



**Școala Doctorală de Electronică, Telecomunicații
și Tehnologia Informației**

REZUMAT TEZĂ DE DOCTORAT

Elena-Anca PARASCHIV

**ABORDĂRI INTEGRATE BAZATE PE
INTELIGENȚĂ ARTIFICIALĂ PENTRU
MONITORIZAREA SĂNĂTĂȚII MINTALE ȘI
VIZUALE**

**INTEGRATIVE AI APPROACHES FOR MENTAL
AND VISUAL HEALTH MONITORING**

THESIS COMMITTEE

Prof. Dr. Ing. Florin Drăghici Univ. Politehnica din București	Președinte
Prof. Dr. Ing. Mihai Ciuc Univ. Politehnica din București	Conducător doctorat
Prof. Dr. Ing. Cătălin Căleanu Univ. Politehnica din Timișoara	Referent
Prof. Dr. Ing. Laurențiu-Mihail Ivanovici Universitate Transilvania, Brașov	Referent
Prof. Dr. Ing. Constantin Vertan Univ. Politehnica din București	Referent

BUCUREȘTI 2025

Cuprins

Introducere.....	1
1.1 Prezentarea domeniului tezei de doctorat.....	2
1.2 Scopul tezei de doctorat	3
1.3 Conținutul tezei de doctorat	3
Capitolul 2 Inteligența artificială în detecția bolilor retiniene	5
2.1 Anatomia retinei și modul acesteia de funcționare	5
2.1.1 Dezvoltarea ochiului uman	5
2.1.2 Anatomia și fiziologia retinei.....	6
2.2 Prezentare generală a bolilor retiniene și a metodelor actuale de diagnostic.....	6
2.3 Învățarea profundă în imagistica retiniană	7
2.3.1 Stadiul actual al cercetării privind algoritmi de segmentare în imagistica fundului de ochi și OCT/OCTA.....	7
2.3.2 Stadiul actual al cercetării privind algoritmi de clasificare în imagistica fundului de ochi și OCT/OCTA.....	8
2.4 Studii de caz și aplicații în detectarea afecțiunilor retiniene.....	8
2.4.1 Seturi de date.....	8
2.4.2 Modele de DL aplicate pentru clasificarea imaginilor OCT.....	9
Capitolul 3 Imagistica retiniană ca fereastră către sănătatea neurologică	13
3.1 Inteligența artificială în detectarea bolilor neurologice prin imagistică retiniană	13
3.1.1 Boala Alzheimer	13
3.1.2 Scleroza multiplă	14
3.1.3 Boala Parkinson	14
3.1.4 Autism.....	15
3.2 Biomarkeri retinieni și detecția asistată de IA în schizofrenie.....	15
3.2.1 Modificări în procesarea vizuală la pacienții cu schizofrenie.....	15
3.2.2 Modificări retiniene în schizofrenie.....	16
3.3 Studiu de caz pe un set de date OCTA privat cu imagini ale pacienților cu schizofrenie	16
3.3.1 Setul de date	16
3.3.2 Analiză statistică și rezultate.....	17
Capitolul 4 Monitorizarea la distanță a pacienților psihiatrici	19
4.1 Fundamentele monitorizării la distanță bazate pe IA	19
4.1.1 Scurt istoric al îngrijirii medicale la distanță	19
4.1.2 Rolul IoT și IA în soluțiile de sănătate la distanță.....	20
4.1.3 Progrese în cloud computing pentru soluțiile de sănătate bazate pe IoT și IA	20
4.1.4 Situația actuală a monitorizării neurologice și psihiatrice	20
4.2 Studii de caz privind utilizarea IA în monitorizarea pacienților cu schizofrenie	20
4.2.1 Monitorizarea bazată pe IA a dietei, sănătății fizice și metabolismului în pacienții cu schizofrenie	20
Capitolul 5 Concluzii	27
Bibliografie	33

Capitolul 1

Introducere

Ochiul uman a reprezentat dintotdeauna un subiect de interes major pentru cercetători și clinicieni. Fascinația provine nu doar din complexitatea structurală și rolul esențial în percepția vizuală, ci și din relația sa profundă cu starea generală de sănătate a individului. Retina trebuie privită nu doar ca un țesut senzorial, ci ca o veritabilă „fereastră” prin care pot fi observate precoce indicii ale sănătății oculare sau neurologice. Bolile retiniene constituie o provocare semnificativă la nivel global, în special prin frecvența lor în creștere, dificultatea diagnosticării precise și severitatea potențială, inclusiv pierderea ireversibilă a vederii. În acest context, comunitatea medicală a început să exploreze soluții inovatoare de diagnostic, dintre care un rol central îl ocupă inteligența artificială (IA), în special tehnicile de DL. Evoluția acestor metode a contribuit semnificativ la transformarea oftalmologiei, prin creșterea preciziei diagnostice, reducerea timpului de analiză și îmbunătățirea eficienței clinice.

Rețelele neuronale convoluționale (Convolutional Neural Networks - CNN) au fost printre primele metode de IA aplicate în imagistica oftalmologică, demonstrând eficiență în analiza imaginilor retiniene, în special a celor obținute prin tomografie în coerență optică (Optical Coherence Tomography - OCT), datorită capacității de a detecta caracteristici subtile și localizate. Totuși, o limitare importantă a CNN-urilor constă în incapacitatea acestora de a surprinde relațiile globale spațiale din imagine. Apariția modelelor Vision Transformers (ViT) a reprezentat un pas înainte, prin capacitatea lor de a analiza imaginea în ansamblu și de a modela relații spațiale globale. Astfel, au fost propuse modele hibride care combină avantajele CNN-urilor în recunoașterea caracteristicilor locale cu abilitatea ViT-urilor de a interpreta structuri globale. Capitolul al doilea al acestei lucrări detaliază potențialul, avantajele și limitările acestor modele CNN, ViT și hibride în contextul diagnosticării bolilor retiniene.

Lucrarea își extinde apoi atenția asupra implicațiilor neurologice ale retinei, evidențiate în capitolul al treilea. Adesea descrisă ca o „fereastră către creier”, retina prezintă conexiuni embriologice și anatomice directe cu sistemul nervos central (SNC), ceea ce îi conferă potențialul de a fi un biomarker non-invaziv pentru sănătatea neurologică. Progresele recente în tehnologiile de imagistică retiniană (OCT și OCT angiografic – OCTA) au permis observarea unor modificări fine ale retinei asociate cu boli neurologice precum boala Alzheimer (AD), boala Parkinson (PD), scleroza

multiplă (SM) și schizofrenia. Aceste progrese pot contribui la identificarea precoce și monitorizarea evoluției bolilor neurologice.

Cu toate acestea, cercetarea este încă la început în ceea ce privește acuratețea diagnostică a biomarkerilor retinieni pentru tulburările neuropsihiatrice, cum ar fi schizofrenia. Aceste limitări subliniază nevoia unei abordări integrate în domeniul sănătății. Capitolul patru explorează soluțiile de monitorizare la distanță a sănătății, evidențiind modul în care tehnologiile portabile și platformele de tip Internetul Lucrurilor (Internet of Things – IoT), alimentate de IA, pot îmbunătăți livrarea serviciilor medicale. Aceste instrumente permit implicarea continuă a pacientului, urmărirea în timp real a simptomelor, analiza detaliată a progresiei bolii și intervenții personalizate, cu aplicabilitate directă în schizofrenie. Integrarea obiceiurilor alimentare în sistemele de monitorizare la distanță a pacienților cu schizofrenie contribuie la o abordare terapeutică holistică. Întrucât schizofrenia este asociată cu perturbări ale conectivității cerebrale, electroencefalograma (EEG) reprezintă un instrument esențial de neuro-monitorizare, fiind o metodă fiabilă și accesibilă utilizată frecvent în cercetarea neuropsihiatrică. Capitolul discută, de asemenea, algoritmi de detecție IA pe bază de EEG, subliniind potențialul integrării acestora în platformele de monitorizare la distanță.

Scopul general al acestei teze este de a explora abordările integrate bazate pe IA pentru monitorizarea sănătății mentale și vizuale, aducând o contribuție semnificativă la convergența dintre neurologie, psihiatrie și oftalmologie. Corelarea progreselor tehnologice cu aplicabilitatea clinică susține direcția de cercetare abordată, conturând o viziune promițătoare asupra viitorului medicinei. Monitorizarea continuă a pacientului, tehnicile de diagnostic precise și managementul proactiv al sănătății contribuie la redefinirea practicii clinice și la îmbunătățirea rezultatelor pentru pacienți.

1.1 Prezentarea domeniului tezei de doctorat

Această teză de doctorat se situează la intersecția dintre tehnicile avansate de IA și domeniile oftalmologiei, neurologiei și psihiatriei. Scopul principal este de a explora modul în care metodologiile IA, în special cele bazate pe DL, pot revoluționa practicile de diagnostic din oftalmologie, contribuind semnificativ la detecția și managementul bolilor retiniene. Dintre algoritmi utilizați, CNN-urile și ViT-urile au fost aplicate cu succes în identificarea afecțiunilor retiniene.

Lucrarea analizează, de asemenea, conexiunea anatomică și embriologică a retinei cu sistemul nervos central (SNC), poziționând imagistica retiniană ca o metodă promițătoare pentru detecția precoce și monitorizarea tulburărilor neurologice și psihiatrice. Tehnologiile de imagistică OCT și OCTA permit vizualizarea unor modificări retiniene fine asociate cu afecțiuni precum boala Alzheimer (AD), boala Parkinson (PD), scleroza multiplă (SM) sau schizofrenia. Totuși, utilizarea exclusivă a imagisticii retiniene în diagnosticul unor boli neurologice complexe poate prezenta limitări, pe care această lucrare își propune să le abordeze.

Astfel, sunt propuse soluții de monitorizare la distanță a stării de sănătate, care integrează IA, tehnologii portabile, platforme IoT și date EEG, pentru a oferi o perspectivă mai completă și integrată asupra îngrijirii pacientului.

Prin aceste direcții, teza conturează un domeniu inovator de cercetare, orientat spre redefinirea metodelor de diagnostic, îmbunătățirea rezultatelor clinice și transformarea paradigmelor de îngrijire medicală în mai multe specializări.

1.2 Scopul tezei de doctorat

Această teză explorează modul în care tehnologiile avansate de IA pot fi utilizate pentru a îmbunătăți acuratețea diagnostică atât în analiza imaginilor retiniene, cât și în interpretarea semnalelor EEG. Unul dintre obiectivele urmărite este identificarea arhitecturilor IA care reușesc să echilibreze o acuratețe ridicată a diagnosticului cu aplicabilitatea practică în context clinic, luând totodată în considerare eficiența computațională și fezabilitatea în utilizarea reală.

Totodată, teza își propune să evidențieze rolul retinei ca instrument predictiv pentru tulburări neurologice și psihiatrice mai ample, incluzând și integrarea practică a inteligenței artificiale în monitorizarea obiceiurilor alimentare ale persoanelor cu schizofrenie. Prin urmare, această cercetare urmărește conectarea dimensiunii teoretice a IA cu perspective aplicabile concret, capabile să transforme îngrijirea pacienților în domenii unde detecția precoce și precisă este esențială.

