



Universitatea Națională  
de Știință și Tehnologie  
POLITEHNICA BUCUREȘTI

Școala Doctorală de Electronică, Telecomunicații  
și Tehnologia Informației  
Universitatea Națională de Știință și Tehnologie  
Politehnica din București

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

Decizie nr. \_\_\_\_ din ZZ-LL-AAAA

**REZUMAT TEZĂ  
DE DOCTORAT**

**Silvia Ovreiu**

---

**Analiza Imaginilor de retină folosind algoritmi de  
învățare profundă**

---

**COMISIA DE DOCTORAT**

<b>Prof. Dr. Ing. Ion MARGHESCU</b> Univ. Politehnica din București	Președinte
<b>Prof. Dr. Ing. Mihai CIUC</b> Univ. Politehnica din București	Conducător de doctorat
<b>Conf. Dr. Ing. Alina SULTANA</b> Univ. Politehnica din București	Referent
<b>Prof. Dr. Ing. Liviu GORAȘ</b> Univ. Tehnică „Gheorghe Asachi” din Iași	Referent
<b>Prof. Dr. Ing. Cristian GRAVA</b> Universitatea din Oradea	Referent

**BUCUREȘTI 2023**

---





# Cuprins

Lista tabelelor .....	vii
Lista figurilor .....	ix
Lista abrevierilor .....	xi
Capitolul 1 Introducere .....	13
1.1 Prezentarea domeniului tezei de doctorat .....	13
1.2 Scopul tezei de doctorat .....	14
1.3 Conținutul tezei de doctorat .....	14
Capitolul 2 Prezentare generală .....	14
2.1 Structura ochiului uman .....	15
2.2 Tulburări oculare frecvente .....	16

2.2.1. Retinopatie diabetică (DR) .....	17
2.2.2 Degenerescenta maculară legată de vârstă (AMD).....	<b>Error! Bookmark not defined.</b>
2.2.3 Glaucom.....	<b>Error! Bookmark not defined.</b>
2.2.4 Boala cardiovasculara .....	<b>Error! Bookmark not defined.</b>
2.2.5 Retinopatie hipertensivă .....	<b>Error! Bookmark not defined.</b>
2.2.6 Cataracta .....	<b>Error! Bookmark not defined.</b>
2.2.7 Dezlipirea retinei.....	<b>Error! Bookmark not defined.</b>
2.2.8 Edemul macular .....	<b>Error! Bookmark not defined.</b>
2.2.9 Retinopatia prematură.....	<b>Error! Bookmark not defined.</b>
2.2.10 Erori de refracție .....	<b>Error! Bookmark not defined.</b>
2.3 Modalităților de imagistică ale retinei .....	<b>Error! Bookmark not defined.</b>
2.3.1 Imagistica fundului de ochi.....	<b>Error! Bookmark not defined.</b>
2.3.2 Tomografie cu coerență optică (OCT).....	<b>Error! Bookmark not defined.</b>
2.4 Glaucomul.....	18
2.4.1 Fiziopatologia glaucomului – teoria vasculara și mecanică	<b>Error! Bookmark not defined.</b>
2.4.2 Tipuri de glaucom .....	<b>Error! Bookmark not defined.</b>
2.4.3 Diagnosticarea Glaucomului.....	<b>Error! Bookmark not defined.</b>
2.5 Inteligența Artificială, Învățarea Automată și Învățarea Profundă în medicină ...	18
2.5.1 Inteligența Artificială .....	<b>Error! Bookmark not defined.</b>
2.5.2 Învățarea Automată.....	<b>Error! Bookmark not defined.</b>
2.5.3 Învățarea Profundă.....	<b>Error! Bookmark not defined.</b>
2.6 Rețele Neurale Artificiale .....	<b>Error! Bookmark not defined.</b>
2.7 Rețele Neuronale Convoluționale.....	<b>Error! Bookmark not defined.</b>

2.7.1 Arhitectura unei Rețele Neurale Convoluționale.....	<b>Error! Bookmark not defined.</b>
2.7.2 Crearea unui algoritm de CNN .....	<b>Error! Bookmark not defined.</b>
2.5.3 Tipuri de arhitecturi CNN.....	18
2.8 DL în analiza și prelucrarea de imagini .....	23
Capitolul 3 State of the art .....	24
3.1 Baze de date de imagini de retină folosite în detecția glaucomului.....	24
3.1.1 ORIGA.....	24
3.1.2 ACRIMA .....	<b>Error! Bookmark not defined.</b>
3.1.3 HRF.....	<b>Error! Bookmark not defined.</b>
3.1.4 RIM-ONE .....	<b>Error! Bookmark not defined.</b>
3.1.5 Drishti-GS.....	<b>Error! Bookmark not defined.</b>
3.1.6 SCES.....	<b>Error! Bookmark not defined.</b>
3.2 Detecția glaucomului prin extragerea de caracteristici din retină.....	<b>Error! Bookmark not defined.</b>
3.3 Detecția automată a glaucomului folosind CNN ..	<b>Error! Bookmark not defined.</b>
3.3.1 Detecția glaucomului din imagini 2D ale retinei .....	<b>Error! Bookmark not defined.</b>
3.3.2 Detecția glaucomului din imagini 3D ale retinei .....	<b>Error! Bookmark not defined.</b>
3.4 Concluzii.....	26
Capitolul 4 Detectarea precoce a glaucomului folosind rețele reziduale.....	27
4.1 Introducere .....	27
4.2 Setul de date.....	27
4.3 Metodologie.....	28
4.4 Rezultate .....	30
4.5 Concluzii.....	33
Capitolul 5 Detectia glaucomului folosind rețeaua DenseNet.....	34
5.1 Introducere .....	34
5.2 DenseNet121.....	35

5.2.1 Baza de date și metode.....	35
5.2.2 Rezultate .....	37
5.2.3 Concluzii .....	39
5.3 DenseNet201 .....	40
5.3.1 Baza de date și metode.....	40
5.3.2 Rezultate .....	42
5.3.3 Concluzii .....	43
5.4 Comparația între DensNet121 si DenseNet201 .....	44
5.5 Concluzii.....	45
Capitolul 6 Concluzii .....	47
6.1 Rezultate obținute .....	48
6.2 Contribuții originale.....	49
6.3 Lista lucrărilor originale .....	50
6.4 Perspective de dezvoltare ulterioară .....	50



# Lista tabelelor

Tabelul 2. 1 Componentele rețelei neuronale .....	<b>Error! Bookmark not defined.</b>
Tabelul 2. 2 Funcții de activare .....	<b>Error! Bookmark not defined.</b>
Tabelul 2. 3 Punctele cheie a învățării automate .....	<b>Error! Bookmark not defined.</b>

Tabelul 3. 2 Rezumatul bazelor de date imagini de retină folosite pentru antrearea și testarea algoritmilor de diagnosticare a glaucomului .....	25
--	----

Tabelul 4. 4	Comparație rezultate obținute pentru diferite modele de CNN .....	31
Tabelul 5. 1	Clasificarea setului de date .....	39
Tabelul 5. 2	Matricea de Confuzie.....	42
Tabelul 5. 3	Comparație rezultate ResNet50, DenseNet121 și DenseNet201 .....	45



# Lista figurilor

Figura 2.1 Anatomia ochiului uman .....	<b>Error! Bookmark not defined.</b>
Figura 2.2 Retină normală .....	16
<i>Figura 2. 3 Structura simplificată a retinei</i> .....	<b>Error! Bookmark not defined.</b>
Figura 2. 4 Retina cu DME (Săgeți solide: Microanevrisme, Săgeți întrerupte: Exudate) .....	17
Figura 2. 5 Retinopatie diabetică proliferativă .....	<b>Error! Bookmark not defined.</b>
Figura 2. 6 Degenerescenta maculară legată de vârstă ...	<b>Error! Bookmark not defined.</b>
Figura 2. 7 Ochi normal vs Ochi cu glaucoma .....	<b>Error! Bookmark not defined.</b>
Figura 2. 8 Presiunea intraoculară .....	<b>Error! Bookmark not defined.</b>
Figura 2. 9 OCT .....	<b>Error! Bookmark not defined.</b>
Figura 2. 10 Tomografia în coeficiență optică-OCT .....	<b>Error! Bookmark not defined.</b>
Figura 2. 11 Glaucom vs Normal.....	<b>Error! Bookmark not defined.</b>
Figura 2. 12 Relația dintre Inteligența Artificială, Machine Learning, Rețele Neuronale și Deep Learning.....	<b>Error! Bookmark not defined.</b>
Figura 2. 13 Învățarea supervizată, învățarea semi-supervizată, învățarea nesupervizată .....	<b>Error! Bookmark not defined.</b>
Figura 2. 14 Rețea neuronală stratificată și rețea neuronală artificială.	<b>Error! Bookmark not defined.</b>
Figura 2. 15 Arhitectura CNN .....	<b>Error! Bookmark not defined.</b>
Figura 2. 16 Exemplul de imagine 2D cu filtru [40] .....	<b>Error! Bookmark not defined.</b>
Figura 2. 17 Operația de convoluție [41].....	<b>Error! Bookmark not defined.</b>
Figura 2. 18 Operația de pooling .....	<b>Error! Bookmark not defined.</b>
Figura 2. 19 Operația de transpunere.....	<b>Error! Bookmark not defined.</b>
Figura 2. 20 Funcții de activare .....	<b>Error! Bookmark not defined.</b>
Figura 2. 21 Fazele de instruire, validare și testare în dezvoltarea modelului de învățare automata.....	<b>Error! Bookmark not defined.</b>
Figura 2. 22 Underfitting și overfitting.....	<b>Error! Bookmark not defined.</b>
Figura 2. 23 Arhitectura LeNet-5 .....	19
Figura 2. 24 Arhitectura AlexNet .....	20
Figura 2. 25 Arhitectura VGGNet .....	21
Figura 2. 26 Diferența între VGG16 și VGG19.....	<b>Error! Bookmark not defined.</b>
Figura 2. 27 Arhitectura ResNet [46] .....	21
Figura 2. 28 Diferența între ResNet50, ResNet101 și ResNet152.....	22
Figura 2. 29 Arhitectura DenseNet .....	22
Figura 2. 30 Arhitectura U-Net.....	<b>Error! Bookmark not defined.</b>
Figura 2. 31 Arhitectura Inception Net.....	<b>Error! Bookmark not defined.</b>
Figura 3. 1 Procesul de detectare a glaucomului .....	<b>Error! Bookmark not defined.</b>
Figura 4. 1 Set de date RETINA cu imagini normale (rândul de sus) și imagini afectat de glaucom (rândul de jos) .....	28

