiectul curent va fi aplicată în cadrul acestui *Centru de etichetare date pentru domeniul oftalmologic*. Urmărim de asemenea interacțiunea dintre acest centru cu Spațiile Europene de date medicale (Common European Data Spaces), cu HUB-ul Român de Inteligență Artificială (HRIA) și cu Institutul de Inteligență Artificială al Universității Tehnice din Cluj-Napoca și care include ca domeniu strategic de cercetare domeniul medical.

0.5 Exploatarea și diseminarea rezultatelor

Rezultatele au fost diseminate și în cadrul unor seminarii (Tabelul 2).

Analiza capabilităților de predicție a IA pe imagini OCT. Scopul acestei recenzii este de a identifica și evalua abordările care aplică inteligența artificială pe imaginile cu tomografie cu coerență optică (OCT) pentru a prezice evoluția degenerescenței maculare asociate vârstei (AMD). Căutarea a vizat șapte baze de date, până la 1 ianuarie 2022, folosind ghidurile PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), fiind identificate 1800 de înregistrări. După evaluarea inițială, 48 de articole au fost selectate pentru regăsirea textului integral și, în cele din urmă, au fost incluse 19 articole. Din aceste 19 articole, 4 articole s-au concentrat pe prezicerea cerinței anti-VEGF în AMD neovasculară (nAMD), 4 articole s-au concentrat pe prezicerea eficacității anti-VEGF la pacienții cu nAMD, 3 articole au prezis conversia de la AMD precoce sau intermediară (iAMD) la nAMD, 1 articol a prezis conversia de la iAMD la atrofie geografică (GA), 1 articol a prezis conversia de la iAMD atât la nAMD, cât și la GA, 3 articole au prezis creșterea GA și 3 articole prezic acuitatea vizuală (VA) după tratament anti-VEGF la pacienții cu nAMD. Deoarece utilizarea metodelor AI pentru a prezice evoluția AMD este doar în faza sa inițială, o astfel de recenzie stabilește contextul lucrărilor existente și poate reprezenta un punct de plecare pentru cercetările viitoare. (Articol ISI, Q2 [19])

Alocarea pacienților la rezidenți. Centrele de formare de rezidenți se confruntă cu provocări în încercarea de a crea programe de rezidențiat echilibrate, cazurile întâlnite de rezidenți nu fiind întotdeauna distribuite în mod eficient din punct de vedere didactic între ei. Propunem un sistem de formare personalizată de rezidențiat în oftalmologie. Sistemul este construit pe două componente: (1) un model de învățare profundă (DL) și (2) un algoritm de alocare a cazurilor către rezidenți bazat pe sisteme expert. Modelul DL este antrenat pe

Tabela 2: Diseminarea rezultatelor la seminarii

Cercetător	Prezentare	Eveniment
A. Groza	Eyes on A.I.	Progress and Innovation in Ophthalmology, Cluj-Napoca, 6 Decembrie 2023
A Marginean	Enhancing OCT and Eye Fundus Image Interpretation with Deep Learning	Progress and Innovation in Ophthalmology, Cluj-Napoca, 6 Decembrie 2023
R. R. Slavescu	Detection of nAMD using Transformer Architectures - Preliminary Experiments	Progress and Innovation in Ophthalmology, Cluj-Napoca 6 Decembrie 2023
A. Groza	Interleaving machine learning with reasoning for identifying retinal conditions	Smart Diaspora 2023, Workshop Abordări orientate către om pentru Inteligență Artificială deîncredere (Trust-AI), 10-13 Aprilie 2023, Timisoara
A. Groza	Interleaving machine learning with reasoning for identifying retinal conditions	Aplicații ale Inteligenței Artificiale în Medicină (AIAM), 30 Martie 2023, Bucuresti, Romania
R. R. Slavescu	Alocarea cazurilor la medicii rezidenți	Zilele UMF, 5 Decembrie 2022
A. Groza	Artificial Intelligence in Ophthalmology	RePatriot, Inteligența Artificială aplicată în domeniul sănătății, 21 Noiembrie, 2022
A Groza	Ongoing Research at Intelligent Systems Group	Transilvania Digital Innovation Hub, Cluj-Napoca, Romania, 24 November, 2022