1.3 Conținutul tezei de doctorat

Această teză de doctorat este structurată în trei capitole principale, fiecare dintre ele construind pe baza celui precedent pentru a oferi o explorare cuprinzătoare a inovației în domeniul sănătății bazate pe IA. Capitolul al doilea, intitulat „IA în detecția bolilor retiniene”, analizează aplicarea modelelor avansate de DL, incluzând CNN, ViT și arhitecturi hibride, în vederea îmbunătățirii acurateței diagnostice a afecțiunilor retiniene. Acest capitol oferă o evaluare detaliată a acestor modele, discutând punctele lor forte, limitările și potențialul lor de integrare în practica clinică.

Capitolul al treilea, „Imagistica retiniană ca fereastră către sănătatea neurologică”, extinde perspectiva oftalmologică explorând semnificația neurologică a biomarkerilor retinieni. Sunt examinate corelațiile anatomice și funcționale dintre retină și sistemul nervos central, fiind analizate tehnicile moderne de imagistică retiniană utilizate pentru identificarea timpurie a bolilor neurologice. De asemenea, sunt prezentate metode statistice aplicate pe un set restrâns de date, care evidențiază corelația semnificativă dintre schizofrenie și modificările retiniene.

Capitolul al patrulea, „Monitorizarea la distanță a pacienților psihiatrici”, extinde în continuare conținutul tezei, concentrându-se asupra aplicațiilor practice ale tehnologiilor bazate pe IA și IoT în monitorizarea la distanță a pacienților, în special a

celor diagnosticați cu schizofrenie, prin utilizarea datelor EEG. Capitolul abordează inovațiile tehnologice, strategiile de gestionare a pacienților și provocările reale din practica medicală, evidențiind modul în care aceste soluții bazate pe IA pot contribui la îmbunătățirea rezultatelor clinice și a calității vieții pacienților în îngrijirea psihiatrică.

Capitolul 2

Inteligența artificială în detecția bolilor retiniene

Acest capitol prezintă modul de funcționare al retinei și subliniază importanța diagnosticării precoce a bolilor retiniene. Totodată, evidențiază rolul și potențialul CNN, al ViT și al modelelor hibride în detectarea afecțiunilor retiniene, oferind o perspectivă detaliată asupra capacităților, avantajelor și limitărilor acestora. Una dintre provocările majore identificate constă în resursele computaționale ridicate necesare implementării arhitecturilor bazate pe Transformere. Din acest motiv, modelele hibride care integrează CNN-uri cu ViT-uri au atras un interes științific considerabil, prin valorificarea combinată a capacității CNN-urilor de a extrage caracteristici locale și a abilității ViT-urilor de a analiza contextul global al imaginilor. Astfel, explorarea aplicabilității inteligenței artificiale în oftalmologie deschide perspective promițătoare pentru obținerea unor informații medicale aprofundate.

2.1 Anatomia retinei și modul acesteia de funcționare

Ochiul uman nu este doar un organ al vederii, ci o structură complexă, esențială pentru modul în care percepem și interacționăm cu lumea înconjurătoare. Lumina pătrunde mai întâi prin pupilă, fiind reglată de iris a cărui pigmentare determină culoarea ochilor în funcție de concentrația de melanină. Trecerea luminii prin corneea și cristalin asigură focalizarea precisă pe retină, locul unde sunt inițiate semnalele vizuale. Aceste componente structurale sunt esențiale pentru formarea imaginii și reflectă totodată complexitatea adaptativă a ochiului la condiții variabile de iluminare.

2.1.1 Dezvoltarea ochiului uman

Dezvoltarea ochiului uman începe încă din perioada embrionară, înainte de naștere. Veziculele optice suferă o invaginație pentru a forma cupa optică, din care stratul intern se diferențiază în retină, iar stratul extern se transformă în epiteliul pigmentar retinian (RPE). Pe măsură ce retina se formează, celulele sale migrează și se diferențiază, ducând la apariția unei structuri complexe și stratificate. În luna a cincea de gestație este conturată arhitectura neurală de bază a retinei, pregătind dezvoltarea sinapselor

funcționale și maturizarea celulelor fotoreceptoare. Ultima etapă a acestui proces o reprezintă maturarea foveei, care continuă până în jurul vârstei de patru ani, asigurând capacitatea ochiului de a percepe în întregime complexitatea mediului vizual.

2.1.2 Anatomia și fiziologia retinei

Retina umană reprezintă o structură complexă care continuă povestea ochiului, fiind interfața esențială dintre lumina incidentă și percepția vizuală formată la nivel cerebral. Are o grosime de puțin peste 0,5 milimetri și acoperă suprafața internă a globului ocular. Retina este organizată în trei straturi distincte, fiecare alcătuit din diferite tipuri de celule nervoase. Aceste straturi (Figura 2.1) sunt interconectate prin zone sinaptice care facilitează comunicarea între celule. Stratului extern al retinei, situat în partea posterioară a ochiului, îi revin fotoreceptorii (bastonașe și conuri), responsabili de captarea luminii și inițierea procesului vizual. Poziționarea fotoreceptorilor face ca lumina să traverseze întreaga structură retiniană înainte de a ajunge la bastonașe și conuri.




Figura 2.1 O scanare OCT și vizualizarea straturilor retiniene (adaptat după David Turbert)

2.2 Prezentare generală a bolilor retiniene și a metodelor actuale de diagnostic

Având în vedere structura complexă a retinei și rolul său central în procesarea vizuală, orice modificare patologică poate afecta semnificativ vederea. Bolile retiniene se numără printre principalele cauze de pierdere a vederii și orbire la nivel global, iar afecțiuni precum Degenerescenta Maculară Legată de Vârstă (AMD) și Retinopatia Diabetică (DR) sunt deosebit de frecvente. Un diagnostic precoce este esențial pentru prevenirea deteriorării ireversibile și pentru menținerea calității vieții.

AMD reprezintă una dintre principalele cauze de pierdere ireversibilă a vederii centrale la persoanele peste 50 de ani. Aceasta afectează în special macula — zona responsabilă pentru percepția detaliilor fine și poate evolua asimptomatic în stadiile incipiente. Boala se prezintă în două forme principale: uscată (non-neovasculară), care este cea mai răspândită, și umedă (neovasculară), responsabilă pentru majoritatea pierderilor severe de vedere, datorită dezvoltării anormale de vase sanguine subretiniene. Prezența drusenilor, depozite galben-albicioase de lipide și proteine,

constituie un biomarker timpuriu al progresiei AMD. Factorii de risc includ îmbătrânirea, predispoziția genetică, stilul de viață și anumite comorbidități, iar prognozele indică o creștere semnificativă a cazurilor în UE până în 2050.

DR este cea mai comună complicație oculară a diabetului, afectând aproximativ o treime dintre persoanele diagnosticate. Aceasta este rezultatul hiperglicemiei prelungite, care deteriorează microvascularizația retiniană și poate conduce la complicații severe precum edemul macular diabetic (DME), hemoragiile retiniene sau neovascularizația. DR este clasificată în forme non-proliferative (incipiente) și proliferative (avansate), DME putând apărea în oricare dintre stadii. Pacienții pot experimenta vedere încețoșată sau distorsionată (metamorfopsie), afectând activitățile zilnice. Riscul de DR crește în contextul controlului glicemic deficitar, hipertensiunii, obezității sau fumatului.

Tehnicile imagistice moderne precum OCT și fotografia de fund de ochi permit detectarea precoce a modificărilor structurale retiniene, chiar înainte de apariția simptomelor. Integrarea acestor modalități cu algoritmi de IA contribuie la îmbunătățirea diagnosticului, la personalizarea intervențiilor clinice și la gestionarea eficientă a creșterii prevalenței acestor boli în populațiile îmbătrânite și diabetice.

2.3 Învățarea profundă în imagistica retiniană

Tehnicile de DL au fost aplicate în analiza fotografiilor color ale fundului de ochi, a imaginilor obținute prin tomografie în coerență optică (OCT) sau a imaginilor autofluorescente, în vederea diagnosticării și monitorizării unor afecțiuni retiniene precum DR, AMD sau retinopatia prematurității. De asemenea, aceste metode au fost utilizate pentru detectarea unor condiții diverse, de la ocluzia venoasă retiniană și dezlipirea de retină, până la tulburări retiniene ereditare, cum ar fi retinita pigmentară.

Prin capacitatea lor structurală de a simplifica fluxurile de diagnostic, algoritmi de DL pot furniza predicții de înaltă acuratețe, oferind un sprijin activ în procesul decizional medical. Pentru a surprinde evoluția acestui domeniu, acest subcapitol este dedicat prezentării progresului realizat, de la algoritmi DL fundamentali până la modelele avansate de tip ViTs.

2.3.1 Stadiul actual al cercetării privind algoritmi de segmentare în imagistica fundului de ochi și OCT/OCTA

IA bazată pe DL a avansat semnificativ domeniul imagisticii retiniene prin facilitarea analizei automate și de înaltă precizie a datelor provenite din imagistica fundului de ochi și OCT/OCTA. Utilizând arhitecturi precum U-Net și adaptările sale moderne, modelele DL excelează în segmentarea structurilor retiniene complexe și a trăsăturilor patologice, incluzând vasele de sânge, discul optic, drusenii și exsudatele. Aceste modele reduc dependența de interpretarea manuală, menținând în același timp niveluri ridicate de acuratețe și consistență. Dincolo de segmentare, modelele de clasificare bazate pe DL pot evalua prezența bolii sau progresia acesteia, iar modelele hibride care combină ambele sarcini contribuie la creșterea valorii diagnostice. Inovațiile recente,

precum rețelele bazate pe Swin-Transformer și cadrele hibride CNN-ViT, integrează mecanisme de atenție multi-scală și extragerea ierarhică a trăsăturilor, îmbunătățind performanța generală. Comparările pe seturi de date diverse au demonstrat că aceste tehnici DL adaptate nu doar că depășesc metodele tradiționale, ci oferă și soluții scalabile și eficiente pentru aplicații clinice și de cercetare în oftalmologie.

2.3.2 Stadiul actual al cercetării privind algoritmi de clasificare în imagistica fundului de ochi și OCT/OCTA

Diverse modele și arhitecturi de IA contribuie la îmbunătățirea performanței în analiza imaginilor medicale, fiind recent utilizate și în sarcinile de clasificare din oftalmologie. CNN-urile au fost aplicate pe scară largă pentru automatizarea acestui proces, demonstrând capacități solide în procesarea imaginilor, în special în etapa esențială de extragere a trăsăturilor, necesară pentru interpretarea imaginilor retiniene complexe. Modelele de tip ViTs sunt, de asemenea, considerate metode de ultimă generație în acest domeniu, întrucât au evidențiat abilități remarcabile în extragerea trăsăturilor spațiale, oferind o perspectivă mai detaliată asupra informației vizuale. Pe lângă aceste două categorii principale, au fost propuse și implementate numeroase alte variante arhitecturale pentru sarcinile de clasificare aplicate imagisticii fundului de ochi și tehnologiilor OCT/OCTA.

2.4 Studii de caz și aplicații în detectarea afecțiunilor retiniene

2.4.1 Seturi de date

Au fost utilizate două seturi de date în cadrul acestei teze: setul de date Kermany și setul de date NEH. Setul de date Kermany utilizat în această cercetare conține 84.495 de imagini OCT, împărțite în patru categorii: CNV (neovascularizație coroidiană), drusen, DME (edem macular diabetic) și normal. Distribuția claselor în cadrul acestui set de date este inegală, având următoarea repartizare: CNV – 37.455 de imagini; DME – 11.598 de imagini; Drusen – 8.666 de imagini; Normal – 26.565 de imagini.