Figura 4. 2 Arhitectura Rețelei Neurale Residuale .....	28
Figura 4. 3 Evoluția acurateții pentru seturile de antrenare (roșu) și validare (albastru) per epocă [93] .....	30
Figura 5. 1 Set de date RETINA cu imagini normale (rândul de sus) și imagini de ochi de la pacienți cu glaucom (rândul de jos) .....	36
Figura 5. 2 (stânga) Arhitectura modelului DenseNet121 utilizat; (dreapta) Dense_block și stratul de tranziție [96] .....	38
Figura 5. 3 Imagini normale de calitate slabă clasificate ca glaucom <b>Error! Bookmark not defined.</b>	
Figura 5. 4 Curba ROC obținută după antrenament pentru 50 de epoci.....	40
Figura 5. 5 Arhitectura rețelei DenseNet201 .....	42
Figura 5. 7 Evoluția acurateții pentru antrenament și validare(roșu respectiv albastru)	42
Figura 5. 8 a) Curba ROC b) Curba ROC mărită .....	43

# Lista abrevierilor

AI - Inteligența artificială  
AMD – Degenerescenta maculară legată de vârstă  
CAD – Diagnosticare asistată de calculator  
CNV – Neovascularizare coroidiana  
CNN - Rețelele neurale convoluționale  
DME – Edem macular diabetic  
DL – Deep Learning  
DR – Retinopatie diabetică  
DCNN – Rețele neuronale convoluționale profunde  
IA – Inteligența artificială  
GPU – Procesoarele grafice  
ML – Machine Learning  
OCT – Tomografie cu coerență optică  
ViT – Vision Transformer  
CT – Computer Tomograf  
CT - Tomografie Computerizată  
SNC - sistemului nervos central  
PIO - Presiunea intraoculară  
OMS - Organizația Mondială a Sănătății  
ONH – Centrul nervului optic  
OCT - Optical Coherence Tomography  
OCTA - Optical Coherence Tomography Angiography  
RMN – Rezonanța Magnetică Nucleară  
K-NN – Clasificatorul k-Nearest Neighbors  
SVM – Mașină Vector Suport  
DBSCAN – Density Spatial Clustering of Applications with Noise  
t-SNE - t-Distributed Stochastic Neighbor Embedding  
PCA - Principle Component Analysis  
GMMs - Gaussian Mixture Models  
MDP - Modelul Procesului de Decizie Markovian  
RNA- Rețelele Neurale Artificiale  
FNN - Rețele Neurale Feedforward  
CNN - Rețele Neurale Convoluționale  
RNN - Rețele Neurale Recurente  
LSTM - Rețele Neurale de Memorare a Lungă Durate

AE - Rețele neurale de Autoencoder  
GAN - Generative Adversarial Networks  
MLP - Rețele Neuronale cu Stratouri Multiple  
BP – Backpropagation  
RR - Rețele neuronale recurente  
SGD – Stochastic Gradient Descent  
MSE – Mean Squared Error  
SSIM - Structural Similarity Index  
LSUV - Layer-Sequential Unit Variance  
TP - True Positives  
TN - True Negative  
FP - False Positives  
FN - False Negatives  
ROC - Receiver Operating Characteristic  
AUC - Area Under the Curve  
TPR - True Positive Rate  
FPR - False Positive Rate  
DRI OCT – Doppler Optical Coherence Tomography  
SM- SoftMax  
USPS - United States Postal Service

# Capitolul 1

## Introducere

### 1.1 Prezentarea domeniului tezei de doctorat

Teza de doctorat explorează utilizarea inteligenței artificiale (IA) în detectarea glaucomului din imagini de retină prin intermediul algoritmilor de învățare profundă. Glaucomul reprezintă o afecțiune oculară comună și poate duce la pierderea vederii dacă nu este identificat și tratat la timp. Progresele în IA au fost influențate de factori precum capacitatea de calcul, creșterea datelor disponibile, evoluția hardware-ului și dezvoltarea algoritmilor avansați.

Învățarea automată implică extragerea manuală a caracteristicilor din date și analiza acestora prin modele precum support vector machine sau random forest. Cu toate acestea, volumul mare de date face extragerea manuală dificilă, limitând astfel aplicabilitatea învățării automate. În contrast, învățarea profundă elimină necesitatea extragerii manuale a caracteristicilor, sporind eficiența și utilizarea resurselor.

Învățarea profundă, bazată pe rețele neuronale cu straturi multiple, a demonstrat eficiență în domenii precum viziunea artificială, procesarea limbajului natural și recunoașterea vorbirii. În medicină, aceasta a devenit esențială pentru analiza seturilor mari de date biomedicale, precum imaginile medicale, fisele medicale electronice și genomică, contribuind la avansarea medicinei personalizate.

În special, în analiza imaginilor medicale, învățarea profundă s-a dovedit utilă pentru clasificarea și segmentarea unor afecțiuni precum cancerul mamar, pneumonie sau retinopatie. În contextul analizei imaginilor de retină, algoritmi de învățare profundă sunt utilizați pentru identificarea și segmentarea vaselor de sânge, precum și pentru clasificarea automată a acestora, fiind utili în screening-ul medical pentru glaucom și alte afecțiuni.

Această teză se concentrează pe intersecția dintre medicină și tehnologie, având ca scop dezvoltarea unor instrumente puternice pentru diagnosticarea și tratarea glaucomului, contribuind astfel la progresul în medicina personalizată și îngrijirea sănătății.



## **1.2 Scopul tezei de doctorat**

Scopul acestei teze de doctorat constă în utilizarea tehnologiilor de învățare profundă pentru a dezvolta și evalua algoritmi avansați capabili să identifice semnele precoce ale glaucomului din imagini de retină. Această abordare inovatoare în diagnosticul bolii are ca obiectiv principal identificarea glaucomului în faze incipiente, fără a necesita proceduri invazive sau costisitoare. Deoarece glaucomul are o evoluție progresivă și adesea este diagnosticat într-o fază avansată, când pierderea vederii este semnificativă și ireversibilă, o metodă automată de diagnosticare devine crucială pentru intervenția precoce și tratamentul eficient al bolii.

Această cercetare aduce în prim-plan importanța diagnosticării precoce a glaucomului, deoarece modificările retiniene pot fi dificil de observat în stadiile incipiente. Prin utilizarea unor modele variate de algoritmi de învățare profundă, teza explorează posibilitatea de a identifica glaucomul din imagini de fund de ochi, inclusiv în fazele inițiale când schimbările sunt subtile și greu de detectat cu ochiul liber.

Integrarea tehnologiilor de învățare profundă în diagnosticul glaucomului reprezintă o abordare modernă și scalabilă, care ar putea schimba radical modul în care afecțiunile oculare sunt diagnosticate și tratate. Algoritmii de învățare profundă oferă o analiză rapidă și precisă a datelor, eliminând necesitatea expertizei umane extinse și a timpului considerabil pentru interpretarea imaginilor. Astfel, această teză propune un avans semnificativ în identificarea precoce a glaucomului, deschizând calea către tratamente mai eficiente și îngrijire medicală mai personalizată în domeniul afecțiunilor oftalmologice.

## **1.3 Conținutul tezei de doctorat**

Această teză de doctorat investighează diagnosticul automat al glaucomului din imagini retiniene, focalizându-se pe utilizarea algoritmilor de învățare profundă. Structurată în șapte capitole, această lucrare oferă o perspectivă interdisciplinară, combinând cunoștințe din anatomia și funcționalitatea ochiului uman, inteligența artificială și domeniul medical.

# Capitolul 2

## Prezentare generală


Capitolul propus în teza de doctorat explorează anatomia și funcționarea ochiului uman, evidențiind diferențele între un ochi sănătos și unul afectat de glaucom. Este detaliată structura anatomică a ochiului sănătos și se explică modul în care boala glaucomului afectează această structură și funcționalitatea. De asemenea, sunt prezentate metodele imagistice folosite pentru vizualizarea retinei, locul principal al modificărilor generate de glaucom, și tehnicile actuale de diagnosticare a acestei afecțiuni.

În continuare, capitolul oferă o introducere în algoritmi de învățare automată și în algoritmi de învățare profundă, evidențiind diversele arhitecturi de algoritmi existente și punctând avantajele și dezavantajele acestora. Astfel, acest capitol oferă o perspectivă generală a domeniului în care se concentrează teza de doctorat, concentrându-se pe tehnici de învățare profundă aplicate în analiza retinei în contextul patologiei glaucomului.

### 2.1 Structura ochiului uman

Structura ochiului uman este complexă și esențială pentru perceperea vizuală. Acest organ senzorial conține elemente-cheie precum corneea, cristalinul, retina și nervul optic, care cooperează în concentrarea luminii și transmiterea informațiilor către creier pentru interpretarea acestora ca imagini. Retina este considerată o extensie a sistemului nervos central (SNC), alcătuită din celule ganglionare retiniene, a căror conectare formează nervul optic, fiind axoni ai sistemului nervos central. Această complexitate anatomică

permite ochiului să primească și să interpreteze informațiile luminoase similar cu creierul și măduva spinării, în procesul său vital de percepție vizuală.