seturi de date disponibile public prin intermediul învățării contrastive și poate clasifica bolile retiniene din imaginile de tip fund de ochi (CFP). Imaginea CFP este interpretată de modelul DL, care va da un diagnostic prezumtiv. Acest diagnostic este apoi transmis unui algoritm de alocare a cazurilor care selectează rezidentul care ar beneficia cel mai mult de pe urma cazului specific, pe baza istoricului și performanței respectivului rezident. La finalul fiecărui caz, medicul expert curant evaluează performanța rezidentului pe baza dosarelor de examinare standardizate, iar rezultatele sunt actualizate imediat în portofoliul acestora. Abordarea noastră oferă o structură pentru viitoarea educație medicală de precizie în oftalmologie. (Articol ISI, Q2 [20])

Verificarea informațiilor medicale. Abordăm problema informațiilor medicale false care sunt distribuite pe internet. Am dezvoltat o unealtă pentru verificarea informațiilor medicale bazată pe patru tehnologii: (i) Ontologia Superioară Unificată (SUMO) pentru reprezentarea cunoștințelor, (ii) demonstratorul de teoreme Vampire pentru verificarea faptelor, (iii) WordNet și (iv) GPT (Generative Pre-trained Transformer) pentru învățarea și alinierea conceptelor. (Workshop indexat DBLP [14])

Dezvoltare de algoritmi de învățare de tipul *white-box* pentru a putea furniza explicații medicului specialist. În domeniul medical este important ca algoritmi de învățare automată utilizați să fie transparenți pentru a putea explica decizia propusă. Astfel, am dezvoltat algoritmi de învățare automată de tip "white-box". Ne-am focalizat pe algoritmi pentru învățarea axiomei în logică descriptivă. Am extins algoritmul Class Expression Learning for Ontology Engineering (CELOE), parte a unelei DL-Learner. Abordarea utilizează mai mulți arbori de căutare și operatori de rafinare a conceptelor învățate pentru a împărți spațiul de căutare în subspații mai mici. Introducem operația de conjuncție a celor mai bune expresii de clasă din fiecare arbore, păstrând rezultatele care oferă cele mai multe informații. Scopul este de a stimula explorarea dintr-un set divers de concepte de pornire și de a simplifica procesul de găsimă a definițiilor unor concepte din ontologii. Conceptele învățate din date vor putea fi analizate de medicul oftalmolog pentru validarea sau invalidarea ipotezelor identificate de către algoritmi de învățare automată (Lucrare Scopus [22])

Metode de extindere a ontologiei DMLV pe baza articolelor științifice utilizând modele lingvistice mari.

Cunoștințele experților în domeniul oftalmologic pot fi formalizate în ontologii medicale. Aceste cunoștințe expert pot fi extrase direct din articole științifice. Am investigat posibilitatea de îmbogățire a ontologiilor medicale prin traducerea automată a propozițiilor din limbaj natural în Logică Descriptivă. Deoarece Modelele Mari de Limbaj (LLM) sunt cele mai bune instrumente disponibile pentru traduceri, am ajustat un model GPT-3 pentru a converti propozițiile în Limbaj Funcțional OWL. Am furnizat exemple de traduceri pentru a antrena modelul legat de: instanțe, subsumarea claselor, domeniul și codomeniul relațiilor, relațiile, clasele disjuncte, restricțiile de cardinalitate. Axiomele rezultate sunt utilizate pentru a îmbogăți o ontologie, într-un mod supervizat de către agentul uman. Unealta dezvoltată este disponibilă ca plugin pentru editorul Protégé. Urmărim extinderea ontologiei DMLV cu informații extrase din articole științifice. (Lucrare ISI, IEEEExplore [18])