Setul de date NEH a fost utilizat în principal pentru testarea algoritmilor pe imagini diferite, o limitare importantă fiind absența imaginilor asociate cu DME.

Setul de date Kermany reprezintă o colecție cuprinzătoare de imagini OCT etichetate, fiind utilizat pe scară largă în dezvoltarea și evaluarea modelelor de DL pentru clasificarea bolilor retiniene. Acest set de date a fost introdus de Daniel Kermany și colaboratorii săi în studiul publicat în anul 2018. O imagine reprezentativă pentru fiecare clasă din cadrul setului de date Kermany este prezentată în Figura 2.2. Săgețile albastre indică structurile retiniene asociate afecțiunilor descrise.




Figura 2.2 Imagine reprezentativă pentru: a). CNV (neovascularizație coroidiană); b). DME (edem macular diabetic); c). Drusen; d). Retină normală (adaptat după D. S. Kermany et al.)

2.4.2 Modele de DL aplicate pentru clasificarea imaginilor OCT

2.4.2.1 Modele bazate pe CNN

CNN-urile s-au dovedit eficiente în captarea caracteristicilor locale, aspect esențial în detectarea detaliilor structurale subtile. Acestea se bazează în principal pe filtre localizate și pe o procesare ierarhică, motiv pentru care, de multe ori, omit relațiile spațiale pe distanțe lungi. În acest context, utilizarea CNN-urilor poate avea limitări în diferențierea unor afecțiuni retiniene care necesită o perspectivă globală asupra imaginii.

Tabelul 2.1. Rezultatele de performanță ale variantelor DenseNet, Inception-ResNet și ale modelelor bazate pe CNN

Model	Acuratețe (%)	AUC	Scor f1	Pierdere
DenseNet121	95.56	0.996	0.94	0.11
DenseNet169	97	0.997	0.97	0.1
DenseNet201	96	0.997	0.96	0.12
Inception-ResNet	93.18	0.99	0.93	0.18
12 CNN-based model	93	0.95	0.93	0.20

2.4.2.2 Modele bazate pe ViT

Prin contrast, rețelele de tip ViT propun o abordare inovatoare, utilizând mecanisme de autoatenție care procesează imaginile sub formă de secvențe de patch-uri. Această metodă le permite să surprindă contextul general și tipare subtile prezente în întreaga

imagine. Pentru a funcționa eficient, ViT-urile necesită, în general, seturi de date de dimensiuni mari și o putere de calcul sporită. Chiar și în cazul versiunilor extinse, precum DeepViT, sarcina poate deveni susceptibilă la supraîncălzire în prezența zgomotului sau a variabilității datelor. O reprezentare vizuală a modului în care arhitectura ViT este aplicată pe o imagine OCT este ilustrată în Figura 2.6.

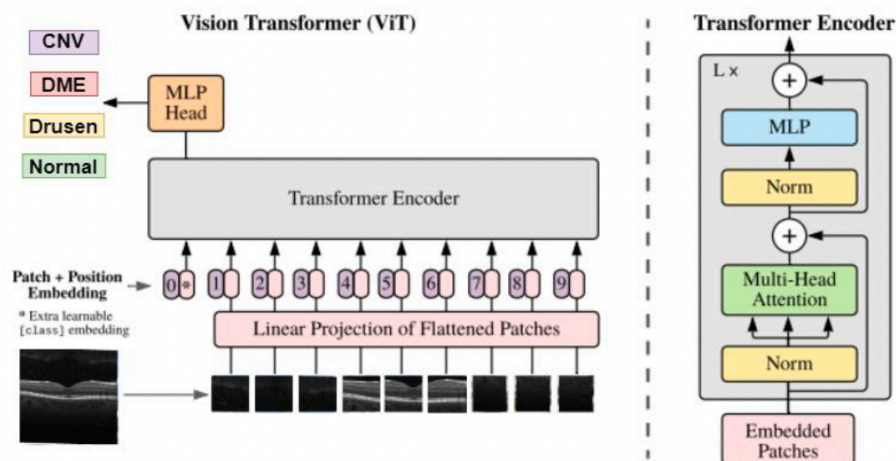


Figura 2.3 Arhitectura ViT (adaptat după Dosovitskiy, Alexey, et al.)

Au fost dezvoltate modele hibride care combină punctele forte ale rețelelor CNN și ale Transformerelor. Modelele prezentate (ResNet50-ViT și FusionViT) integrează capacitatea de extragere locală a caracteristicilor, specifică CNN-urilor, cu modelarea contextului global, caracteristică Transformerelor.

Modelul hibrid ResNet50 + ViT a reunit abilitatea CNN-urilor de a extrage trăsături locale cu potențialul Transformerului de a recunoaște tipare globale. Acesta a obținut cea mai mare acuratețe (99,97%) și o bună generalizare între clasele de boli retiniene. Cu toate acestea, complexitatea computațională ridicată a reprezentat o limitare semnificativă pentru mediile cu resurse limitate. Această provocare a condus la dezvoltarea modelului FusionViT, care înlocuiește ResNet50 cu o arhitectură convoluțională mai ușoară. Această arhitectură a reușit să atingă un echilibru între performanță (97,83% acuratețe) și eficiență computațională. În Tabelul 2.10 sunt prezentate toate modelele implementate în cadrul acestei teze.

Tabelul 2.2 Tabel comparativ al tuturor modelelor aplicate pentru clasificarea bolilor retiniene

Model	Arhitectură	Acuratețe (%)	Puncte forte	Limitări
DenseNet121	CNN	95.56	Reutilizare eficientă a caracteristicilor, reduce supraîncălzirea	Modelare limitată a dependențelor pe distanțe lungi
DenseNet169	CNN	97	Extragere profundă de caracteristici, generalizare mai bună	Timp de antrenare crescut
DenseNet201	CNN	96	Cea mai bună dintre modelele DenseNet,	Cost computațional ridicat

			propagare eficientă a caracteristicilor	
InceptionResNet-V2	Hybrid (Inception + ResNet)	93.18	Extragere de caracteristici la scară multiplă, învățare reziduală	Computațional intensiv
CNN-based model	CNN	93	Arhitectură simplă, optimizată pentru eficiență	Capacitate limitată de captare a tiparelor complexe
ViT	Transformer	96.80	Capturează dependențe globale, excelent în recunoașterea tiparelor complexe	Necesită seturi de date mari, consum ridicat de resurse
DeepViT	Transformer	89.98	Învățare îmbunătățită a caracteristicilor, generalizare superioară	Risc de supraînvățare, timp lung de antrenare
ResNet50 + ViT	Hybrid (CNN + Transformer)	99.97	Cea mai bună acuratețe, combină extragerea locală a caracteristicilor (CNN) cu contextul global (ViT)	Model complex, necesită resurse semnificative
ConvBackBone + ViT	Hybrid (CNN + Transformer)	97.83	Eficient, echilibrează performanța și cerințele de resurse	Acuratețe ușor mai mică decât ResNet50-ViT

Experimentele ample care au comparat CNN-uri, ViT-uri și abordări hibride pentru clasificarea bolilor retiniene pe imagini OCT au evidențiat câteva aspecte importante. Pe de o parte, arhitecturile CNN tradiționale, precum DenseNet și InceptionResNet, s-au dovedit foarte eficiente în captarea detaliilor fine, însă întâmpină dificultăți în modelarea relațiilor spațiale pe distanțe mari. Pe de altă parte, ViT și versiunea sa extinsă, DeepViT, utilizează mecanisme de self-attention pentru a interpreta contextul global al imaginii, deși sunt în general intensive din punct de vedere computațional și necesită volume mari de date. Dintre abordările hibride, modele precum ResNet50-ViT și FusionViT au oferit un compromis promițător. Modelul ResNet50-ViT a obținut cea mai ridicată acuratețe (99,97%), însă cerințele sale computaționale ridicate pot limita utilizarea în medii cu resurse reduse. În comparație, FusionViT a oferit o acuratețe competitivă (97,83%) cu un cost computațional semnificativ mai redus, ceea ce îl face mai potrivit pentru aplicații clinice în timp real.

Capitolul 3

Imagistica retiniană ca fereastră către sănătatea neurologică

Ochiul uman este considerat mai mult decât un simplu organ responsabil pentru vedere. El reprezintă o extensie a creierului, oferind indicii valoroase despre sănătatea neurologică. Pornind de la concluziile obținute în detectarea bolilor retiniene utilizând modele de DL, așa cum a fost discutat în capitolul anterior, această secțiune aprofundează relația fascinantă dintre retină și diverse tulburări neurologice.

Adesea descrisă metaforic ca o „fereastră către creier”, retina se dezvoltă embrionar ca parte integrantă a SNC. Structura sa neurală complexă și rețeaua microvasculară fină reflectă îndeaproape arhitectura creierului. Această conexiune anatomică și funcțională specială oferă cercetătorilor și clinicienilor o oportunitate deosebită: aceea de a monitoriza, într-un mod non-invaziv, modificările neurovasculare și neurodegenerative care apar la nivel cerebral, prin examinarea retinei.

Acest capitol evidențiază ideea conform căreia semnele subtile transmise prin intermediul retinei ar putea transforma semnificativ, în viitor, modul de diagnosticare și de gestionare a sănătății neurologice. O astfel de abordare ar putea sprijini luarea unor decizii clinice mai informate și ar permite o monitorizare la distanță mai eficientă a pacienților.

3.1 Inteligența artificială în detectarea bolilor neurologice prin imagistică retiniană

3.1.1 Boala Alzheimer

Demența este o afecțiune neurologică profundă care afectează grav memoria, capacitatea de a gândi și abilitatea de a desfășura activități cotidiene. Vârsta este considerată principalul factor de risc în declanșarea bolii Alzheimer (AD), cea mai răspândită formă de demență, responsabilă pentru 60–70% din totalul cazurilor.

În prezent, diagnosticarea AD se bazează pe analiza lichidului cefalorahidian (LCR) și a biomarkerilor imagistici. Cu toate acestea, recoltarea LCR este o metodă

invazivă, iar tehnicile imagistice precum RMN și PET sunt costisitoare și, de obicei, disponibile doar în clinici specializate, ceea ce limitează aplicabilitatea lor pentru screening-ul extins. Din cauza acestor provocări, există o nevoie acută de metode non-invazive și accesibile pentru detectarea timpurie a AD. O direcție promițătoare este reprezentată de explorarea biomarkerilor retinieni, având în vedere conexiunea dintre retină și sistemul nervos central (SNC), ambele împărțind caracteristici structurale și funcționale comune (bariera hemato-encefalică, sistemul de neurotransmițători).

Literatura analizată evidențiază diversitatea biomarkerilor retinieni și relevanța lor în identificarea AD prin tehnici de imagistică retiniană:

- Biomarkeri structurali: subțierea stratului Ganglion Cell–Inner Plexiform Layer (GC-IPL) și a stratului de fibre nervoase retiniene (RNFL);
- Modificări vasculare retiniene: scăderea densității vasculare, modificări ale fluxului capilar sau modele anormale de perfuzie sangvină, care pot reflecta procesele cerebrovasculare din cadrul neurodegenerării;
- Caracteristici radiomice: atribute precum forma, compactitatea sau excentricitatea zonei avasculare foveale (FAZ), care pot îmbunătăți acuratețea diagnosticării AD.