*Figura 2.1 Retină normală*

În cercetarea prezentată în această teză, accentul se pune pe structura și funcționarea retinei, componenta crucială a ochiului. Atunci când oamenii privesc un obiect, lumina străbate corneea și este parțial focalizată, apoi trece prin pupila și lentile. Imaginea continuă să fie focalizată de obiectiv și este direcționată prin vitros către o zonă specializată a retinei, numită macula. Macula permite observarea detaliilor fine necesare pentru activități precum cititul, scrierea și percepția culorilor. Pe de altă parte, retina periferică este responsabilă pentru vederea laterală. Retina, un țesut stratificat în ochi, are rolul de a transforma lumina într-un semnal neuronal transmis ulterior către creier pentru interpretare.

Retina reprezintă o extensie a creierului, având rolul crucial de a converti informația luminoasă în semnale neurale pentru analiza ulterioară a creierului. Pentru a-și menține funcționalitatea, retina este alimentată cu sânge printr-o rețea de vase de sânge. Anumite boli, precum diabetul, pot afecta negativ aceste vase de sânge, deteriorându-le și perturbând astfel funcționarea normală a retinei.

## **2.2 Tulburări oculare frecvente**

O multitudine de boli care emană de la ochi, creier sau sistemul cardiovascular se manifestă prin retină. Această secțiune discută cele mai frecvente patologii care pot fi studiate prin imagistica retiniană.

### 2.2.1. Retinopatie diabetică (DR)

Diabetul zaharat, confirmat atunci când nivelul glucozei din sânge depășește 7,0 mmol/L conform OMS [7], poate conduce la hiperglicemie, afectând vasele de sânge și celulele nervoase. Retinopatia diabetică (RD), rezultată din deteriorarea pereților vaselor retinei din cauza hiperglicemiei, este una dintre principalele cauze ale pierderii vederii la adulți. Această afecțiune poate provoca două complicații majore: ischemia și edemul macular diabetic (EMD). Ischemia implică formarea de noi vase de sânge fragile, susceptibile la rupturi, provocând hemoragii severe ce pot duce la pierderea vederii. Pe de altă parte, EMD se dezvoltă când bariera sânge-retină este compromisă, determinând scurgeri de lichid și afectând vederea centrală. Ambele complicații sunt asociate cu deteriorarea fotoreceptorilor și pot afecta semnificativ vederea la persoanele cu diabet zaharat.

Figura 2.4 din lucrare prezintă imagini ale retinei evidențiind EMD sau ischemie, inclusiv hemoragii, exsudate și microanevrisme. În concluzie, diabetul zaharat poate duce la retinopatie diabetică, cu complicații precum ischemia și edemul macular diabetic, ambele având potențialul de a afecta în mod semnificativ vederea.



**Figura 2. 2** Retina cu DME (Săgeți solide: Microanevrisme, Săgeți întrerupte: Exudate) [9]

## 2.4 Glaucomul

Glaucomul este o afecțiune oculară gravă caracterizată de deteriorarea progresivă a nervului optic, esențial pentru transmiterea semnalelor vizuale către creier. Această boală poate cauza pierderea lentă, dar ireversibilă, a vederii și poate fi declanșată de factori precum boli genetice, infecții, leziuni sau afecțiuni cronice. Organizația Mondială a Sănătății (OMS) estimează că glaucomul afectează aproximativ 70 de milioane de oameni în prezent, reprezentând a doua cauză de orbire la nivel global, fiind principala cauză de orbire ireversibilă, urmând cataracta.

O caracteristică distinctivă a glaucomului este caracterul său tăcut, deoarece creșterea presiunii intraoculare poate deteriora nervul optic și poate conduce la o pierdere graduală a vederii. Fiind o afecțiune adesea fără simptome până în stadiile avansate, glaucomul poate rămâne nedetectat la până la 90% dintre persoanele afectate, inclusiv în țările dezvoltate.

Prevalența globală a glaucomului se situează în jurul valorii de 3,4% pentru grupa de vârstă cuprinsă între 40 și 80 de ani, iar estimările indică că până în 2040 ar putea exista aproximativ 112 milioane de persoane afectate la nivel mondial. Această caracteristică asimptomatică și rata ridicată de nediagnosticare constituie provocări majore în gestionarea și tratarea glaucomului, iar netratată corespunzător, această afecțiune oculară poate duce la orbire.


## 2.5 Inteligența Artificială, Învățarea Automată și Învățarea Profundă în medicină

### 2.5.3 Tipuri de arhitecturi CNN

Arhitecturi ale CNN sunt modele de învățare profundă utilizate pentru analiza imaginilor și recunoașterea obiectelor. Acestea includ straturi de convoluție, unde se aplică filtre pe imagini pentru a extrage caracteristici semnificative, straturi de subsampling, care reduc dimensiunea imaginilor și straturi complex conectate care clasifică obiectele în funcție de

caracteristicile complet conectate. În funcție de caracteristicile extrase. Exemple de arhitecturi populare sunt LeNet-5, AlexNet, VGGNet, ResNet, DenseNet, InceptionNet.


**LeNet-5** [43] este o arhitectură de CNN dezvoltată în anii '90. A fost concepută inițial pentru recunoașterea caracterelor scrise de mână în imagini și a jucat un rol semnificativ în dezvoltarea învățării profunde și în aplicarea ei în domeniul recunoașterii vizuale.



*Figura 2. 3 Arhitectura LeNet-5 [43]*

LeNet-5 utilizează mai multe straturi de convoluție și de reducere (pooling) pentru a extrage caracteristici din imaginea de intrare, urmate de straturi complet conectate pentru clasificare.

**AlexNet** [44] este o rețea convoluțională profundă de învățare a mașinilor, care a câștigat concursul de recunoaștere a imaginilor ImageNet în 2012. Modelul AlexNet a fost primul model care a întrecut cu mult performanțele precedente ale rețelelor neuronale.



*Figura 2. 4 Arhitectura AlexNet [44]*

AlexNet a fost construit pe baza Rețelei LeNet-5, dar a adăugat mai multe straturi de procesare, un proces de îmbunătățire accelerată, reglare de greutate și regularizare. Straturile adăugate de AlexNet au permis rețelei să abordeze cu succes probleme cu volum mare de date, precum clasificarea imaginilor în 1000 de clase. AlexNet a fost una dintre primele rețele neuronale care a arătat că rețelele neuronale convoluționale sunt eficiente pentru multe tipuri de probleme de clasificare de imagini.






**Figura 2. 7** Diferența între ResNet50, ResNet101 și ResNet152

Cu toate acestea, adâncimea rețelelor nu înseamnă întotdeauna o performanță mai bună, deoarece cu cât rețeaua devine mai adâncă, cu atât devine mai dificil de antrenat din cauza fenomenului de degradare a performanței (vanishing gradients). De aceea, în practică, se ia în considerare un echilibru între profunzimea rețelei și performanța acesteia pe baza cerințelor specifice ale aplicației sau setului de date.

**DenseNet** [47] este o arhitectură de rețea neuronală profundă care conectează direct toate straturile între ele, rezultând un flux de informații eficiente. Această arhitectură a fost introdusă în 2016 în lucrarea Densely Connected Convolutional Networks.



**Figura 2. 8** Arhitectura DenseNet [47]

Idea cheie din spatele DenseNet este de a utiliza conexiuni directe între toate straturile pentru a promova utilizarea caracteristicilor și a reduce numărul de parametri din rețea.

## 2.8 DL în analiza și prelucrarea de imagini

În analiza de imagini, DL poate fi folosit pentru clasificare, segmentare, recunoașterea obiectelor sau a oamenilor, detectarea anomaliilor și multe altele. În prelucrarea de imagini, poate restaura imagini deteriorate, elimina zgomotul sau genera imagini noi. În cazul detectării glaucomului, rețelele neuronale convoluționale (CNN) pot fi antrenate pentru a identifica caracteristicile specifice ale ochilor afectați și pentru a prezice probabilitatea de glaucom.

Studiile au arătat că CNN-urile sunt precise în detectarea glaucomului. Un studiu din 2018 a arătat o acuratețe de 97,9% în detectarea glaucomului folosind imagini de fund de ochi. Totuși, aceste rețele necesită date semnificative pentru antrenare și nu ar trebui să înlocuiască evaluarea medicală de către un oftalmolog. Utilizarea lor poate îmbunătăți diagnosticul, dar necesită o evaluare atentă și corelare cu informațiile medicale provenite de la specialiști în domeniu.

# Capitolul 3

## State of the art

Acest capitol explorează progresele și inovațiile recente din domeniul algoritmilor de Deep Learning aplicate imaginilor de retină pentru diagnosticarea glaucomului. Se concentrează pe contribuția acestor tehnologii în detectarea precoce și precisă a afecțiunii. Sunt analizate rețelele neurale artificiale, precum CNN și alte modele de învățare profundă, utilizate pentru analiza datelor imagistice. De asemenea, sunt prezentate diversele baze de date de imagini cu glaucom folosite în literatură pentru antrenarea și validarea algoritmilor.

În cadrul acestui studiu, se evaluează avantajele și dezavantajele fiecărui model examinat, oferind o perspectivă asupra rezultatelor obținute. De asemenea, se discută despre provocările și perspectivele viitoare în acest domeniu în continuă dezvoltare. Informațiile prezentate au potențialul de a îmbunătăți înțelegerea potențialului algoritmilor de Deep Learning în îmbunătățirea diagnosticului și gestionării glaucomului, contribuind astfel la evoluția diagnosticului și tratamentului acestei afecțiuni oftalmologice.

### 3.1 Baze de date de imagini de retină folosite în detecția glaucomului

Această secțiune prezintă principalele baze de date de imagini publice și private care au fost utilizate recent pentru a evalua performanța algoritmilor din literatură.

Bazele de date includ fie doar imagini cu glaucom sau imagini cu mai multe patologii. De asemenea, vor fi prezentate atât baze de date publice cât și cele private.