Detectarea nivelurilor de severitate ale retinopatiei diabetice. În cazul retinopatiei diabetice, vasele de sânge din retina se deteriorează și pot duce la sângerare, umflare și alte modificări care afectează vederea. Am propus o metodă pentru detectarea nivelurilor de severitate ale retinopatiei diabetice. Într-o prima etapă, imaginile disponibile sunt procesate prin: egalizare adaptivă, normalizare a culorii, filtru Gaussian, îndepărtarea discului optic și a vaselor de sânge. În a doua etapă, efectuăm segmentarea imaginilor pentru biomarkeri relevanți și extragem caracteristici din imaginile fundului de ochi. În a treia etapă, aplicăm un ansamblu de clasificatori și evaluăm încrederea în rezultatul obținut prin învățarea automată. (Lucrare DBLP [23])

Identificarea biomarkerilor pentru DMLV prin segmentarea imaginilor OCT. Clasificarea imaginilor medicale este considerată rezolvată din perspectiva tehnică: date fiind suficient de multe imagini - în termeni de cantitate, calitate și distribuție - algoritmi de învățare automată sunt capabili să clasifice diverse afecțiuni. Cu toate acestea, un dezavantaj este că majoritatea abordărilor vizează direct semnalizarea bolii, fără a lua deloc în considerare protocoalele sau ghidurile medicale utilizate de clinicieni. Abordăm decalajul dintre protocoalele clinice și soluțiile oferite de IA. În loc să urmărim detecția bolii cu instrumente de învățare profundă, ne propunem să identificăm doar biomarkerii căutați de medici conform protocoalelor medicale pentru DMLV. Soluția propusă combină segmentarea retiniană bazată pe învățare adâncă cu clasificarea imaginii bazată pe caracteristici. Metoda poate distinge între o anumită zonă de fluid și zonele retiniene învecinate. Din cauza reprezentării reduse a unor fluide în setul de date de referință considerat, abordăm și îmbunătățim recunoașterea lor prin clasificarea texturii bazată pe regiuni de interes. Abordarea propusă reprezintă un pas către dezvoltarea sistemelor de IA în concordanță cu protocoalele medicale în desfășurare. (Lucrare ISI [4])

Ontologie pentru DMLV. Ne propunem să sprijinim monitorizarea ghidurilor curente și a informațiilor științifice în managementul degenerescenței maculare legate de vârstă (AMD) pentru a ajuta specialiștii în retină să dezvolte un protocol clinic pentru abordările terapeutice ale AMD. În primul rând, am dezvoltat o ontologie pentru condiția AMD folosind informații din literatură, ontologii medicale conexe și cunoștințe de domeniu de la oftalmologi. În al doilea rând, am populat și îmbogățit ontologia AMD folosind cunoștințe structurate extrase din literatura medicală cu ajutorul modelului de limbaj GPT-3. În al treilea rând, am aplicat algoritmi de raționare pe cunoștințele formalizate în ontologie pentru a semnaliza oftalmologului diferențe sau inconsistențe între diferite studii clinice, protocoale sau abordări terapeutice specifice AMD. (Workshop indexat DBLP [12])

Metoda de generare a explicațiilor. În domeniul medical, capacitatea unui sistem bazat pe IA de a explica modul în care a ajuns la o decizie este importantă pentru a câștiga încrederea în sistem, pentru a înțelege modul său de funcționare și, posibil, pentru a obține cunoștințe noi și mai generalizabile. Cu agenții de inteligență artificială devenind tot mai complexi și răspândiți, există un interes tot mai mare în dotarea lor cu abilitatea de a se explica. Cu toate acestea, explicațiile sunt mai mult decât o chestiune de integrare a tehnicilor pentru a aproxima modelele de învățare automată prin tehnici mai simple; explicațiile sunt acte de comunicare interactive care trebuie adaptate intereselor persoanei care caută explicații. Pentru a ușura

reprezentarea obiectivelor de comunicare din spatele unei explicații, propunem ontologia ”Explanation Interchange Format”, care are mai multe scopuri. În primul rând, descrie formal actul de comunicare a explicațiilor și structura sa bazată pe lucrări teoretice existente referitoare la explicațiile științifice. În al doilea rând, ontologia permite raționamentul pentru a construi explicații, de exemplu, selectând structuri explicative adecvate intereselor celui care pune întrebările. (Capitol carte SpringerLink [11])