3.1.2 Scleroza multiplă

Scleroza multiplă (SM) este o boală neurodegenerativă cronică, caracterizată prin multiple dizabilități fizice, pierderea vederii, declin cognitiv, pierderea mielinei neuronale, degenerare axonală, atrofie neuronală și inflamație la nivelul SNC. Având în vedere că retina este o componentă a SNC, cu conexiuni bidirecționale către creier, aceasta este frecvent afectată în SM (pierderea vederii fiind adesea primul simptom), aproape jumătate dintre pacienți prezentând cel puțin un episod de nevrită optică (ON). Prin urmare, imagistica retiniană, în special tehnica OCT, devine o alternativă rapidă și non-invazivă pentru diagnosticarea SM. În plus, în ultima perioadă s-a intensificat interesul pentru utilizarea aplicațiilor bazate pe învățare automată (ML) și DL în analiza imaginilor retiniene pentru urmărirea evoluției SM.

3.1.3 Boala Parkinson

Boala Parkinson (PD) este o tulburare neurodegenerativă care afectează peste 8,5 milioane de persoane la nivel global, în special pe cele de peste 60 de ani. Dincolo de simptomele motorii precum tremorul și rigiditatea musculară, PD implică frecvent anomalii retiniene precoc. Studiile arată că semnele disfuncției dopaminergice și acumulării de sinucleină pot fi detectate în retină înainte de apariția simptomelor cerebrale. Imagistica OCT s-a dovedit valoroasă în identificarea modificărilor retiniene asociate cu progresia PD și cu halucinațiile vizuale. Printre biomarkerii-cheie se numără reducerea grosimii și volumului în straturile retiniene precum macula, RNFL, GCL, IPL și stratul fotoreceptorilor, ceea ce subliniază potențialul imagisticii retiniene pentru detecția și monitorizarea precoce a PD.

3.1.4 Autism

Tulburarea de spectru autist (ASD) este asociată cu dezvoltarea atipică a creierului, afectând percepția, învățarea și interacțiunea socială. Studiile au evidențiat modificări retiniene în ASD, cum ar fi subțierea RNFL și dimensiuni mai mari ale discului optic, ceea ce sugerează că metricele retiniene pot sprijini diagnosticarea. Având în vedere că imagistica retiniană este non-invazivă și adecvată pentru copii, aceasta prezintă potențial în evaluarea ASD. Totuși, cercetările în acest domeniu sunt încă limitate. Un studiu care a utilizat un clasificator SVM pe baza unor caracteristici retiniene extrase de la 46 de copii cu ASD și 24 de copii sănătoși a raportat o performanță diagnostică ridicată, cu o sensibilitate de 95,7% și o specificitate de 91,3%.

3.2 Biomarkeri retinieni și detecția asistată de IA în schizofrenie

Imagistica retiniană bazată pe IA a demonstrat un potențial considerabil în detectarea tulburărilor neurologice precum boala Alzheimer, Parkinson, scleroza multiplă sau autismul. Deoarece retina reflectă modificările care au loc la nivelul creierului, caracteristicile sale structurale și vasculare pot servi drept biomarkeri non-invazivi și rentabili. Cu sprijinul IA, aceste modificări subtile pot fi cuantificate cu o precizie crescută, îmbunătățind diagnosticarea precoce și monitorizarea afecțiunilor.

Pornind de la aceste premise, capitolul analizează aplicarea analizei retiniene asistate de IA în contextul tulburărilor psihiatrice, cu accent pe schizofrenie, o boală mentală complexă care afectează percepția, comportamentul și cogniția. Având o prevalență globală estimată între 0,7% și 1%, schizofrenia este asociată adesea cu modificări retiniene precoce. Imagistica retiniană îmbunătățită cu IA ar putea sprijini diagnosticarea timpurie și ar putea oferi o nouă abordare în gestionarea integrată a afecțiunilor neurologice și psihiatrice.

3.2.1 Modificări în procesarea vizuală la pacienții cu schizofrenie

Persoanele cu schizofrenie se confruntă frecvent cu tulburări de percepție vizuală, precum distorsionarea formelor și culorilor sau chiar halucinații vizuale. Dincolo de aceste manifestări perceptive, cercetările au arătat că schizofrenia afectează și procesele vizuale de bază, cum ar fi sensibilitatea la contrast și recunoașterea detaliilor, evidențiind impactul asupra modului în care creierul interpretează informația vizuală. Pe lângă simptomele cognitive și emoționale, schizofrenia influențează multiple simțuri, inclusiv vederea. Modificările structurale retiniene pot explica o parte dintre dificultățile vizuale întâlnite la acești pacienți, mai ales în contextul comorbidităților frecvente precum diabetul zaharat sau hipertensiunea. Aceste conexiuni susțin potențialul imagisticii retiniene ca instrument de monitorizare și înțelegere a schizofreniei.

3.2.2 Modificări retiniene în schizofrenie

Retina, ca extensie directă a sistemului nervos central, împărtășește numeroase caracteristici neurobiologice cu creierul, ceea ce o transformă într-un domeniu promițător pentru identificarea biomarkerilor asociați cu tulburările neuropsihiatrice, inclusiv schizofrenia. Studii bazate pe OCT au evidențiat subțierea unor straturi retiniene specifice (precum RNFL, GCL, IPL, INL, ONL), reducerea volumului macular și creșterea raportului cupă-disc optic, toate aceste aspecte reflectând posibile procese de neurodegenerare sau variații ale răspunsului la tratament.

Date suplimentare provenite din electroretinografie (ERG) susțin existența unor deficite funcționale, indicând amplitudini diminuate ale undelor a și b – în special la nivelul bastonașelor și conurilor – nu doar la pacienții diagnosticați cu schizofrenie, ci și la descendenții acestora aparent sănătoși, sugerând astfel posibili markeri endofenotipici.

În plus, OCTA a evidențiat modificări microvasculare, precum scăderea densității vasculare, mărirea FAZ, dilatarea venulelor și dinamici anormale ale perfuziei. Aceste constatări indică, în mod colectiv, un flux sanguin retinian perturbat, posibil asociat cu disfuncții neurovasculare. Deși acești biomarkeri retinieni oferă o perspectivă valoroasă asupra fiziopatologiei schizofreniei, integrarea lor în schemele de diagnostic clinic este încă în stadiu incipient.

3.3 Studiu de caz pe un set de date OCTA privat cu imagini ale pacienților cu schizofrenie

Studii recente subliniază utilizarea tot mai frecventă a imagisticii retiniene, în special a tomografiei în coerență optică cu angiografie (OCTA), ca metodă non-invazivă pentru detectarea afecțiunilor neurologice prin analiza modificărilor microvasculare. Cu toate că potențialul acestei metode este promițător, aplicațiile bazate pe IA pentru detecția schizofreniei utilizând date retiniene sunt în continuare limitate.

3.3.1 Setul de date

Setul de date utilizat în acest studiu a fost furnizat de Universitatea din Rochester și cuprinde o colecție distinctivă de imagini OCTA și scanări OCT aferente, provenind atât de la persoane diagnosticate cu schizofrenie, cât și de la indivizi sănătoși (HC). Datele au fost adnotate de Prof. Dr. Steven Silverstein, profesor de Psihiatrie, Neuroștiințe și Oftalmologie la University of Rochester Medical Center. Fiecare imagine este etichetată cu „OD” (ochiul drept) sau „OS” (ochiul stâng).

Setul de date este împărțit în patru categorii:

- **Tineri sănătoși** – 38 de imagini; persoane sănătoase, utilizate ca referință pentru retina normală;
- **Prim episod psihotic (FEP)** – 18 imagini; pacienți recent diagnosticați cu schizofrenie, utilizați pentru identificarea timpurie a afecțiunii;

- **Vârștnici sănătoși** – 34 de imagini; adulți sănătoși de vârstă înaintată, incluși pentru a evalua impactul îmbătrânirii normale asupra retinei;
- **Pacienți cronici** – 23 de imagini; persoane cu schizofrenie de lungă durată, unde este cel mai probabil să se observe modificări neurovasculare specifice.

O imagine reprezentativă pentru fiecare categorie este prezentată în Figura 3.1.




Figure 3.1 Imagini OCTA din: a. Tineri sănătoși; b. FEP; c. Vârștnici sănătoși; d. Pacienți cronici.

3.3.2 Analiză statistică și rezultate

Analiza urmărește să investigheze dacă zona FAZ diferă între pacienții cu schizofrenie și persoanele sănătoase și dacă aceste variații reflectă progresia bolii. Măsurătorile FAZ au fost extrase din imaginile OCTA folosind un algoritm de segmentare personalizat, care a inclus conversia în tonuri de gri, binarizare prin prag Otsu, detecția contururilor și conversia pixelilor în suprafață exprimată în milimetri pătrați.

Distribuțiile rezultate au fost comparate între cele patru grupuri: tineri sănătoși, vârștnici sănătoși, FEP și pacienți cronici cu schizofrenie. După cum se observă în Figura 3.2, diagrama boxplot evidențiază clar o creștere a valorilor suprafeței FAZ la pacienții cronici, în comparație cu toate celelalte grupuri. Acest lucru susține ipoteza conform căreia modificările microvasculare retiniene devin mai accentuate în stadiile avansate ale afecțiunii. În schimb, grupurile FEP și controale tinere prezintă valori similare, ceea ce sugerează că aceste alterări nu sunt prezente în faza de debut și nu sunt strict asociate îmbătrânirii normale.




Figura 3.2 Distribuția valorilor FAZ în cele patru grupuri analizate

Normalitatea datelor a fost confirmată prin testul Shapiro-Wilk, permițând aplicarea metodelor statistice parametrice. Testele t de comparație între eșantioane independente nu au indicat diferențe semnificative între controalele tinere și FEP, nici între FEP și pacienții cronici, dar au evidențiat o creștere semnificativă a valorilor FAZ la pacienții cronici față de controalele vârstnice. Comparațiile între grupuri multiple (ANOVA și Kruskal-Wallis) au confirmat faptul că valorile FAZ diferă semnificativ între clase. Analiza dimensiunii efectului (Cohen's d) a arătat un efect mare între grupul de controale vârstnice și cel al pacienților cronici, susținând semnificația clinică a măririi zonei FAZ în stadiile avansate ale bolii.

Aceste rezultate sugerează că mărirea zonei FAZ poate reflecta alterări neurovasculare progresive asociate cu schizofrenia, mai degrabă decât să servească drept marker de diagnostic timpuriu. Deoarece FAZ mărită apare și în alte tulburări neurologice, aceasta nu ar trebui utilizată ca indicator unic. În schimb, ea ar putea contribui la dezvoltarea unui cadru multimodal mai larg, care să combine biomarkeri retinieni, EEG și neuroimagistică. Cercetări viitoare ar trebui să valideze aceste concluzii pe cohorte mai mari, să analizeze influența tratamentului medicamentos și să exploreze modele hibride bazate pe IA pentru îmbunătățirea specificității diagnosticului.

Capitolul 4

Monitorizarea la distanță a pacienților psihiatrici

Integrarea diagnosticelor bazate pe IA și a tehnologiilor de asistență medicală la distanță a deschis noi perspective pentru detectarea timpurie și gestionarea afecțiunilor neurologice și psihiatrice, precum schizofrenia. Deși biomarkerii retinieni, cum ar fi aria FAZ, prezintă potențial, aceștia nu sunt suficienți singuri, ceea ce subliniază necesitatea combinării acestora cu alte surse de date, cum ar fi EEG, pentru un diagnostic mai fiabil.