Pentru a antrena și valida algoritmi de DL pentru detecția automată a glaucomului, diferite grupuri de cercetare și-au creat propriile baze de date [52]. Unele grupuri au făcut aceste baze de date publice, pentru a fi folosite și de alți cercetători, altele au fost păstrate private.

**Tabelul 3. 1** Rezumatul bazelor de date imagini de retină folosite pentru diagnosticare a glaucomului

Bază de date	Număr imagini	Imagini cu Glaucom	Imagini Sănătoase	Rezoluție	Scop
ORIGA	650	168	482	3072 × 2048	Segmentarea Discului & Cupei optice
ACRIMA	705	396	309	2048 × 1536	Detecția glaucomului
HRF	45	15	15	3304 x 2336	DR Grading
RIM-ONE	169	51	118	2144 × 1424	Detecția glaucomului
Drishti-GS	101	31	70	2896 × 1944	Segmentarea Discului & Cupei optice
SCES	1676	46	1630	3888 × 2592	Detecția glaucomului
<b>Total</b>	<b>3346</b>	<b>707</b>	<b>2624</b>		

Această secțiune a prezentat bazele de date publice și private cu imagini de retină utilizate în mod obișnuit pentru detectarea și clasificarea glaucomului.

Observăm că seturile de date create conțin fie 2 categorii de imagini: glaucom și imagini sănătoase, fie mai multe categorii, cum este HRF, care conține, pe lângă imaginile cu glaucom și cele sănătoase, și imagini de retină afectată de diabetoretinopatie.

Algoritmii pot fi antrenați de la zero, din rețele pre-antrenate sau pe ansambluri de rețele CNN. Performanța modelului depinde de numărul de imagini, sarcinile de preprocesare, calitatea imaginii și de sarcina la îndemână [59].

În continuare vom prezenta diferitele metode de analiză și detecție automată a glaucomului existente în literatură. Metodele sunt împărțite în 2 categorii: cele care detectează glaucomul bazându-se pe extragerea de caracteristici din imagine și cele care fac diagnosticarea automat.

### **3.4 Concluzii**

Metodele bazate pe rețele neuronale convoluționale (CNN) au demonstrat eficiență remarcabilă în detectarea glaucomului din imagini ale fundului de ochi, acoperind diverse aspecte precum segmentarea optică, clasificarea bolii și identificarea stadiilor diferite ale glaucomului. Aceste tehnici utilizează variante de CNN-uri pentru extragerea caracteristicilor din imagini sau pentru clasificare directă, susținute de diverse arhitecturi CNN, cum ar fi VGG, ResNet sau Inception, demonstrând performanțe promițătoare pe diferite seturi de date. Cu toate acestea, există provocări în detectarea glaucomului în stadiile incipiente, iar performanța algoritmilor poate varia în funcție de setul de date utilizat, necesitând eforturi continue pentru dezvoltarea și validarea algoritmilor robusti pentru o detecție timpurie și precisă a acestei afecțiuni oculare în practica clinică.

# Capitolul 4


## Detectarea precoce a glaucomului folosind rețele reziduale

### 4.1 Introducere

Rețelele neuronale profunde, în special rețelele reziduale, au captat atenția în detectarea precoce a glaucomului din imagini de fund de ochi. Aceste tehnici avansate permit identificarea semnelor incipiente ale glaucomului, facilitând intervenții rapide pentru prevenirea deteriorării optice ulterioare. Procesul implică colectarea datelor imagistice, prelucrarea acestora, construirea și antrenarea rețelei reziduale, iar rezultatele obținute sunt evaluate pentru performanța diagnosticului. În ciuda eficienței lor, aceste tehnologii ar trebui să completeze evaluările făcute de medicii specialiști, susținând un diagnostic și tratament corespunzător pentru glaucom. Detectarea precoce a glaucomului rămâne o provocare complexă, iar utilizarea rețelelor reziduale reprezintă o direcție promițătoare în această domeniu, oferind posibilitatea unor intervenții mai eficiente și tratament precoce.

### 4.2 Setul de date

În acest studiu s-a folosit un set de date proprietar care conține imagini color ale fundului de ochi în stadii incipiente de glaucom (set de date RETINA).



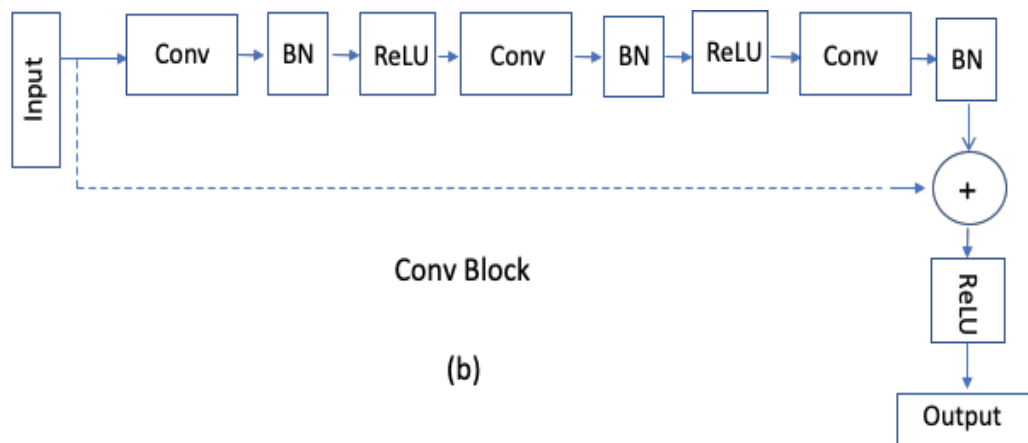
**Figura 4. 1** Set de date RETINA cu imagini normale (rândul de sus) și imagini afectat de glaucom (rândul de jos)

Numărul total de imagini rezultate din toate cele 4 seturi de date utilizate este de 826, dintre care 460 de imagini de retina au fost etichetate ca fiind afectate de glaucom și 366 imagini provenind de la ochi sănătoși.

### 4.3 Metodologie

În procesul de pre-procesare conform [86] și [87], focusul s-a concentrat pe zona discului optic și a împrejurimilor sale, având în vedere impactul principal al glaucomului. Astfel, imaginile de fund de ochi au fost manual decupate în jurul opticului pentru a servi ca intrare pentru modelul propus. Setul de date a fost apoi împărțit aleator într-un set de antrenare și unul de validare, respectând proporția de 80% pentru antrenare și 20% pentru validare. Etichetarea imaginilor s-a făcut automat prin segregarea acestora în sub-foldere distincte, pentru subiecții cu glaucom și pentru cei sănătoși.

Procesul ulterior a implicat normalizarea inițială a valorilor pixelilor la un interval între 0 și 1, urmată de standardizare. Augmentarea imaginilor a fost aplicată atât pe seturile de antrenare, cât și pe cele de validare, în vederea îmbunătățirii robusteții și performanței algoritmului propus.



**Figura 4. 2** Arhitectura Rețelei Neurale Residuale

Augmentarea datelor este o tehnică de învățare automată care este folosită mai ales în imagistica medicală, din cauza lipsei de imagini suficiente. Ea constă în adăugarea unei

serii de transformări la imagini cu scopul de a simula un set de date mai mare prin crearea de versiuni modificate ale imaginilor deja existente în setul de date. Scopul principal al creșterii de date este de a evita supra-învățarea (overfitting), care este o problemă comună care apare atunci când se lucrează cu baze de date mici.

În această lucrare am aplicat următoarele transformări: flipping orizontal și vertical, mărirea imaginilor cu un factor de rază între [0.2, 1.0], rotirea imaginilor de la 1 la 180 de grade, cu pași de 20 de grade și forfecarea cu un factor de 0.2 precum și luminozitatea cu un interval de factori de [0.2, 1.0].

### **Antrenarea modelului**

Pentru a antrena imaginile noastre am folosit rețeaua reziduală propusă de [88]. Ca și în Figura 4.2 a, rețeaua înlanțuie 4 blocuri convoluționale, fiecare dintre ele constând din: 3 straturi convoluționale, normalizare pe loturi [89], unități liniare rectificate [90] și un strat de adăuție care adaugă intrarea neschimbată. Într-un bloc convoluțional, reprezentat în Figura.4.2.b, Conv este un strat convoluțional 2D [91], este stratul de normalizare pe loturi și este unitatea liniară rectificată.

Conform Figurii 4.2 care exemplifică arhitectura rețelei neurale, primul *ConvBlock* se repetă de 3 ori, al doilea de 4 ori, al treilea de 6 ori și ultimul de 3 ori. Pentru fiecare bloc, filtrele au dimensiunea  $1 \times 1$  sau  $3 \times 3$ , singura diferență între filtre este numărul de canale: în primul bloc filtrele au 64, respectiv 256 canale, al doilea 128 și 512, al treilea 256 și 1024 ultimile 512, respectiv 2048.