Metoda pentru administrarea injecțiilor anti-VEGF. Coerența Optică reprezintă o examinare non-invazivă care nu numai că poate ajuta clinicienii să diagnosticheze multiple anomalii retiniene, inclusiv AMD, dar și să monitorizeze progresul bolii. Există încă nevoi în ceea ce privește tratamentul personalizat pentru pacienții care suferă de AMD, fiind o boală care prezintă diversitate individuală în ceea ce privește progresia și rezultatele sale. Propunem o metodă care va utiliza tehnologii de învățare adâncă pentru a analiza progresul bolii la pacienți și posibilele rezultate, Metoda propusă se bazează exclusiv pe scanările OCT realizate în primele două examinări inițiale. Propunem o arhitectură care va ajuta oftalmologii în administrarea injecțiilor anti-VEGF, tratamentul standard pentru AMD neovascular avansată. Arhitectura se bazează pe caracteristici extrase din B-scanurile unui volum OCT și, prin practici de transfer learning, va prezice cantitatea totală de injecții necesară pentru o persoană aflată în tratament, decizia pentru următoarea vizită de administrare a injecției, precum și acuitatea vizuală la următoarea vizită. (Lucrare ISI proceedings [5])

Metode de extindere a seturilor de imagini medicale adnotate. În scopul alcătuirii unui set extins de imagini medicale, inclusiv a măștilor aferente, s-a antrenat un model bazat pe FCBBFormer, reușindu-se obținerea a două versiuni promițătoare. Prima se bazează pe optimizatorul AdaBelief pentru antrenare, iar ca funcție de loss utilizează o sumă ponderată între binary cross entropy și coeficientul Dice. Pe testele efectuate, se ating valori pentru Precision și coeficientul Dice superioare celor oferite de arhitectura de bază FCBBFormer. Cea de a doua utilizează optimizatorul Adam pentru antrenare și binary cross entropy ca funcție de loss. Se obțin valori mai bune pentru Recall și Precision (0,95, respectiv 0,998), cu prețul unei scăderi ușoare a valorii scorului Dice (de la 0,93 la 0,92). Deși viza inițial detectarea automată a polipilor, metoda este suficient de generală pentru a fi utilizată și în alte tipuri de imagini. (Lucrare ISI proceedings [28], poster [24])

Clasificarea afecțiunilor retinei. Degenerescenta maculară legată de vârstă (AMD), o cauză principală a pierderii vederii la adulții mai în vârstă, reprezintă o provocare semnificativă în dezvoltarea strategiilor personalizate de tratament datorită modelelor diverse de progresie și rezultatelor. Tomografia cu Coerență Optică (OCT), o unealtă diagnostică non-invazivă, oferă clinicienilor un mijloc valoros de identificare a diferitelor anomalii retiniene, inclusiv AMD, și de urmărire a progresiei bolii. Diferențierea între sănătos și AMD sau retinopatie diabetică în OCT nu reprezintă o provocare atât de mare pentru arhitecturile de pre-antrenare a viziunii curente. Lucrarea actuală explorează utilizarea învățării transfer pentru a trece de la B-scans la volume și secvențe de volume. Transferul este de la o sarcină destul de generală de clasificare între Normal, CNV și Drusen, la o sarcină specifică de recunoaștere a semnelor timpurii care indică progresia viitoare a bolii. Diferite tipuri de caracteristici de bază și agregare sunt combinate cu arhitecturi EfficientNetV2 pe două seturi de date: un set de date care include volume cu adnotări la nivelul B-scans și la nivelul volumului, respectiv un set de date care include 94 de pacienți și istoricul lor de tratament. Primele două examinări din ultimul set de date sunt luate în considerare pentru estimarea administrării injecțiilor anti-VEGF. Experimentele sugerează că arhitecturile pre-antrenate sunt capabile să surprindă nu numai prezența bolii, ci și elemente relevante pentru evoluția bolii, fără a avea nevoie de adnotări complexe precum cele necesare în segmentarea semantică. Atunci când rețelele sunt capabile să identifice aspecte pentru care nu au fost antrenate explicit pentru a le recunoaște, descoperirea de noi biomarkere, o mai bună înțelegere a bolii și tratamente personalizate devin mai fezabile. (Lucrare ISI proceedings [16])