Sistemele de monitorizare la distanță bazate pe IA – inclusiv purtabile, platforme IoT și modele de învățare automată – permit o observație continuă a pacientului și pot îmbunătăți semnificativ urmărirea simptomelor, evaluarea tratamentului și detectarea timpurie a recidivelor în îngrijirea pacienților cu schizofrenie.

4.1 Fundamentele monitorizării la distanță bazate pe IA

Dezvoltarea soluțiilor de îngrijire medicală la distanță a modificat fundamental peisajul serviciilor medicale, prin tranziția de la consultațiile tradiționale față-în-față către monitorizarea continuă, facilitată de IoT și IA. Integrarea dispozitivelor purtabile, a tehnologiilor cloud și a algoritmilor IA permite furnizarea de îngrijiri personalizate și în timp real de la distanță. Aceste progrese au demonstrat un impact semnificativ asupra preciziei diagnosticului, intervențiilor terapeutice la timp și monitorizării pe termen lung.

4.1.1 Scurt istoric al îngrijirii medicale la distanță

Îngrijirea medicală la distanță își are originea în telemedicina apărută la mijlocul secolului XX, cu scopul de a oferi servicii medicale în zone izolate. Sistemele timpurii se bazează pe comunicații audio și video de bază, limitate de calitatea transmisiei datelor. Odată cu apariția internetului de mare viteză, a rețelelor mobile și a 5G, telemedicina a evoluat într-o soluție în timp real și scalabilă. Introducerea dosarelor electronice de sănătate (EHR), a platformelor cloud și a tehnologiilor mHealth (inclusiv telefoane

inteligente și purtabile) a extins semnificativ capacitatea de monitorizare continuă și gestionare a bolilor cronice.

4.1.2 Rolul IoT și IA în soluțiile de sănătate la distanță

Datele fiziologice continue și analiza EEG bazată pe IA pot semnala devreme modificările activității neuronale asociate schizofreniei. Aceste instrumente deschid noi oportunități pentru extinderea sprijinului psihiatric în mediul de acasă al pacientului, facilitând strategii personalizate și proactive de îngrijire.

4.1.3 Progrese în cloud computing pentru soluțiile de sănătate bazate pe IoT și IA

Cloud computing-ul joacă un rol esențial în îngrijirea medicală la distanță, oferind stocare sigură și acces rapid la EHR, ceea ce îmbunătățește luarea deciziilor în telemedicină. Beneficiile includ: scalabilitate în perioade de criză, securitate ridicată a datelor și conformitate cu Regulamentul general privind protecția datelor (GDPR), dar și interoperabilitate cu dispozitive IoT și aplicații purtabile, sprijinind o viziune integrată asupra sănătății pacientului.

4.1.4 Situația actuală a monitorizării neurologice și psihiatrice

Integrarea tehnologiilor de IA și monitorizare de la distanță transformă îngrijirea sănătății mintale, în special în gestionarea tulburărilor complexe precum schizofrenia. Sistemele tradiționale de sănătate mintală se confruntă cu limitări precum accesibilitatea redusă, lipsa monitorizării în timp real și cerințe ridicate de resurse. Progresele în dispozitivele purtabile, Internetul lucrurilor (IoT) și IA abordează aceste probleme, permițând îngrijire continuă, personalizată și detectarea timpurie a simptomelor. În cazul schizofreniei, modelele IA bazate pe EEG, în special abordările de DL precum CNN, Bi-LSTM și arhitecturile hibride, prezintă o acuratețe ridicată în diagnostic și monitorizare. Aceste inovații pot oferi pacienților o mai mare autonomie în gestionarea propriei afecțiuni, iar pe măsură ce aceste instrumente evoluează, ele promit o tranziție către o îngrijire a sănătății mintale mai proactivă, scalabilă și precisă.

4.2 Studii de caz privind utilizarea IA în monitorizarea pacienților cu schizofrenie

4.2.1 Monitorizarea bazată pe IA a dietei, sănătății fizice și metabolismului în pacienții cu schizofrenie

Schizofrenia este adesea însoțită de complicații grave de sănătate fizică, cum ar fi obezitatea, diabetul, afecțiunile cardiovasculare și obiceiurile alimentare nesănătoase. Sistemele emergente de asistență medicală la distanță, bazate pe IA, își propun să acopere acest gol prin monitorizarea continuă a dietei, somnului, nivelului de stres și a

indicatorilor metabolici cu ajutorul dispozitivelor purtabile. Aceste instrumente permit urmărirea în timp real și intervenții personalizate, oferind o abordare mai proactivă atât a sănătății fizice, cât și a celei mintale. De exemplu, integrarea metricilor fiziologici, cum ar fi variabilitatea ritmului cardiac și nivelul glucozei, cu date comportamentale poate evidenția semne timpurii de declin cognitiv sau agravare a simptomelor. Suportul decizional bazat pe IA poate furniza apoi recomandări nutriționale personalizate și alerte automate, contribuind la reducerea riscurilor precum sindromul metabolic și la susținerea stării de bine pe termen lung.

Un caz de utilizare esențial pentru îngrijirea personalizată în schizofrenie este ilustrat în Figura 4.1, prezentând un flux ML (machine learning) care procesează date despre dietă, somn, medicație și activitate fizică pentru a furniza avertizări timpurii și recomandări personalizate de tratament. Acest sistem permite feedback dinamic și adaptare la nevoile individuale și, în același timp, oferă pacienților perspective în timp real despre modul în care alegerile lor de stil de viață influențează sănătatea mintală. Prin valorificarea analizelor predictive și a învățării continue, astfel de platforme depășesc modelele reactive de tratament și deschid calea către psihiatria de precizie. Integrarea monitorizării alimentației, a urmării somnului și a gestionării stresului în sistemele de sănătate la distanță bazate pe IA are potențialul de a transforma modul în care este gestionată schizofrenia, făcând îngrijirea mai accesibilă, adaptabilă și eficientă.

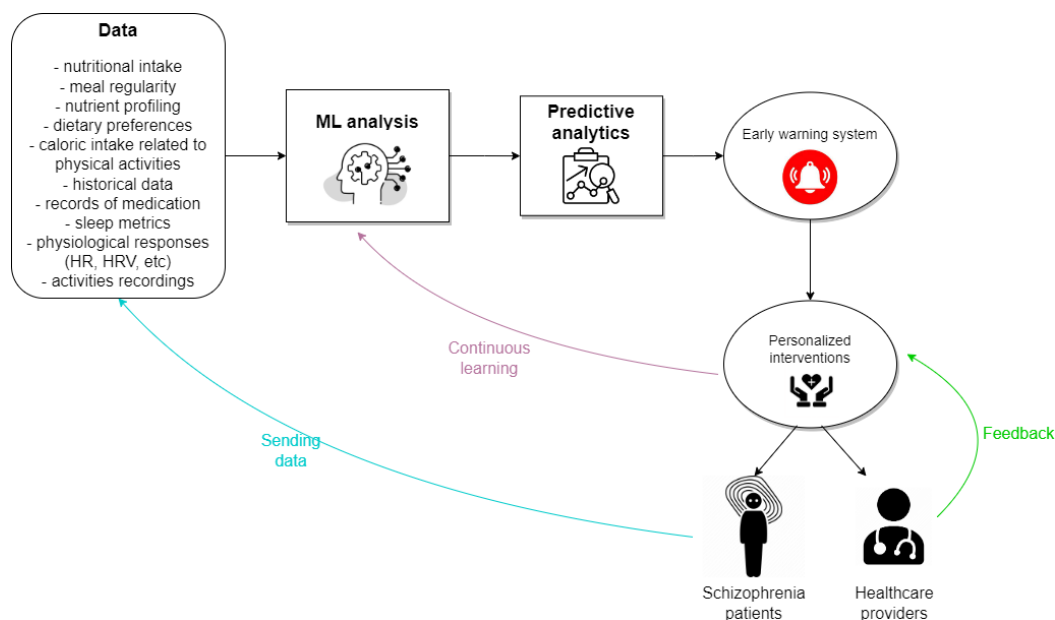


Figura 4.1 Fluxul unui caz de utilizare pentru o aplicație cu abordare personalizată în îngrijirea pacienților cu schizofrenie, utilizând învățarea automată

4.2.2 Detectarea și monitorizarea schizofreniei pe baza EEG, asistată de IA

Modificările în conectivitatea cerebrală, procesarea neuronală afectată sau integrarea senzorio-motorie neregulată pot influența semnificativ evoluția schizofreniei. În acest context, un instrument important care poate fi utilizat atât pentru diagnostic, cât și

pentru monitorizarea progresiei bolii este reprezentat de neuro-monitorizarea bazată pe EEG (electroencefalogramă).

EEG-ul este o tehnică non-invazivă și rentabilă care înregistrează activitatea electrică a creierului cu o rezoluție temporală ridicată, permițând analiza oscilațiilor neuronale, a modelelor de conectivitate și a potențialelor evocate (ERP-uri). Toate aceste semnale sunt alterate în cazul pacienților cu schizofrenie. EEG-ul este utilizat pentru a înțelege disfuncțiile cognitive, anomaliile senzoriale și modificările de conectivitate care caracterizează această afecțiune.

4.2.2.1 Setul de date EEG utilizat pentru detectarea schizofreniei

Această cercetare a utilizat un set de date EEG open-source axat pe schizofrenie, care conține înregistrări de la 81 de participanți (49 diagnosticați cu schizofrenie și 32 de persoane sănătoase – HC). Sarcina experimentală a inclus trei condiții, concepute pentru a explora disfuncția de descărcare corolară: apăsarea unui buton pentru a genera un sunet (stimul auto-generat), ascultarea pasivă a aceluiași sunet (stimul extern), și apăsarea unui buton fără sunet (control motor simplu).

Această configurație a fost concepută pentru a identifica anomalii în predicția senzorială, care pot fi asociate cu schizofrenia. Datele EEG au trecut prin mai multe etape de preprocesare pentru a îmbunătăți claritatea semnalului. Acestea au inclus: referențierea semnalului la electrozii de la nivelul lobului urechii, aplicarea unui filtru trece-sus la 0.1 Hz pentru eliminarea zgomotului de frecvență joasă, precum și interpolarea datelor lipsă.

După segmentarea datelor în funcție de evenimentele legate de stimul, artefactele au fost eliminate, iar medii ERP au fost extrase de la nouă electrozi-cheie (Fz, FCz, Cz, FC3, FC4, C3, C4, CP3, CP4), ilustrați în Figura 4.3. Setul final de date a fost normalizat și pregătit pentru analiza ulterioară, distribuția claselor fiind prezentată în Figura 4.2.