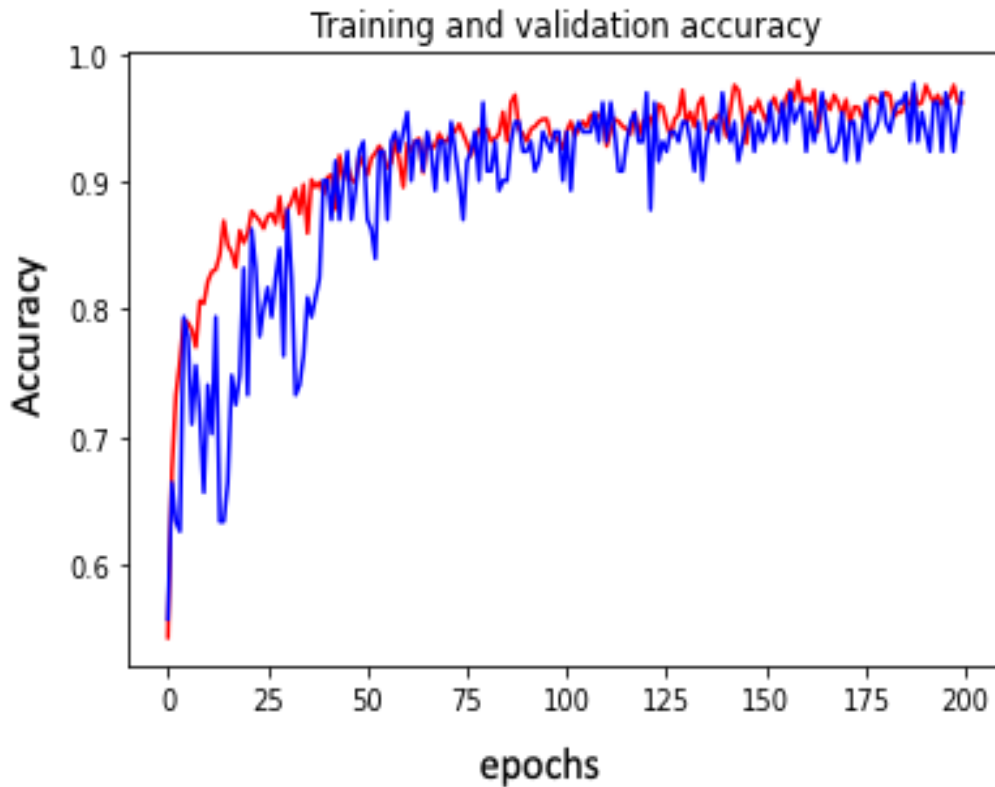
Intrarea modelului este formată din imagini ONH cu dimensiunea de  $224 \times 224 \times 3$ . Marimea imaginilor este redusă după fiecare ConvBlock, ca în Figura 4.2 a

Primul strat al modelului este un strat convoluțional cu un filtru de dimensiune  $7 \times 7$  și 64 de canale, urmat de un strat de normalizare a lotului și un strat ReLU. Ultimul strat este o funcție SoftMax de 2 clase (SM ca în Figura 4.2 ) care face clasificarea între ochi cu glaucom și ochi sănătoși.

Modelul pe care l-am utilizat în această lucrare este modelul de rețea reziduală pre-antrenată pe setul de date *ImageNet* [92], ResNet50 disponibil în biblioteca Deep Learning Keras. Acesta are 50 de straturi și 25.636.712 parametri și a fost inițial antrenat pe imagini din setul de date *ImageNet*. Noi am modificat ultimele straturi și le-am făcut pe toate antrenabile.

Modelul a fost antrenat folosind o tehnică de optimizare a gradientului Stochastic Descent, cu o rată de învățare de 0,0001 și un impuls de 0,9. Pentru a măsura valoarea pierderii, a fost utilizat criteriul de entropie încrucișată. După formarea modelului nostru pentru 200 de epoci, am obținut un nivel de precizie al setului de validare de 0,9695 (Figura 4.3)





*Figura 4.3* Evoluția acurateții pentru seturile de antrenare (roșu) și validare (albastru) per epocă [93]

## 4.4 Rezultate

După ce am antrenat modelul nostru timp de 200 de epoci, am obținut un nivel de acuratețe al setului de validare de 0,9695. În Figura 4.3 este reprezentată evoluția acurateții obținută pentru ambele seturi de date, de instruire și de validare, în timpul antrenării pe parcursul a 200 de epoci.

Dintre imaginile de glaucom în stadiu incipient din setul de date RETINA, 5 din cele 8 imagini etichetate ca glaucom din setul de validare au fost clasificate corect de modelul nostru. Toate imaginile etichetate ca fiind sănătoase care au fost, de asemenea, clasificate corect. Aceasta înseamnă un scor F1 de 0,769 pe setul de date RETINA. Prin urmare, în timp ce clasificarea de către experții umani nu a fost posibilă doar pe baza acestui set de imagini, acest model a fost capabil să furnizeze o analiză preliminară cu un nivel de încredere relativ ridicat.

Algoritmul a fost implementat în Google Collab, utilizând biblioteca DL Keras, back-end de TensorFlow.

Diagnosticul precis al glaucomului în stările sale incipiente, când modificările produse pe capul nervului optic sunt abia vizibile de ochiul uman, în prezent este posibil doar

împreună cu alte examinări cum ar fi tonometria, perimetria, gonioscopia și tomografia de coerență optică.

Deoarece semnele din imagine sunt adesea prea subtile, este dificil pentru un specialist să diferențieze glaucomul de un ochi normal.

Rezultatele au demonstrat că rețelele neuronale convoluționale și, în special, rețelele reziduale, sunt capabile să diferențieze exact între glaucom și non-glaucom prin analiza imaginilor. Precizia modelului nostru de rețele reziduale a fost de 0,9695 pe setul de validare. Printre imaginile cu glaucom în stadiu incipient din setul de date private, 62% dintre imagini au fost clasificate corect.

Comparația rezultatelor obținute în această lucrare cu rezultate din literatura de specialitate este destul de dificil de făcut, din cauza antrenării și testării algoritmilor de învățare profundă pe seturi de date diferite.

În plus, în această lucrare s-a folosit, pe lângă bazele de date publice cu imagini de glaucoma care sunt folosite și în alte modele propuse în literatură, o bază de date nouă, care face comparația și mai dificilă.

Mai mult, fiecare publicație folosește o metodă diferită pentru a evalua calitatea rezultatelor obținute, cum ar fi: acuratețea, sensibilitatea, specificitatea, F1-score, AUC. Având în vedere că baza de date pe care am antrenat rețeaua ResNet este compusă din baza de date proprietară, RETINA și alte 3 baze de date publice – ACRIMA, ORIGA și HRF, vom compara rezultatele obținute în acest capitol cu algoritmi din literatură care sunt antrenați pe aceleași baze de date.

În [94] și [95] autorii au antrenat modelele VGG16, VGG19, InceptionV3, ResNet50 și Xception pe un set de date format din 5 baze de date publice: HRF, Drishti-GS1, RIM-ONE, sjchoi86-HRF și ACRIMA. Modelele de CNN folosite au fost pre-antrenate pe *ImageNet*.

**Tabelul 4. 1**  Comparație rezultate obținute pentru diferite modele de CNN

<b>Model CNN</b>	<b>Baza de date</b>	<b>Acuratețea</b>	<b>Scor F1</b>
VGG16	HRF + Drishti-GS1 + RIM-ONE + sjchoi86-HRF + ACRIMA	0.8948	0.9005
VGG19	HRF + Drishti-GS1 + RIM-ONE + sjchoi86-HRF + ACRIMA	0.9069	0.9125

Inception3	HRF + Drishti-GS1+ RIM-ONE + sjchoi86-HRF + ACRIMA	0.9000	0.9056
ResNet50	HRF + Drishti-GS1+ RIM-ONE + sjchoi86-HRF + ACRIMA	0.9029	0.9076
Xception	HRF + Drishti-GS1+ RIM-ONE + sjchoi86-HRF + ACRIMA	0.8977	0.9051
<b>ResNet50</b>	<b>ORIGA + HRF + ACRIMA + RETINA</b>	<b>0,9695</b>	<b>0,769 (pe RETINA)</b>

HRF + Drishti-GS1+ RIM-ONE + sjchoi86-HRF + ACRIMA însumează un total de 1707 imagini (788 cu glaucom și 919 normale), pe când ORIGA + HRF + ACRIMA + RETINA însumează un total de 826 de imagini (460 de imagini de glaucom și 366 imagini de ochi sănătoși).

Observăm din Tabel 4.1 că rezultatele obținute în această lucrare pentru ResNet50 sunt mai bune, din punct de vedere al acurateței decât cele obținute în literatură pe seturi de date similare, desi setul de antrenare folosit în acest model este, ca număr de imagini la jumtatea celui folosit în literatură.

Scorul F1 în schimb este mai mic (0.769 vs. 0.9076) calculat exclusiv pe rezultatele obținute de algoritmul ResNet50 pe setul de date RETINA. Această valoare a lui F1 este dată de dezechilibrul claselor (460 de imagini de glaucom și 366 imagini de ochi sănătoși), ceea ce înseamnă că ResNet50 este capabilă să clasifice corect clasa majoritară (glaucom), dar nu este la fel de bună pentru a clasifica corect clasa minoritară (imagini normale). Aceasta poate fi explicată prin faptul ca modelul ResNet50 ar putea clasifica un număr mai mare de imagini fals negative, mai exact consideră că sunt imagini sănătoase cele din categoria glaucom. Având în vedere că, din cele 460 de imagini cu glaucoma pe care a fost antrenat modelul, 46 sunt imagini de glaucom incipient, adică foarte aproape de imagini sănătoase, este posibil ca algoritmul să le clasifice ca fiind sănătoase. Acest lucru este demonstrat și de rezultatele obținute pe testul de validare: doar 5 din 8 imagini cu glaucom au fost clasificate corect, restul de 3 au fost clasificate ca fiind sănătoase.

Cu toate acestea, considerăm că rezultatele sunt promițătoare în ceea ce privește detectarea glaucomului în fază incipientă cu modelul propus în acest capitol, dacă acesta ar fi antrenat pe o bază de date mai mare de imagini de glaucom incipient.

## 4.5 Concluzii

În concluzie, în această parte a cercetării doctorale am aplicat un model de rețele reziduale pe un set de date cu imagini color de fund de ochi, constând atât în imagini preluate de la subiecți cu glaucom în stadiu incipient cât și de la subiecți cu glaucom în stadiu avansat. Am demonstrat că prin aplicarea unei rețele reziduale putem diagnostica glaucomul cu un nivel de precizie 96.97%. Acesta este un indicator bun ca rețelele neuronale convoluționale au un potențial mare de a deveni un instrument pentru detectarea glaucomului precoce.

Prin urmare, procedura complexă folosită azi pentru diagnosticarea glaucomului precoce ar putea fi eliminată printr-un sistem de diagnostic asistat de computer care utilizează algoritmi de învățare profundă.