Diseminarea către societate și public. La finalul proiectului (Mai 2024) am organizat două evenimente de diseminare a rezultatelor către public. Modulul de reconstrucție 3D a neovascularității în imagini AngioOCT pentru NAMD a fost prezentat la Noaptea Muzeelor (Fig. 18), 24 Mai 2024, HUB UTCN, Cluj-Napoca (Fig. 19). Modulul de clasificare a afecțiunilor retinei pe baza imaginilor

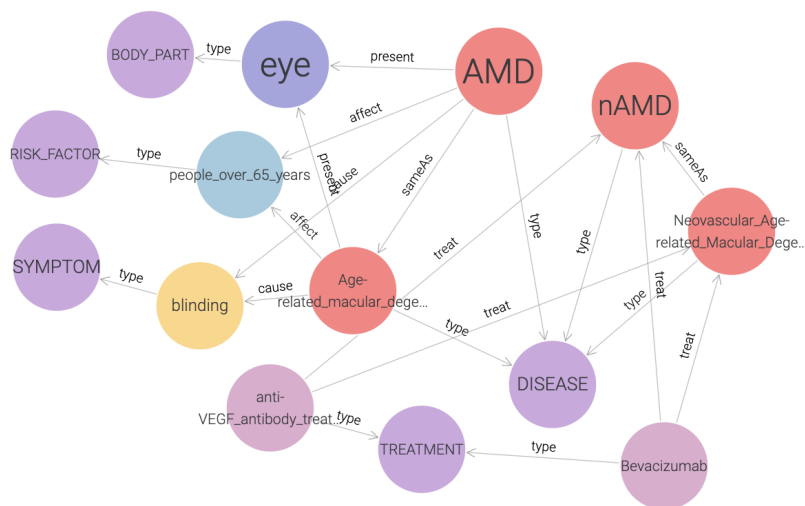


Figura 17: Graf de cunoștințe cauzale extrase dintr-un articol științific

Tabela 3: Seturi de date oftalmologie dezvoltate in cadrul proiectului

Set de date	Descriere	Ref.
ReziOCT	10,592 imagini fund de ochi clasificate in 39 de clase preluate din seturi de date publice (ODIR, RFMID, JSIEC). Adnotările au fost aliniate de către medic specialist.	[20]
BioMs DR	2660 imagini OCT de la 52 de pacienți cu informații despre prezența unuia sau mai multor biomarkeri ai retinopatiei diabetice: edem in 1615, detașare in 330, foci in 2096, respectiv 510 imagini cu aspect sănătos.	[29]
CausalAMD	70 rezumate ale articolelor științifice legate de DMLV. (numar mediu de cuvinte 350). Rezumatele au fost adnotate cu ajutorul uneltei Prodigy cu 9 relatii cauzale si entitatile denumite corespunzatoare	[3]
DLMV FollowUp	Contine valorile acuitatii vizuale la 98 de pacienti la 4 vizite succesive $LTFU_0$, $LTFU+3$, $LTFU_6$, respectiv $LTFU+12$ luni. Pentru fiecare pacient sunt colectate 16 caracteristici (e.g. sex, varsta, mediu, ocupatie, severitate OD, severitate OS, vitrectomie	[17]