Figura 4.2 Distribuția claselor în setul de date (stânga: control; dreapta: schizofrenie)




Figura 4.3 Sistemul internațional 10–20 pentru plasarea electrozilor EEG pe scalp

4.2.2.2 Modele DL de tip 1D-CNN, LSTM și CNN-LSTM pentru clasificarea schizofreniei

Un studiu dezvoltat în cadrul acestei cercetări a fost publicat în 2023 și descrie aplicabilitatea a trei modele de DL: **(1) Modelul 1D-CNN** care procesează date unidimensionale folosind operațiuni convoluționale pentru a extrage tipare locale și relații între puncte adiacente, o alegere firească pentru datele EEG, care conțin adesea astfel de caracteristici localizate; **(2) Modelul bazat pe LSTM**, care ajută la captarea dependențelor pe termen lung din semnalul EEG, abordând eficient problema gradientului care dispare; **(3) Modelul hibrid CNN-LSTM**, care permite captarea simultană a detaliilor pe termen scurt și a tendințelor pe termen lung. Procesele de antrenare au implicat experimentarea cu mai multe straturi pentru a obține performanța optimă a modelelor.

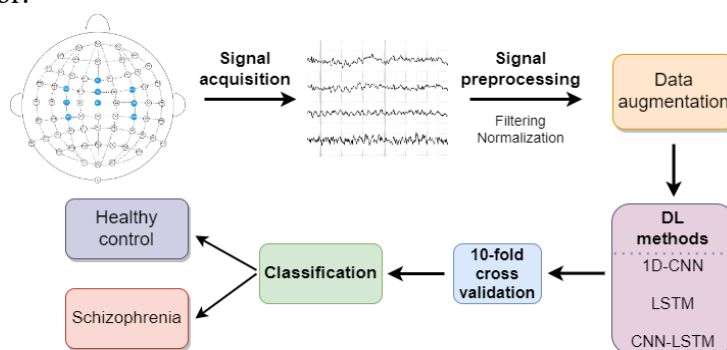


Figura 4.4 Diagrama metodei propuse pentru clasificarea EEG

Figura 4.4 prezintă o diagramă care evidențiază fluxul complet de procesare pentru clasificarea înregistrărilor EEG în „Control sănătos” și „Schizofrenie”. Procesul începe cu pașii esențiali de preprocesare: normalizarea, care standardizează datele EEG prin eliminarea diferențelor de scară, și filtrarea, care reduce zgomotul și artefactele nedorite, clarificând astfel semnalul. Pentru a îmbunătăți setul de date, se aplică tehnici de augmentare a datelor, cum ar fi injecția de zgomot. Modelele de DL sunt apoi antrenate și evaluate utilizând metoda de validare încrucișată în 10 folduri, care ajută la evaluarea performanței modelului și a capacității acestuia de generalizare.

Cea mai bună performanță a fost observată în cazul modelului CNN-LSTM, care a atins o acuratețe de testare de 82%. Rezultatele competitive obținute de arhitecturile LSTM și CNN-LSTM subliniază capacitatea acestora de a modela caracteristicile spectrale și temporale complexe prezente în datele EEG. În plus, utilizarea metodei de validare încrucișată în 10 folduri a contribuit la robustețea generală a modelelor de clasificare.

Tabelul 4.1 Rezultatele modelelor de DL propuse

Modele de DL	Timp (s)	Rezultate	
		Acuratețe	Pierdere
1D-CNN	300	78.8%	0.56
LSTM	600	79.8%	0.63
CNN-LSTM	800	82.1%	0.45

4.2.2.3 Modelul CNN-BiLSTM utilizând matrici TE

Un progres semnificativ în această cercetare a fost publicat în 2024, modelul fiind antrenat pe baza matricilor Transfer Entropy (TE) derivate din date EEG, având ca scop sprijinirea diagnosticului și predicției schizofreniei. Utilizând setul de date open-source detaliat în secțiunea 4.2.2.1, semnalele EEG provenite de la nouă electrozi (Fz, FCz, Cz, FC3, FC4, C3, C4, CP3, CP4) au fost procesate pentru a calcula matricile TE (indicatori cantitativi ai conectivității cerebrale direcționale, care reflectă modul în care activitatea dintr-o regiune cerebrală influențează alta).

Aceste matrici TE, vizualizate sub formă de hărți de căldură asimetrice, au fost introduse într-un model hibrid CNN-BiLSTM. Componenta CNN a extras caracteristici spațiale din matrici, în timp ce stratul BiLSTM a captat dependențele temporale, permițând modelului să detecteze mai bine disfuncțiile neuronale subtile asociate cu schizofrenia. Matricile au fost calculate utilizând ferestre temporale de 5 secunde din semnalele EEG și au evidențiat o conectivitate semnificativ redusă la pacienții cu schizofrenie, în special în regiunile frontale și centrale (de exemplu, Fz, FCz, C3, C4), în concordanță cu afectările cunoscute în reglarea cognitivă și emoțională în această tulburare (Figura 4.6a).

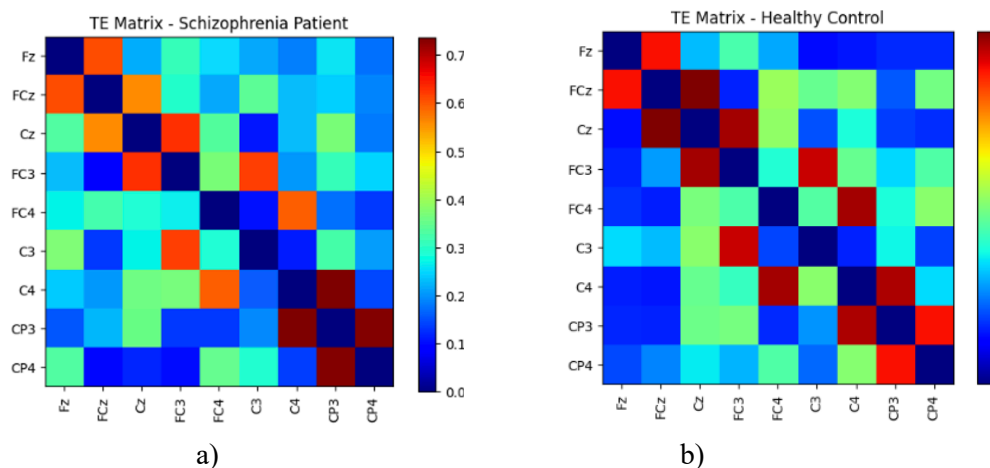


Figura 4.5 Hărți de căldură ale conectivității direcționale derivate din valorile Transfer Entropy (fără unitate de măsură), prezentate pentru: (a) pacienți cu schizofrenie și (b) persoane din grupul de control sănătos (HC).

Figura 4.6 (b) prezintă matricea Transfer Entropy (TE) pentru un subiect din grupul HC, evidențiind o conectivitate crescută, cu valori TE mai mari, între regiunile centrale și parietale. Acest lucru indică un flux direcțional puternic al informației, coerent cu funcționarea cognitivă normală, contrastând cu modelele de conectivitate perturbate observate la pacienții cu schizofrenie.

Modelul CNN-BiLSTM a fost antrenat utilizând matrice TE derivate din datele EEG. Această arhitectură hibridă extrage atât caracteristici spațiale, cât și temporale, permițând o clasificare precisă între pacienții cu schizofrenie și HC. Modelul a atins o acuratețe de 99,94%, demonstrând o capacitate solidă de generalizare și performanță predictivă ridicată. Această convergență remarcabilă este reflectată în graficele pentru acuratețea în antrenare și validare (Figura 4.7 a) și în curbele de pierdere (Figura 4.7 b).




Figura 4.6 Graficele pentru acuratețea în antrenare și validare (a), respectiv pentru pierdere (b)..

Figura 4.9 oferă o reprezentare vizuală a unei propuneri de integrare a modelului de DL într-un cadru de monitorizare la distanță a stării de sănătate. Procesul începe cu achiziția semnalelor EEG de la mai mulți electrozi. Aceste semnale sunt apoi prelucrate pentru a genera matrice TE, care surprind modelele de conectivitate neuronală. Matricele sunt analizate folosind un model hibrid CNN-BiLSTM, care captează eficient atât caracteristicile spațiale, cât și pe cele temporale ale datelor EEG.

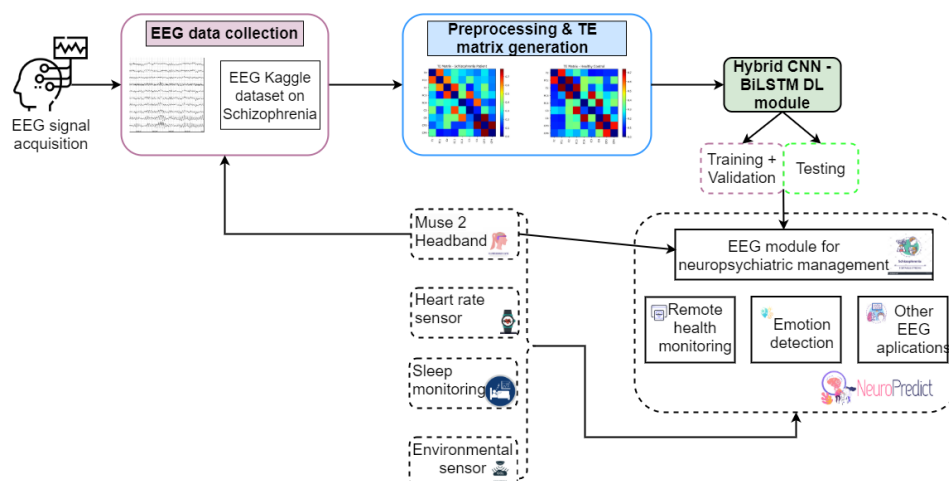


Figura 4.7 Model conceptual privind modul în care modelele de DL pot fi integrate într-un sistem de monitorizare la distanță a sănătății.

Tabelul 4.2 Comparație între diverse tehnici bazate pe IA pentru detectarea schizofreniei utilizând date EEG

Metoda	Tehnica	Acuratețea	Studiu
SchizoGoogLeNet	CNN cu arhitectură GoogLeNet	99.02%	Siuly et al.
Recurrence Plot + Gramian Angular Field	Reprezentări spațiale bazate pe CNN	93.2%	Ko and Yang
CNN-based EEG model	CNN pentru clasificarea	92%	Guo et al.

	semnalelor EEG non-liniare		
MSST-Bi-CNN	Transformare spectrală multi-scalară cu BiLSTM-CNN	84.42%	Jindal et al.
SchizoNET	Analiză timp-frecvență cu CNN	99.74%	Khare et al.
1D-CNN	1D-CNN	78.8%	Prezenta cercetare
LSTM	LSTM	79.8%	Prezenta cercetare
CNN-LSTM	CNN-LSTM	82.1%	Prezenta cercetare
Proposed CNN-BiLSTM (TE matrices)	CNN-BiLSTM pe matrice de entropie de transfer (TE)	99.94%	Prezenta cercetare

Modelul propus CNN-BiLSTM a atins niveluri de performanță comparabile cu arhitecturi de ultimă generație (SOTA – State of the Art), precum SchizoGoogLeNet și SchizoNET. Această cercetare a subliniat aplicabilitatea matricilor de entropie de transfer (TE), deoarece acestea surprind tiparele spațiale și temporale ale conectivității neuronale. Performanța modelului CNN-BiLSTM poate deschide oportunități substanțiale pentru integrarea sa într-un sistem comprehensiv de monitorizare a sănătății mintale. Acest model conceptual de sistem de monitorizare la distanță este proiectat pentru a colecta date EEG, împreună cu metriche fiziologice și comportamentale suplimentare, și ar putea oferi evaluări în timp real ale tiparelor de conectivitate neuronală. Aceste evaluări sunt esențiale pentru detectarea timpurie a recăderilor în schizofrenie sau a declinului cognitiv.