În concluzie, utilizarea rețelelor reziduale în detectarea precoce a glaucomului reprezintă o abordare promițătoare și inovatoare în domeniul oftalmologiei. Această tehnică avansată de învățare profundă permite identificarea semnelor precoce a glaucomului în imagini de fund de ochi, ceea ce facilitează intervenții rapide și tratament adecvat.

Prin utilizarea rețelelor reziduale, se pot obține rezultate precise și generalizabile, permițând detectarea glaucomului în stadii incipiente. Această ofertă oferă oportunitatea de a interveni înainte ca deteriorarea optică să devină ireversibilă, contribuind astfel la îmbunătățirea prognosticului și a calității vieții pacienților.

Este important de menționat că rezultatele obținute prin intermediul rețelelor reziduale trebuie interpretate în contextul evaluării clinice efectuate de către medicii specialiști în oftalmologie. Aceste tehnici avansate reprezintă instrumente complementare care pot sprijini procesul de diagnostic și de luare a deciziilor, dar nu trebuie să înlocuiască expertiza medicală.

În continuare, cercetările și dezvoltarea în acest domeniu pot contribui la rafinarea tehnicilor de detecție precoce a glaucomului și la integrarea lor în practica medicală curentă. Utilizarea rețelelor reziduale în detectarea precoce a glaucomului reprezintă un pas important în direcția îmbunătățirii gestionării și tratamentului acestei afecțiuni oculare grave.

# Capitolul 5

## Detectia glaucomului folosind rețeaua DenseNet

### 5.1 Introducere

În lucrarea a doua am aplicat un set de rețele neuronale conectate dens cu 121 straturi pe un set de date de imagini colorate de fund de ochi, constând atât din imagini cu glaucom în stadiu precoce, cât și imagini aflate într-un stadiu avansat al glaucomului. Am demonstrat că dacă aplicăm o imagine de rețea dens conectată putem diagnostica glaucomul cu 95,6%. Acesta este un indicator bun că rețele neuronale convoluționale un este un potential mare de a deveni un instrument pentru diagnosticul automat al glaucomului.

Studiul privind glaucomul folosind rețeaua DenseNet (Dense Convolutional Network) se concentrează pe utilizarea tehnologiilor de învățare profundă pentru identificarea precoce a acestei afecțiuni oculare.

Studiul prezent poate evalua performanța rețelei DenseNet în diagnosticarea automată a glaucomului utilizând metode precum validarea încrucișată (cross-validation) sau divizarea setului de date în set de antrenare și set de testare. Performanța modelului poate fi evaluată în funcție de metrici precum acuratețea, sensibilitatea și specificitatea.

Asadar, utilizarea rețelelor DenseNet în studiul privind detectarea glaucomului reprezintă o abordare inovatoare și promițătoare. Aceasta implică antrenarea rețelei pe imagini de fund de ochi pentru a identifica modele specifice asociate glaucomului. Această metodă poate contribui la detectarea precoce a glaucomului și la îmbunătățirea diagnosticului și managementului acestei afecțiuni oculare.

Rețelele neuronale convoluționale s-au dovedit a funcționa foarte bine în detectarea modificărilor foarte subtile produse de glaucom.

În această lucrare am propus o metodă care utilizează rețele neuronale conectate dens pentru detectarea timpurie a glaucomului.

## 5.2 DenseNet121

În prima parte, am aplicat rețeaua DenseNet cu 121 straturi, care a fost pre-antrenată inițial pe un set de date de imagini naturale, *ImageNet* [72]. Am obținut o precizie de 95,6% și un scor F1 de 0,97% pe un set de date care conține atât imagini cu glaucom timpuriu cât și avansat. Rezultatele indică faptul că algoritmiile rețelelor neuronale convoluționale au puterea de a deveni un instrument de screening eficient din punct de vedere al costurilor pentru screeningul populației, pentru a evita orbirea ireversibilă produsă de glaucom.

### 5.2.1 Baza de date și metode

Ca bază de date am folosit RETINA împreună cu ACRIMA.

Imaginile au fost normalizate (valoarea pixelilor a fost redusă la o valoare între 0 și 1 și standardizată. Pentru a simula un set de date mai mare, a fost aplicată tehnica de mărire a imaginii.


Primul pas al preprocesării a fost decuparea manuală a imaginilor ale retinei din jurul capului nervului optic (ONH).

Augmentarea setului de imagini se aplică în cea mai mare parte în domeniul imagisticii medicale, în cazul în care, de obicei, nu există suficiente date disponibile. Augmentarea datelor constă în aplicarea unei serii de transformări asupra imaginilor, cum ar fi rotația, mărirea, răsucirea verticală și orizontală, strălucirea, taierea cu scopul de a simula un set de date mai mare prin crearea de versiuni modificate ale imaginilor deja disponibile în setul de date. Efectul principal al măririi datelor este de a evita *overfitting-ul*.

În studiul de față, pe imagini s-au aplicat *flipping-ul* vertical și orizontal precum și o rotație cu un interval de  $[0, 360]$ . Imaginile au fost redimensionate la dimensiunea  $(224 \times 224 \times 3)$  aceasta fiind dimensiunea de intrare pentru rețeaua DenseNet121.

Etichetarea imaginilor se face automat prin introducerea lor în 2 subfoldere: un folder este folosit pentru imagini cu glaucom și al doilea folder pentru imagini cu ochi normali.

Imaginile cu glaucom au fost etichetate cu 0 și cele normale cu 1. Apoi, setul de date a fost împărțit aleatoriu în seturi de antrenament și validare, urmând regula de 80% imagini de antrenament și 20% imagini de validare. Pentru a se face clasificarea între imagini normale și cele cu glaucom s-a folosit rețeaua convoluțională dens conectată (DenseNet121) cu 121 straturi.



**Figura 5.1** Set de date RETINA cu imagini normale (rândul de sus) și imagini de ochi de la pacienți cu glaucom (rândul de jos)

Există trei tipuri de blocuri într-o arhitectură DenseNet: *bloc dens*, *bloc convolutional*, și *strat de tranziție*. Blocul convolutional (*conv\_block*) este similar blocului de identitate din ResNet și este blocul de bază a unei rețele DenseBlock: primul DenseBlock conține 6 blocuri convolutionale (*ConvBlock*), al doilea este format din 12 blocuri convolutionale (*ConvBlock*), al treilea 24 de blocuri convolutionale (*ConvBlock*) și ultimul din 16 blocuri convolutionale (*ConvBlock*). Blocul dens este componenta principală a DenseNet în care blocurile de convoluție sunt concatenate și conectate dens.

Primele 3 blocuri dense sunt urmate de un strat de tranziție (stratul de tranziție), iar ultimul este urmat de stratul mediu comun. Stratul de tranziție se conectează la blocuri dense adiacente și reduce dimensiunile hărții de caracteristici, care rămân neschimbate în blocul dens.

Primul strat al modelului este un strat convolutional cu un filtru de  $7 \times 7$  și un stride de 2, urmat de un strat de  $3 \times 3$  *Max Pooling* cu o valoare stride de 2. Intrarea modelului constă din imagini ONH cu o dimensiune de  $224 \times 224 \times 3$ . Dimensiunea imaginii este redusă la  $112 \times 112$ , apoi  $56 \times 56$ ,  $28 \times 28$ ,  $14 \times 14$  atingând în ultimul strat o dimensiune de  $7 \times 7$ .

Stratul de clasificare este urmat de o funcție Softmax care produce 2 clase: glaucom și normal. Modelul utilizat în acest studiu este rețeaua convolutională *DenseNet121*, disponibilă în biblioteca DL Keras. Modelul are 121 de straturi și 8062504 parametri și a fost inițial antrenat pe imagini din setul de date ImageNet [72].

Deoarece modelul inițial implementat în Keras are o ieșire cu 1000 de clase, în această lucrare am modificat ultimile straturi pentru clasificarea în 2 clase. Toate straturile modelului nostru au fost setate ca antrenabile.

Modelul a fost antrenat folosind o tehnică de optimizare a descensiei gradientului stochastic, cu o rată inițială de învățare de  $1e-4$  și un impuls de 0,9. Iar după antrenare rata de învățare a scăzut cu un factor de 0,5, până la  $1e-6$ .

## 5.2.2 Rezultate

În acest tabel ( Tabel 5.1) avem 82 de imagini care au fost clasificate corect ca fiind normale (adevărat pozitiv = 81, fals pozitiv = 1) și 88 de imagini au fost clasificate ca având boli de glaucom (adevărat negativ=84, fals negativ=4) incluzând toate imaginile timpurii ale glaucomului din setul de date RETINA. Acest rezultat este obținut din cauza calității slabe a unor imagini normale din baza de date RETINA care au fost clasificate ca glaucom, după cum se poate observa în Figura 5.4.