Tabela 4: Utilizarea expertizei obținute și continuarea colaborării în cercetări ulterioare

Titlu proiect	Partener	Apel	Status
1 Crearea unui centru de etichetare de imagini oftalmologice	SCJ Cluj	TDIH	acceptat
2 Evaluarea urgentelor pediatrice utilizand inteligenta artificiala	Peditech	TDIH	acceptat
3 Utilizarea învățării profunde și a reprezentării cunoștințelor pentru formarea personalizată în rezidențiatul de oftalmologie	Easeful S.R.L.	PED	in evaluare
4 Telemedicina asistată de IA pentru îmbunătățirea tratării bolilor de retină: screening, biomarkeri, sugerare diagnostic și monitorizare pacienți	Brainoble Appsmart și UMF	PTE	in evaluare
5 Dezvoltarea unui asistent virtual personalizat, cu AI, folosind ceasuri de mână inteligente, pentru pacienții cu Alzheimer sau demență	UEFISCDI și TUBI-TAK	mobilități RO-TR	in evaluare




Figura 18: Prezentarea la evenimentul public “Noaptea Muzeelor” a chioșcului de telemedicina oftalmologică și a modului de reconstrucție 3D a neovascularității în imagini AngioOCT pentru NAMD



Figura 19: Prezentarea modului de clasificare a afecțiunilor retinei pe baza imaginilor de tip fund de ochi în cadrul evenimentului AI@UTCN, deschis către cetățeni

de tip fund de ochi a fost prezentat în cadrul evenimentului public AI@UTCN, deschis către public, eveniment diseminat și pe platformele X și Instagram.

Bibliografie

- [1] Pop Adrian, Adrian Groza, Damian Ioana, and Simona Delia Nicoara. 3D reconstruction, volume approximation and evolution comparison of neovascularization in Age-Related Macular Degeneration. MEDITECH2024. Springer, 2024.
- [2] Aron Katona Adrian Groza. FACE: Fact Checker with Explanations. In *24th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing*, SYNASC22, 2022.
- [3] Lecu Alex, Groza Adrian, and Lezan Hawizy. Extracting causal relations from medical abstracts using fine-tuned LLMs and knowledge graphs. In under review, editor, *6th International Conference on AI in Computational Linguistic*, ACLing, 2024. Elsevier.
- [4] Raluca Brehar, Adrian Groza, Ioana Damian, George Muntean, and Simona Delia Nicoara. Age-Related Macular Degeneration Biomarker Segmentation from OCT images. In *24th International Conference on Control Systems and Computer Science*, CSCS23, pages 444–451. IEEE, 2023.

Livrabile/indicatori planificați	Nr.	Livrabile/indicatori realizați	Nr.
Articole ISI	5	[19],[20], [17], [29], [13], [8]	6
Articole in reviste	0	[30]	1
Capitole carte	0	[11]	1
Lucrari la conferințe	9	[18],[5],[16], [28], [4], [24], [26], [27], [1], [9], [3], [25] [14], [12], [10]	15
Rapoarte tehnice si financiare	5	3 rapoarte anuale, 1 raport de utilizare a aplicatiei pentru rezidenti, 1 raport tehnic	5
Ghid de utilizare a aplicatiei	1	Link	1
Organizare workshop-uri științifice	0	Zilele UMF	
Organizare evenimente publice	0	Noaptea Muzeelor, AI@UTCN	2
Seturi de date in oftalmologie	1	Descrise in [20], [3],	4
Ontologii	0	OntoAMD [12, 14, 2], CausalAMD [3]	2
Valorificarea expertizei: proiecte câștigate		Centru de etichetare de date, Evaluarea urgențelor pediatrice	2
Valorificarea expertizei: proiecte în evaluare	0	PED2023, PTE2023	2