Mai mult, există un potențial promițător pentru monitorizarea în timp real a conectivității atât în medii clinice, cât și în cele la distanță, deoarece aceste modele pot fi integrate într-un sistem de monitorizare a sănătății care să fie utilizat în asociere cu o bentiță EEG portabilă, ce poate fi folosită acasă sau în afara mediului spitalicesc.

Capitolul 5

Concluzii

În încheierea acestei călătorii doctorale, a fost explorat un drum în domeniul sănătății neuro-oftalmologice, pornind de la detaliile microscopice ale imagisticii retiniene, traversând conexiunile neuronale delicate ale retinei și ajungând la peisajul mai larg al tulburărilor neurologice și psihiatrice, pentru ca în final să culmineze în domeniul inovator al monitorizării la distanță a sănătății, susținută de IA (IA).

Povestea a început cu dansul complex dintre CNN și rețelele de tip ViT, fiecare aducând propriile avantaje în interpretarea subtilităților din imaginile OCT retiniene. Modele hibride precum ResNet50-ViT și FusionViT au fost de asemenea aplicate cu succes pentru diagnosticul bolilor.

Pe măsură ce drumul a avansat, rolul retinei s-a transformat dintr-un simplu organ al vederii într-o fereastră către starea neurologică și psihiatrică. Prin analize detaliate, modificări microvasculare fine, precum mărirea FAZ, au fost observate ca disfuncții neurovasculare progresive în evoluția schizofreniei. Aceste constatări au subliniat potențialul retinei de a servi drept biomarker non-invaziv.

În cele din urmă, călătoria a pătruns și în peisajul transformator al monitorizării la distanță a sănătății. Folosind modele avansate de IA care integrează arhitecturi CNN și LSTM, au fost demonstrate performanțe ridicate de acuratețe diagnostică în monitorizarea EEG.

Parcursul descris în această teză simbolizează o transformare semnificativă în practica medicală – una orientată spre o îngrijire predictivă, personalizată și realizată la distanță, cu sprijinul inteligenței artificiale. Deși capitolele se încheie aici, povestea inovației și explorării continuă.

5.1 Rezultate obținute

Capitolul al doilea a subliniat importanța detectării bolilor retiniene pe baza CNN-urilor, a transformatoarelor vizuale (ViT) și a versiunilor lor hibride. Experimentele care au comparat arhitecturi CNN, ViT și abordări hibride pentru clasificarea bolilor retiniene folosind imagini OCT au relevat mai multe aspecte importante. Rezultatele privind acuratețea pentru arhitecturile bazate pe CNN au fost următoarele: DenseNet121 – 95,56%, DenseNet169 – 97%, DenseNet201 – 96%, InceptionResNet-V2 – 93,18%, iar CNN-ul cu 12 straturi – 93%. ViT și versiunea sa extinsă, DeepViT,

au utilizat mecanisme de self-attention pentru a înțelege contextul general al imaginii. Deși s-au dovedit a fi consumatoare de resurse și au nevoie de volume mari de date, ele au oferit acurateți de ultimă generație: ViT – 96,80% și DeepViT – 89,98%. Dintre abordările hibride folosite, modelele ResNet50-ViT și FusionViT au oferit un compromis promițător. Modelul ResNet50-ViT a obținut cea mai mare acuratețe (99,97%), însă cerințele ridicate de calcul pot limita utilizarea sa în medii cu resurse restrânse. Prin comparație, FusionViT a oferit o acuratețe competitivă (97,83%) cu un cost computațional considerabil mai mic, ceea ce îl face mai potrivit pentru aplicații clinice în timp real.

Capitolul al treilea a explorat rolul măsurătorilor FAZ în detectarea schizofreniei, arătând că mărirea FAZ este mai pronunțată la pacienții cu schizofrenie cronică decât în cazurile aflate în stadii incipiente. Aceste constatări susțin ideea conform căreia modificările vasculare în schizofrenie sunt progresive și nu sunt neapărat prezente la debutul bolii. În acest capitol au fost propuse și abordări statistice pentru a valida ipoteza corelării între mărirea FAZ și schizofrenie. Valoarea de 0,8868 pentru coeficientul d al lui Cohen în comparația dintre grupul de control mai în vârstă și pacienții cu schizofrenie cronică indică un efect de magnitudine mare. Acest rezultat validează că mărirea zonei FAZ în schizofrenie nu este doar statistic semnificativă, ci și clinic relevantă.

Capitolul al patrulea a evidențiat potențialul tehnicilor avansate de DL care combină punctele forte ale arhitecturilor CNN și LSTM pentru datele EEG. Integrarea caracteristicilor bazate pe entropia de transfer (TE) cu modelul CNN-BiLSTM a îmbunătățit și mai mult performanța sistemului. Acesta a obținut o acuratețe de validare de 99,94% și a demonstrat fezabilitatea monitorizării în timp real prin intermediul unor dispozitive EEG portabile. S-a demonstrat, de asemenea, un potențial promițător pentru monitorizarea în timp real a conectivității neuronale în medii clinice și la distanță, întrucât aceste modele pot fi integrate într-un sistem de monitorizare a sănătății de la distanță, utilizabil împreună cu o bandă EEG destinată uzului casnic sau remote. Acest capitol a integrat și legătura dintre obiceiurile alimentare și schizofrenie, evidențiind o direcție complementară pentru îngrijirea personalizată în domeniul sănătății mintale. Monitorizarea continuă a dietei și urmărirea sănătății metabolice pot fi integrate în sistemele de sănătate la distanță pentru a obține o mai bună înțelegere a modului în care tiparele nutriționale influențează funcționarea cognitivă și emoțională în schizofrenie.

5.2 Contribuții originale

Contribuțiile principale ale acestei teze de doctorat includ:

(1) Dezvoltarea și evaluarea unor algoritmi personalizați de DL, inclusiv a unor modele hibride, precum ResNet50-ViT, precum și crearea arhitecturii FusionViT, optimizată special pentru detecția bolilor retiniene pe baza imaginilor OCT. FusionViT a fost conceput pentru a echilibra eficiența computațională cu o acuratețe diagnostică ridicată;

(2) Introducerea unui set de date OCTA de dimensiuni reduse și analiza

cuprinzătoare și validarea biomarkerilor retinieni, în special a măsurătorilor FAZ. Zona FAZ s-a dovedit a fi un indicator non-invaziv al progresiei schizofreniei, oferind perspective valoroase asupra aspectelor neurovasculare ale bolii;

(3) Implementarea și testarea riguroasă a unor sisteme avansate de monitorizare a sănătății la distanță bazate pe IA, care integrează date EEG și monitorizarea alimentației. Acest lucru a condus la propunerea unui model conceptual pentru o abordare personalizată a managementului schizofreniei. Dezvoltarea modelului CNN-BiLSTM bazat pe matrici de entropie de transfer (TE) generate din date EEG reprezintă o altă contribuție originală a acestei teze.

Aceste contribuții, în ansamblu, aduc îmbunătățiri semnificative practicilor de diagnostic și îngrijirii pacienților în oftalmologie, neurologie și psihiatrie.

5.3 Lista lucrărilor originale

Această listă include doar lucrările publicate / comunicate în care doctorandul este autor sau coautor. La acestea se adaugă rapoartele de cercetare din cadrul programului doctoral și contractele de cercetare la care doctorandul a contribuit. Toate aceste lucrări se regăsesc și în Bibliografie. Toate lucrările menționate trebuie să aibă un conținut relevant pentru tema tezei de doctorat.

Publicațiile de mai jos abordează în mod direct și semnificativ temele tratate în cadrul tezei:

1. **Elena-Anca Paraschiv**, Lidia Băjenaru, Cristian Petrache, Ovidiu Bica, and Dragoș-Nicolae Nicolau. 2024. "AI-Driven Neuro-Monitoring: Advancing Schizophrenia Detection and Management Through Deep Learning and EEG Analysis" *Future Internet* 16, no. 11: 424. <https://doi.org/10.3390/fi16110424>. WOS:001365026100001.
2. **Elena-Anca Paraschiv**, Marilena Ianculescu, Adriana Alexandru (2024). Bridging the Gap: Deep Learning EEG-Based Applications for Schizophrenia Classification and Management. In: Costin, HN., Magjarević, R., Petroiu, G.G. (eds) *Advances in Digital Health and Medical Bioengineering*. EHB 2023. IFMBE Proceedings, vol 109. Springer, Cham. https://doi.org/10.1007/978-3-031-62502-2_76. WOS:001326807700076.
3. **Elena-Anca Paraschiv**, Alina-Elena Sultana, "Harnessing the power of vision transformers for enhanced OCT image classification", *Romanian Journal of Information Technology and Automatic Control*, ISSN 1220-1758, vol. 34(2), pp. 97-111, 2024. <https://doi.org/10.33436/v34i2y202408>. WOS:001253386000008.
4. Laura-Ioana Coman, Marilena Ianculescu, **Elena-Anca Paraschiv**, Adriana Alexandru, and Ioana-Anca Bădăraș. 2024. "Smart Solutions for Diet-Related Disease Management: Connected Care, Remote Health Monitoring Systems, and Integrated Insights for Advanced Evaluation", *Applied Sciences* 14, no. 6: 2351. <https://doi.org/10.3390/app14062351>. WOS:001191807000001.

5. **Elena-Anca Paraschiv**, “Applications of Deep Learning algorithms for retinal diseases diagnosis based on Optical Coherence Tomography imaging,” 2023 24th International Conference on Control Systems and Computer Science (CSCS), Bucharest, Romania, 2023, pp. 594-597, doi: 10.1109/CSCS59211.2023.00099.
6. Marilena Ianculescu, **Elena-Anca Paraschiv**, Adriana Alexandru, “The Potential of the Remote Monitoring Digital Solutions to Sustain the Mental and Emotional Health of the Elderly during and Post COVID-19 Crisis in Romania”, Healthcare 11, no. 4: 608. 2023. <https://doi.org/10.3390/healthcare11040608>. WOS:000939108500001.
7. **Elena-Anca Paraschiv**, Marilena Ianculescu, Ovidiu Bica and Alexandru Sipică, “Underpinning Improved Outcomes through Preventative Patient Care Models Based on Remote Monitoring and AI,” 2021 International Conference on e-Health and Bioengineering (EHB), Iasi, Romania, 2021, pp. 1-4, doi: 10.1109/EHB52898.2021.9657668. WOS:000802227900128.