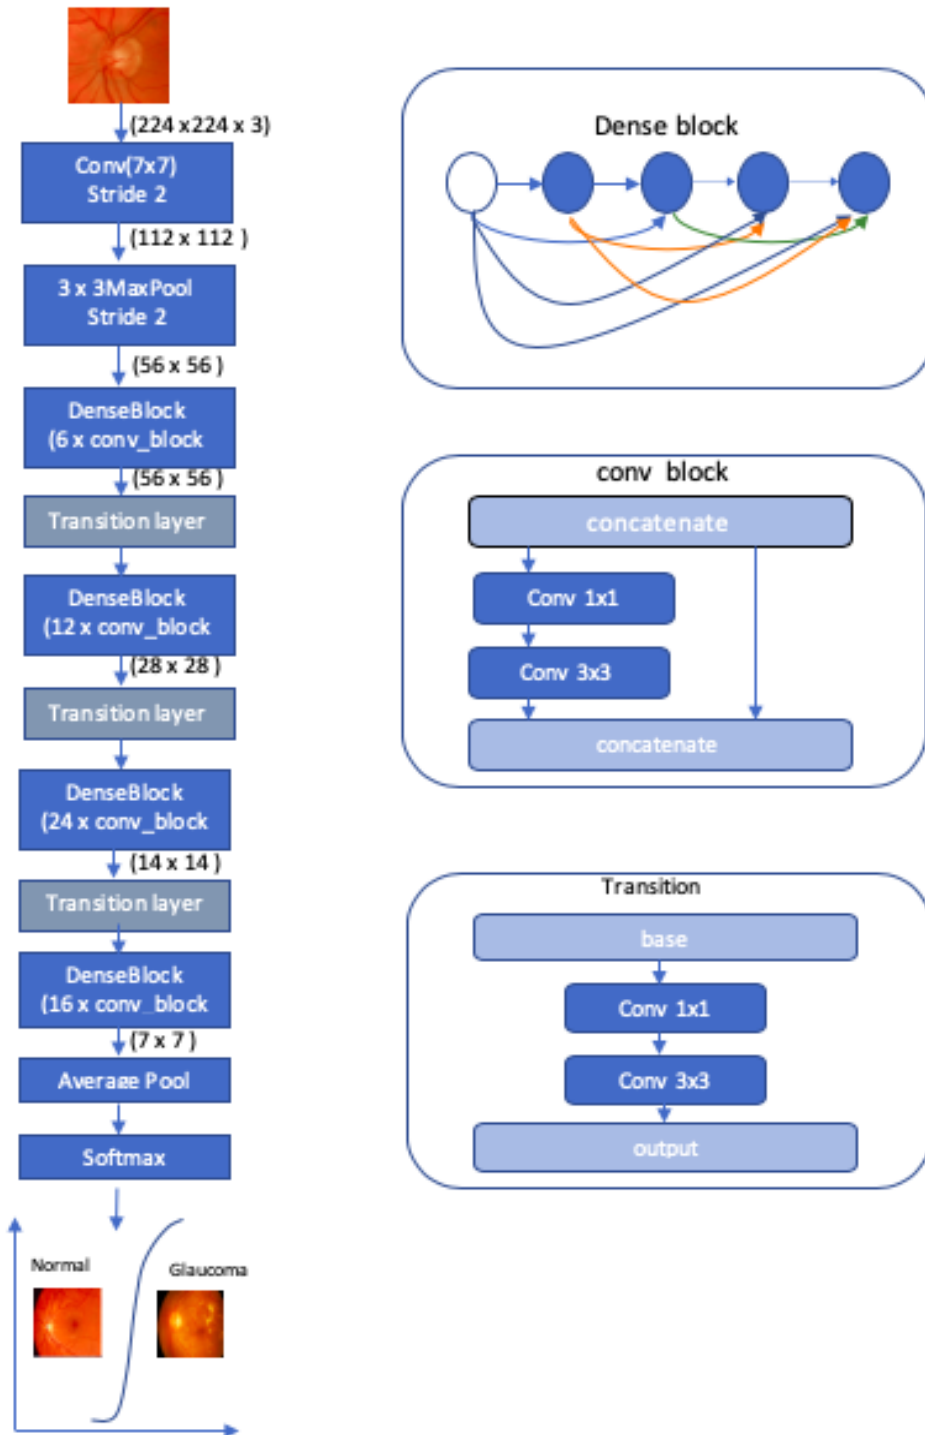
Valoarea sensibilității este 0.952, în timp ce specificitatea este 0.988. Am obținut un scor F1 de 0,97.

84 de imagini de glaucom au fost clasificate corect, inclusiv toate imaginile de glaucom timpurii din setul de date RETINA. Setul de date RETINA conține doar imagini afectate de glaucom în stadiu precoce, ceea ce înseamnă că modificările produse de glaucom pe imagini sunt foarte subtile, aceasta făcând imposibilă diagnosticarea doar de ochiul uman, fără alte examinări secundare.

Zona de sub curbă (AUC) are o valoare de 0,971 (Figura 5.5), ceea ce sugerează că modelul este bun la diferențierea dintre clase. Precizia obținută cu rețelele neuronale dens conectate este mai bună decât precizia obținută în [96] cu rețelele reziduale: în jur de 0.9, după 50 de epoci și 0.956 după 200 de epoci.

În plus, modelul actual s-a dovedit a fi mai bun în recunoașterea imaginilor glaucomului timpurii. Ambele modele (rețele conectate dens și rețele reziduale) au fost instruite pe un set de date similar.





*Figura 5. 2 (stânga) Arhitectura modelului DenseNet121 utilizat; (dreapta) Dense\_block și stratul de tranziție [97]*

**Tabelul 5. 1 Clasificarea setului de date**


<b>170</b>	<b>Actual Normal</b>	<b>Actual Glaucoma</b>
<b>Predicted Normal</b>	<b>81</b>	<b>1</b>
<b>Predicted Glaucoma</b>	<b>4</b>	<b>84</b>

### 5.2.3 Concluzii

În concluzie, am aplicat un set de rețele neuronale conectate dens cu 121 straturi pe un set de date de imagini ale fondului de culoare constând atât din stadiu precoce, cât și din stadiul avansat al glaucomului. Am demonstrat că dacă aplicăm o imagine de rețea dens conectată putem diagnostica glaucomul cu 95,6%. Acesta este un indicator bun cu rețelele neuronale convoluționale cu un potențial mare de a deveni un instrument pentru diagnosticul automat al glaucomului.

Rețeaua DenseNet este mai bună la clasificarea între 2 seturi de date care conțin imagini cu glaucom și imagini fără glaucom. Rezultatele au demonstrat că rețelele neuronale conectate dens sunt capabile de diferențierea exactă între glaucom și non-glaucom prin analiza imaginilor.

S-au dovedit a fi capabile pentru diagnosticarea corectă a imaginilor precoce ale glaucomului, care au modificări foarte subtile produse de glaucom, care nu sunt vizibile de ochiul uman și necesită de obicei o examinare suplimentară costisitoare. În plus, rețeaua neuronală dens conectată utilizată în acest studiu oferă rezultate mai bune în ceea ce privește precizia decât cea a rețelelor neuronale reziduale.



*Figura 5. 3 Curba ROC obținută după antrenament pentru 50 de epoci*

Precizia rețelei noastre dens conectate este de 0,956 după 50 de epoci pe setul de validare, în timp ce precizia obținută cu rețeaua reziduală pe un set de date similar a fost în jur de 0,9 după același număr de epoci.

## 5.3 DenseNet201

În cea de-a doua parte am folosit arhitectura DenseNet201 pentru a detecta glaucomul din imagini color de fund de ochi.

### 5.3.1 Baza de date și metode

Am ales pentru acest studiu ca bază de date, Acrima [54] care conține 705 imagini digitale cu fund de ochi: 396 imagini cu glaucoma și 309 imagini de la ochi sănătoși. La setul de date Acrima am adăugat setul de date RETINA, ca și la metoda anterioară.

Așadar, am obținut un set de date cu un număr total de 856 de imagini combinate cu fund de ochi cu glaucom și fund de ochi normali.

#### Pre-procesare

Deoarece baza de date este limitată ca dimensiune, a fost implementată o metodă de creștere a datelor pentru a simula un set de date mai mare. Am aplicat o metodă tehnică

de creștere a datelor pentru a mări cantitatea de date utilizate prin copii ușor transformate ale datelor existente. Aceste transformări includ rotația, răsturnarea verticală și orizontală, mărirea sau luminozitatea pentru a modifica setul de date existent, dar totuși pe baza datelor reale, reducând overfitting-ul. Metoda prezentată a aplicat răsturnarea orizontală și verticală, precum și un interval de rotație de  $[0, 360]$ .

Mai mult, imaginile sunt redimensionate, pentru a corespunde cu dimensiunea de intrare DenseNet201 ( $224 \times 224 \times 3$ ). În cele din urmă, au fost create două subfoldere care conțin imagini etichetate, iar setul de date a fost împărțit aleatoriu în 80% imagini de antrenament și 20% imagini de validare.

### Metodă

Am propus implementarea DenseNet201 ce are 201 straturi. Această arhitectură implică utilizarea de blocuri dense, convoluționale și straturi de tranzație pentru a extrage și învăța caracteristici complexe din imagini (vezi Figura

Blocurile dense sunt componente cheie ale arhitecturii DenseNet și sunt responsabile de conectarea densă între straturile din rețea.

Primul bloc dens conține 6 blocuri convoluționale, al doilea include 12 blocuri convoluționale, al treilea este format din 48 de blocuri convoluționale și ultimul bloc dens conține 32 de blocuri convoluționale.

Blocul convoluțional este bloc elementar pentru *DenseNet*. Primul strat al modelului este reprezentat de un strat convoluțional cu filter  $7 \times 7$  și un stride de 2 ce reprezintă o imagine dată ca imagine de intrare. Este apoi urmat de un MaxPooling cu un stride de 2. Primele 3 Blocuri Dense ale modelului sunt urmate de un strat de convoluție ( $1 \times 1$ ) și un strat de Average Pooling ( $2 \times 2$  cu stride de 2) ce formează un Strat de Tranziție.

Acest tip de strat se conectează cu blocurile dense și diminuează dimensiunea hărții caracteristicilor.

În cele din urmă, stratul de clasificare constă dintr-un *Pooling Global* și *SoftMax* care este concepută pentru a scoate cele 2 clase: glaucom și normal. Intrarea modelului este reprezentată de imagini digitale de fund de ochi cu dimensiunile redimensionate de  $224 \times 224 \times 3$ . Imaginile sunt apoi reduse la  $112 \times 112$ ,  $56 \times 56$ ,  $28 \times 28$ ,  $14 \times 14$  realizând o dimensiune de  $7 \times 7$  pentru ultimul strat (a se vedea în Figura 5.6).

Algoritmul DenseNet201 utilizat pentru această lucrare constă din pre-antrenarea a setului de date *ImageNet*, ce conține 201 straturi și 20M parametrii. Antrenamentul modelului a folosit o tehnică de optimizare bazată pe *Stochastic Gradient Descent* cu o rată de învățare de  $1e-6$  și un impuls de 0,9.