- [5] Alexandra Ioana Bucur, George Adrian Muntean, Anca Marginean, and Simona Delia Nicoara. Predicting necessary treatment plans for patients with Age-Related Macular Degeneration using characteristics derived from optical coherence tomography B-scans. In *Int. Conf. on Intelligent Computer Communication and Processing, ICCP23*. IEEE, 2023.
- [6] Adrian Ciu and Anca Marginean. Self-healing model from uncertain data. In *Int. Conf. on Intelligent Computer Communication and Processing - in review*, 2024.
- [7] Loredana Coroama and Adrian Groza. Evaluation Metrics in Explainable Artificial Intelligence (XAI). In Teresa Guarda, Filipe Portela, and Maria Fernanda Augusto, editors, *Advanced Research in Technologies, Information, Innovation and Sustainability*, ARTIIS'22, pages 401–413, Cham, 2022. Springer Nature Switzerland.
- [8] Ioana Damian, George-Adrian Muntean, Larisa-Bianca Galea-Holhoş, and Simona-Delia Nicoară. Advanced ImageJ Analysis in Degenerative Acquired Vitelliform Lesions Using Techniques Based on Optical Coherence Tomography. *Biomedicines*, 11(5):1382, 2023.
- [9] Adrian Groza. Measuring Hallucinations of Large Language Models in Ophthalmology. 2024.
- [10] Adrian Groza and Marginean Anca. Brave new world: Artificial Intelligence in teaching and learning. In *16th annual International Conference of Education, Research and Innovation, ICERI2023*, page 8706, 13-15 November, 2023., 2023. IATED.
- [11] Adrian Groza and Mihai Pomarlan. Towards an Ontology of Explanations. In Rubina Polovina, Simon Polovina, and Neil Kemp, editors, *Measuring Ontologies for Value Enhancement: Aligning Computing Productivity with Human Creativity for Societal Adaptation*, pages 73–85, Cham, 2023. Springer Nature Switzerland.
- [12] Anca Marginean Groza, Adrian and Simona Delia Nicoara. An ontology for Age-Related Macular Degeneration using ophthalmologists and language models. In *14th Int. Conf. on Semantic Web Applications and Tools for Health Care and Life Sciences, SWAT4LS,23*, 2023.
- [13] Mădălina-Claudia Hapca, George-Adrian Muntean, Iulia-Andrada Nemeş-Drăgan, Ștefan Cristian Vesa, and Simona-Delia Nicoară. Visual Outcomes of Traumatic Lens Dislocations and Subluxations Managed by Pars Plana Vitrectomy and Lensectomy. *Journal of Clinical Medicine*, 12(22):6981, 2023.