Publicațiile de mai jos sunt corelate cu temele abordate în cadrul tezei:

1. Marilena Ianculescu, Victor Constantin, **Elena-Anca Paraschiv**, and Adriana Alexandru, “Design and Development of Comprehensive Health Tracking Devices for Enhanced Health Monitoring,” 2024 E-Health and Bioengineering Conference (EHB), IASI, Romania, 2024, pp. 1-4, doi: 10.1109/EHB64556.2024.10805642. WOS:001413708800046.
2. **Elena-Anca Paraschiv**, Marilena Ianculescu, Andreea Gusatu, Victor Constantin (2024) “Digital Health Platforms as Educational Tools: Enhancing Self-Management for Patients with Mental Health Conditions”, ICERI2024 Proceedings, pp. 4338-4347.
3. Adriana Alexandru. Marilena Ianculescu, **Elena-Anca Paraschiv** (2024). “Harnessing the Capabilities of IoHT-Based Remote Monitoring Systems for Decision Making in Elderly Healthcare”. In: Balas, V.E., Dzemyda, G., Belciug, S., Kacprzyk, J. (eds) Decision Making and Decision Support in the Information Era. Studies in Systems, Decision and Control, vol 534. Springer, Cham. https://doi.org/10.1007/978-3-031-62158-1_10
4. **Elena-Anca Paraschiv**, Cristian-Mihail Petrache, Ovidiu Bica, Ana-Mihaela Vasilevschi, “Fall Detection System: Continuous in-Home Monitoring of Parkinson’s Patients”, Proceedings of The 10th Edition of IEEE International Conference on e-Health and Bioengineering (EHB 2022), 17-19 Nov. 2022, Iasi – WEBCONFERENCE – Romania 2022 E-Health and Bioengineering Conference (EHB).
5. **Elena-Anca Paraschiv**, Cristian-Mihail Petrache, and Ovidiu Bica, “On the continuous development of IoT in Big Data Era in the context of Remote Healthcare Monitoring & Artificial Intelligence,” 2022 14th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), Ploiesti, Romania, 2022, pp. 1-6, doi: 10.1109/ECAI54874.2022.9847503.
6. Marilena Ianculescu, **Elena-Anca Paraschiv**, Adriana Alexandru,

“Addressing Mild Cognitive Impairment and Boosting Wellness for the Elderly through Personalized Remote Monitoring”, Healthcare 10, no. 7: 1214. 2022. <https://doi.org/10.3390/healthcare10071214>. WOS:000832374800001

7. **Elena-Anca Paraschiv**, Eleonora Tudora, Eugenia Tîrziu and Adriana Alexandru, “IoT & Cloud Computing-based Remote Healthcare Monitoring System for an Elderly-Centered Care,” 2021 International Conference on e-Health and Bioengineering (EHB), Iasi, Romania, 2021, pp. 1-4, doi: 10.1109/EHB52898.2021.9657585. WOS:000802227900049
8. Silvia Ovreiu, **Elena-Anca Paraschiv**, Elena Ovreiu, “Deep Learning & Digital Fundus Images: Glaucoma Detection using DenseNet”, ECAI 2021 13th Edition International Conference on Electronics, Computers and Artificial Intelligence, Pitesti, Romania, 2021, pp. 1-4, doi: 10.1109/ECAI52376.2021.9515188.

5.4 Perspective de dezvoltare ulterioară

Cercetările viitoare ar trebui să acorde prioritate perfecționării abordărilor multimodale bazate pe IA, în special pentru detectarea și gestionarea schizofreniei, prin combinarea biomarkerilor retinieni cu date EEG și de neuroimagistică. Dezvoltarea unor algoritmi avansați de integrare, capabili să interpreteze fără întreruperi fluxuri de date provenite din surse multiple, ar putea îmbunătăți semnificativ acuratețea diagnosticului precoce și ar permite monitorizarea în timp real a afecțiunilor psihiatrice și neurologice. De asemenea, explorarea arhitecturilor eficiente de tip transformer și a modelelor hibride optimizate ar putea aborda limitările actuale legate de resursele computaționale, facilitând astfel accesibilitatea și adoptarea pe scară largă în medii de îngrijire a sănătății diverse.

Mai mult, progresele în tehnologiile portabile și platformele de sănătate bazate pe IoT ar trebui continuate pentru a extinde și mai mult capacitățile de monitorizare de la distanță a pacienților. Integrarea monitorizării continue a parametrilor metabolici și a obiceiurilor alimentare în sistemele de supraveghere medicală la distanță oferă perspective promițătoare pentru intervenții personalizate și o îngrijire holistică a pacientului. Aceste strategii integrative au potențialul de a transforma profund modul de livrare a serviciilor de sănătate, creând modele dinamice, adaptive și reactive, care răspund în mod specific nevoilor fiecărui pacient, îmbunătățind în cele din urmă rezultatele medicale și calitatea vieții pacienților.

Bibliografie

- David Turbert, “What Is Optical Coherence Tomography?,” American Academy of Ophthalmology.
- “Webvision - The organization of the retina and visual system,” Helga Kolb, Ralph Nelson, Eduardo Fernandez, Bryan Jones.
- M. O. F. A. Paul Chous, “Do diabetes, diabetic retinal disease contribute to macular degeneration?,” Optometry Times Journal.
- Y. Zhang, Z. Xing, and A. Deng, “Prediction of treatment outcome for branch retinal vein occlusion using convolutional neural network-based retinal fluorescein angiography,” *Sci Rep*, vol. 14, no. 1, p. 20018, Aug. 2024, doi: 10.1038/s41598-024-71061-7.
- T. H. M. Fung *et al.*, “Artificial intelligence using deep learning to predict the anatomical outcome of rhegmatogenous retinal detachment surgery: a pilot study,” *Graefe’s Archive for Clinical and Experimental Ophthalmology*, vol. 261, no. 3, pp. 715–721, Mar. 2023, doi: 10.1007/s00417-022-05884-3.
- T. Y. A. Liu, C. Ling, L. Hahn, C. K. Jones, C. J. Boon, and M. S. Singh, “Prediction of visual impairment in retinitis pigmentosa using deep learning and multimodal fundus images,” *British Journal of Ophthalmology*, vol. 107, no. 10, pp. 1484–1489, Oct. 2023, doi: 10.1136/bjo-2021-320897.
- R. Rashid, W. Aslam, A. Mehmood, D. L. R. Vargas, I. D. L. T. Diez, and I. Ashraf, “A Detectability Analysis of Retinitis Pigmentosa Using Novel SE-ResNet Based Deep Learning Model and Color Fundus Images,” *IEEE Access*, vol. 12, pp. 28297–28309, 2024, doi: 10.1109/ACCESS.2024.3367977.
- D. S. Kermany *et al.*, “Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning,” *Cell*, vol. 172, no. 5, pp. 1122–1131.e9, Feb. 2018, doi: 10.1016/j.cell.2018.02.010.
- K. Z. M. G. Daniel Kermany, “Large Dataset of Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images,” *Mendeley Data*, V3, doi: 10.17632/rschjbr9sj.3, 2018.
- S. Ovreiu, E. A. Paraschiv, and E. Ovreiu, “Deep Learning Digital Fundus Images: Glaucoma Detection using DenseNet,” *Proceedings of the 13th International Conference on Electronics, Computers and Artificial Intelligence, ECAI 2021*, Jul. 2021, doi: 10.1109/ECAI52376.2021.9515188.
- Dosovitskiy, Alexey, et al. An Image Is Worth 16x16 Words: Transformers for Image Recognition at Scale. arXiv:2010.11929, arXiv, 3 June 2021. arXiv.org, <https://doi.org/10.48550/arXiv.2010.11929>.”
- Y. Iturria-Medina *et al.*, “Early role of vascular dysregulation on late-onset Alzheimer’s disease based on multifactorial data-driven analysis,” *Nat Commun*, vol. 7, no. 1, p. 11934, Jun. 2016, doi: 10.1038/ncomms11934.
- J. M. Yoon *et al.*, “Enhancing foveal avascular zone analysis for Alzheimer’s diagnosis with AI segmentation and machine learning using multiple radiomic features,” *Sci Rep*, vol. 14, no. 1, p. 1841, Jan. 2024, doi: 10.1038/s41598-024-51612-8.
- N. Aslam *et al.*, “Multiple Sclerosis Diagnosis Using Machine Learning and Deep Learning: Challenges and Opportunities,” *Sensors*, vol. 22, no. 20, p. 7856, Oct. 2022, doi: 10.3390/s22207856.
- A. Montolío, J. Cegoñino, E. Orduna, B. Sebastian, E. Garcia-Martin, and A. Pérez del Palomar, “A mathematical model to predict the evolution of retinal nerve fiber layer thinning

in multiple sclerosis patients,” *Comput Biol Med*, vol. 111, p. 103357, Aug. 2019, doi: 10.1016/j.compbimed.2019.103357.

- M. Siger, M. Owidzka, M. Świderek-Matysiak, W. Omulecki, and M. Stasiółek, “Optical Coherence Tomography in the Differential Diagnosis of Patients with Multiple Sclerosis and Patients with MRI Nonspecific White Matter Lesions,” *Sensors*, vol. 21, no. 21, p. 7127, Oct. 2021, doi: 10.3390/s21217127.
- M. Lai *et al.*, “A machine learning approach for retinal images analysis as an objective screening method for children with autism spectrum disorder,” *EClinicalMedicine*, vol. 28, p. 100588, Nov. 2020, doi: 10.1016/j.eclinm.2020.100588.
- A. Appaji *et al.*, “Deep learning model using retinal vascular images for classifying schizophrenia,” *Schizophr Res*, vol. 241, pp. 238–243, Mar. 2022, doi: 10.1016/j.schres.2022.01.058.
- S. D’Alfonso, “AI in mental health,” *Curr Opin Psychol*, vol. 36, pp. 112–117, Dec. 2020, doi: 10.1016/j.copsyc.2020.04.005.
- S. Siuly, Y. Li, P. Wen, and O. F. Alcin, “SchizoGoogLeNet: The GoogLeNet-Based Deep Feature Extraction Design for Automatic Detection of Schizophrenia,” *Comput Intell Neurosci*, vol. 2022, pp. 1–13, Sep. 2022, doi: 10.1155/2022/1992596.
- D.-W. Ko and J.-J. Yang, “EEG-Based Schizophrenia Diagnosis through Time Series Image Conversion and Deep Learning,” *Electronics (Basel)*, vol. 11, no. 14, p. 2265, Jul. 2022, doi: 10.3390/electronics11142265.
- Z. Guo, L. Wu, Y. Li, and B. Li, “Deep neural network classification of EEG data in schizophrenia,” in *2021 IEEE 10th Data Driven Control and Learning Systems Conference (DDCLS)*, IEEE, May 2021, pp. 1322–1327. doi: 10.1109/DDCLS52934.2021.9455509.
- K. Jindal, R. Upadhyay, P. K. Padhy, and L. Longo, “Bi-LSTM-deep CNN for schizophrenia detection using MSST-spectral images of EEG signals,” in *Artificial Intelligence-Based Brain-Computer Interface*, Elsevier, 2022, pp. 145–162. doi: 10.1016/B978-0-323-91197-9.00011-4.
- S. K. Khare, V. Bajaj, and U. R. Acharya, “SchizoNET: a robust and accurate Margenau–Hill time-frequency distribution based deep neural network model for schizophrenia detection using EEG signals,” *Physiol Meas*, vol. 44, no. 3, p. 035005, Mar. 2023, doi: 10.1088/1361-6579/acbc06.
- Z. Yin, J. Li, Y. Zhang, A. Ren, K. M. Von Meneen, and L. Huang, “Functional brain network analysis of schizophrenic patients with positive and negative syndrome based on mutual information of EEG time series,” *Biomed Signal Process Control*, vol. 31, pp. 331–338, Jan. 2017, doi: 10.1016/j.bspc.2016.08.013.
- E.-A. Paraschiv, L. Băjenaru, C. Petrache, O. Bica, and D.-N. Nicolau, “AI-Driven Neuro-Monitoring: Advancing Schizophrenia Detection and Management Through Deep Learning and EEG Analysis,” *Future Internet*, vol. 16, no. 11, p. 424, Nov. 2024, doi: 10.3390/fi16110424.