- [14] Dan Lupu, Groza Adrian, and Adam Pease. Cross-validation of Answers with SUMO and GPT. In *Knowledge Base Construction from Pre-Trained Language Models*, KBC-LM@ 22nd International Semantic Web Conference (ISWC 2023). COEU, 2023.
- [15] Anca Marginean, Vesa Bianca, Simona Delia Nicoara, and George Muntean. Low-dimensional Representation of OCT Volumes with Supervised Contrastive Learning. In *2022 IEEE 18th International Conference on Intelligent Computer Communication and Processing (ICCP)*, pages 47–54. IEEE, 2022.
- [16] Anca Marginean, George Adrian Muntean, Alexandra Ioana Bucur, and Simona Delia Nicoara. Exploring Early Estimation of Treatment Needs for Age-Related Macular Degeneration Patients Using Easily Generated Features. In *25th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing*, SYNASC23, 2023.
- [17] Beatrice-Andreea Marginean, Adrian Groza, George Muntean, and Simona Delia Nicoara. Predicting Visual Acuity in Patients Treated for AMD. *Diagnostics*, 12(6):1504, 2022.
- [18] Patricia Mateiu and Adrian Groza. Ontology engineering with Large Language Models. In *25th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing*, SYNASC23, 2023.
- [19] G.A. Muntean, A. Marginean, A. Groza, I. Damian, S.A. Roman, M.C. Hapca, M.V. Muntean, and S.D Nicoară. The Predictive Capabilities of Artificial Intelligence-Based OCT Analysis for Age-Related Macular Degeneration Progression—A Systematic Review. *Diagnostics*, 13(14), 2023.
- [20] George Adrian Muntean, Adrian Groza, Anca Marginean, Radu Razvan Slavescu, Mihnea Gabriel Steiu, Valentin Muntean, and Simona Delia Nicoara. Artificial Intelligence for Personalised Ophthalmology Residency Training. *Journal of Clinical Medicine*, 12(5), 2023.
- [21] George Adrian Muntean, Anca Marginean, Adrian Groza, Ioana Damian, Sara Alexia Roman, Madalina Claudia Hapca, Anca Mădalina Sere, Roxana, Mihaela Manoiu, Maximilian Vlad Muntean, and Simona Delia Nicoara. Qualitative Evaluation of ChatGPT4 and PALM2’s Response to Patient’s Questions Regarding Age-related Macular Degeneration. *Diagnostics*, page under review, 2024.
- [22] Marco Pop-Mihali and Adrian Groza. Forest Mixing: investigating the impact of multiple search trees and a shared refinements pool on ontology learning. In David Wyld et al., editor, *10th International Conference on Artificial Intelligence & Applications*, ARIA23. AIRCC, 2023.
- [23] Eugen Popescu, Adrian Groza, and Damian Ioana. Detecting Diabetic Retinopathy through Fundus Images using an Ensemble of classifiers. In *11th International Conference on Advanced Technologies*, ICAT23, 2023.
- [24] Kinga Cristina Slavescu, Daniel-Alexandru Ulics, and Radu Razvan Slavescu. Transformer based architectures for semantic segmentation of endoscopy images – first evaluation. *JPGN Reports (ESPGHAN 56th Annual Meeting Abstracts)*, 5(S1):S1424, 2024.
- [25] Radu Razvan Slavescu, Zsófia Fodor, and Kinga Cristina Slavescu. Detecting polyps in endoscopic images with u-net based architectures - a preliminary evaluation. In Simona Vlad and Nicolae Marius Roman, editors, *8th International Conference on Advancements of Medicine and Health Care Through Technology*, pages 12–20, Cham, 2024. Springer Nature Switzerland.

- [26] Radu Razvan Slavescu and Sergiu Alexandru Gaga. Vision Transformers: A Promising Pathway to Retinal Semantic Segmentation. In *Int. Conf. on Intelligent Computer Communication and Processing - in review*, ICCP24. IEEE, 2024.
- [27] Radu Razvan Slavescu, Marina Bianca Trif, and Kinga Cristina Slavescu. Detecting fake medical content with Transformers. In *26th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing - in review*, SYNASC, 2024.
- [28] Radu Razvan Slavescu, Daniel-Alexandru Ulics, and Kinga Cristina Slavescu. Semantic Segmentation of Endoscopic Images using Transformers - Towards Trading off Dice and Precision. In *Int. Conf. on Intelligent Computer Communication and Processing*, ICCP23. IEEE, 2023.
- [29] Corina Iuliana Suciu, Anca Marginean, Vlad-Ioan Suciu, George Adrian Muntean, and Simona Delia Nicoară. Diabetic Macular Edema Optical Coherence Tomography Biomarkers Detected with EfficientNetV2B1 and ConvNeXt. *Diagnostics*, 14(1):76, 2024.
- [30] Corina-Iuliana Suciu, Vlad-Ioan Suciu, and Simona Delia Nicoară. Optical Coherence Tomography Measurements in Type 1 Diabetic Subjects with Low and Moderate Daily Physical Activity. *Romanian Journal of Ophthalmology*, 67(4):337, 2023.