Am antrenat modelul DenseNet201 pe 200 de epoci, pe setul de date ACRIMA, ceea ce înseamnă că numărul de imagini cu glaucom este egal cu numărul de imagini obținute de la ochi sănătoși (0 - Glaucom, 1-Normal).


Figura 5.7 ne arată evoluția pe care algoritmul a avut-o de-a lungul a 200 de epoci, atât pentru validare, cât și pentru antrenament.

În final am obținut o precizie de 0.97 și un scor F1, descris ca medie armonică pentru model, având valoarea de 0.969.

### 5.3.2 Rezultate

În Tabelul 5.2 este reprezentată matricea de confuzie care arată că 73 de imagini au fost clasificate corect, 12 imagini cu glaucom au fost clasificate greșit și 85 de imagini cu glaucom au fost clasificate corect (adevărat pozitiv =73, adevărat negativ=85, fals pozitiv= 0 , fals negativ= 0). Rezultatele obținute au avut erori, deoarece unele dintre imaginile cu ochi normali ar fi putut să nu fost de calitate bună.

Valoarea zonei de sub curbă (AUC) este de 0.97, ceea ce indică faptul că modelul implementat distinge corect clasele. Curba ROC este generată



**Figura 5. 4** Evoluția acurateții pentru antrenament și validare(roșu respectiv albastru)

**Tabelul 5. 2** Matricea de Confuzie

170 Imagini digitale de fund de ochi	Actual Normal	Actual Glaucoma
Predicted Normal	73	0
Predicted Glaucoma	12	85

prin reprezentarea grafică a TP față de FP la diferite setări de prag. Mai mult, valorile pentru sensibilitate, specificitate, rechemare și precizie sunt 0.941, 1.9, 0.01 și respectiv 0.01, arătând o performanță de clasificare eficientă.

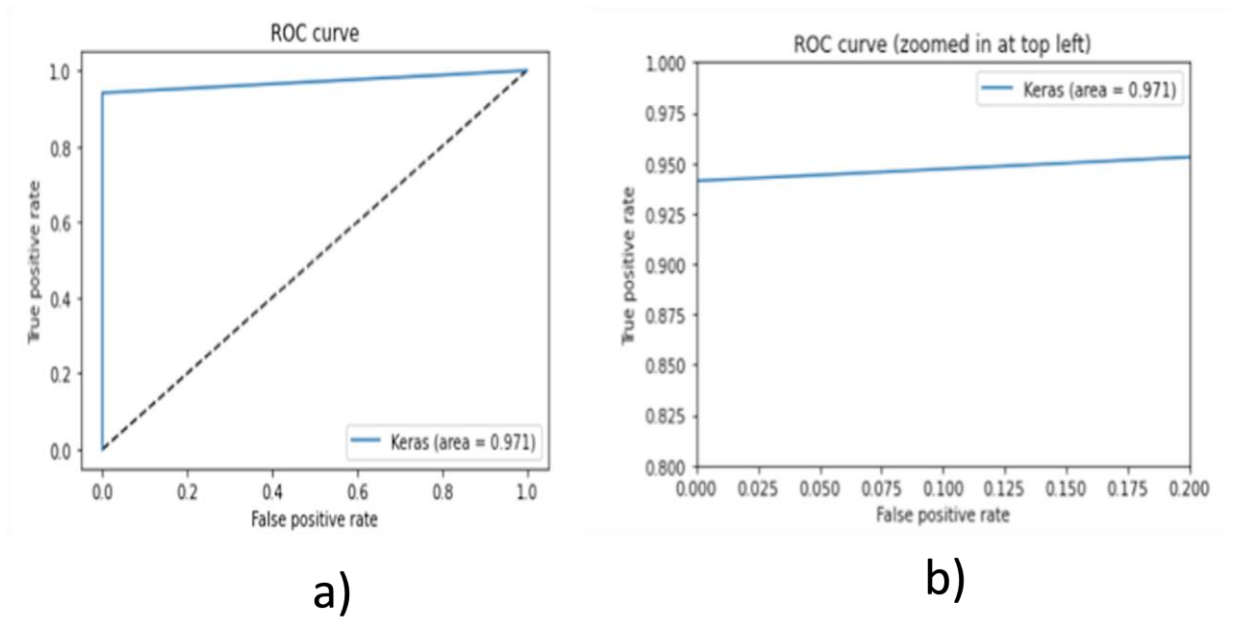


Figura 5. 5 a) Curba ROC b) Curba ROC mărită

### 5.3.3 Concluzii

În concluzie, acest articol a implementat rețele neurale dens conectate cu 121 de straturi pe un set de date de imagini color ale fundusului ocular, cuprinzând atât stadii incipiente, cât și avansate ale glaucomului. Am demonstrat că prin utilizarea unei rețele dens conectate putem diagnostica glaucomul cu o precizie de 95,6%. Acest lucru indică un potențial semnificativ al rețelelor neurale convoluționale de a deveni un instrument pentru diagnosticul automat al glaucomului.

DenseNet este mai eficient în clasificarea dintre glaucom și non-glaucom decât ResNet. Rezultatele evidențiază faptul că rețelele neurale dens conectate sunt capabile să facă o distincție precisă între glaucom și non-glaucom prin analiza imaginilor (fără necesitatea unor examene suplimentare). Ele au dovedit că sunt capabile să diagnosticheze corect imagini de glaucom incipient, care prezintă schimbări subtile dificil de observat cu ochiul uman și care necesită de obicei examene suplimentare costisitoare. În plus, rețeaua neurală dens conectată utilizată în acest studiu oferă rezultate mai bune în ceea ce privește precizia decât rețelele neurale reziduale. Precizia rețelei noastre dens conectate este de 0,956 după 50 de epoci pe setul de validare, în timp ce precizia obținută cu rețeaua reziduală pe un set de date similar era în jur de 0,9 după același număr de epoci.

Este important să subliniem faptul că DenseNet se evidențiază în distincția dintre glaucom și non-glaucom în comparație cu ResNet.

Algoritmul a fost implementat în Google Colab, folosind biblioteca de învățare profundă Keras, cu suport în spate de TensorFlow.

## 5.4 Comparația între DensNet121 si DenseNet201

DenseNet121 și DenseNet201 sunt două arhitecturi de rețele neuronale convoluționale care au fost dezvoltate pentru a aborda problema detectării glaucomului și au fost introduse ca extensii ale modelului DenseNet de bază. Aceste arhitecturi sunt cunoscute pentru performanța lor impresionantă în clasificarea imaginilor și au fost aplicate cu succes în detectarea glaucomului.

DenseNet121 este o arhitectură mai mică și mai ușoară în comparație cu DenseNet201. Are un total de 121 de straturi, inclusiv blocurile dense, straturile convoluționale și straturile de tranziție. Deoarece are mai puține straturi și parametri, DenseNet121 are o complexitate redusă și poate fi antrenată mai rapid decât DenseNet201. Cu toate acestea, aceasta nu înseamnă că DenseNet121 are o performanță inferioară. Acesta poate oferi o detectare mai bună a glaucomului în funcție de setul de date și de antrenare.

Pe de altă parte, DenseNet201 este o arhitectură mai adâncă și mai complexă, cu un total de 201 de straturi. Datorită adâncimii sale mai mari, DenseNet201 are capacitatea de a captura caracteristici și relații mai complexe din imagini. Acest lucru poate duce la o performanță îmbunătățită în detectarea glaucomului, în special în cazul seturilor de date mari sau complexe. Cu toate acestea, antrenarea DenseNet201 poate necesita mai mult timp și resurse computaționale din cauza numărului mai mare de parametri și straturi.

Ambele arhitecturi, DenseNet121 și DenseNet201, oferă avantaje și pot fi utilizate cu succes în detectarea glaucomului. Alegerea dintre cele două depinde de cerințele și nevoile specifice ale aplicației. DenseNet121 poate fi o alegere potrivită pentru seturi de date mai mici sau mai puțin complexe, în timp ce DenseNet201 poate fi preferabil în cazul seturilor de date mari și complexe, unde caracteristicile fine și relațiile subtile pot juca un rol important în detectare.

În general, ambele studii au oferit performanțe favorabile în ceea ce privește clasificarea imaginilor digitale ale fundului de ochi cu glaucom și non- glaucom, dar DenseNet cu 201 straturi a obținut rezultate mai bune.

Modelele DenseNet121 și DenseNet201 folosite în acest capitol au fost antrenate pe o bază de date mai mică, compusă doar din RETINA și ACRIMA, însumând un total de 783 de imagini de retină (441 imagini cu glaucom și 342 imagini normale).

**Tabelul 5.3** Comparație rezultate ResNet50, DenseNet121 și DenseNet201

Algoritm	Bază de date	Acuratețea	F1 score
ResNet50	HRF + ORIGA + ACRIMA + RETINA	0,9695	0.79
DenseNet121	RETINA + ACRIMA	0.9563	<b>0.97</b>
DenseNet201	RETINA + ACRIMA	<b>0.97</b>	0.69

Observăm din tabelul 5.3 că cea mai bună acuratețe este dată de modelul DenseNet201 iar cel mai bun F1 scor este obținut pentru DenseNet121.

DenseNet201 are o arhitectură mai complexă și mai profundă, cu mai mulți parametri comparativ cu DenseNet121, aceasta făcând-o mai sensibilă la a capta subtilitățile dintr-o imagine, motiv pentru care acuratețea obținută cu DenseNet201 este mai mare decât cea obținută cu DenseNet121. Doar ca bază de date pe care rețele sunt antrenate este dezechilibrată (441 -glaucom vs 342 - normal, o diferență care este simțită pentru un set de date mic).

DenseNet201, deși mai complexă, este sensibilă la dezechilibrul dintre clase, deoarece ia în considerare atât precizia cât și *recall*-ul (recuperarea). Acuratețea mare obținută de DenseNet201 poate fi dată de capacitatea modelului de a clasifica corect imaginile din clasa majoritară, în cazul acesta glaucomul. Dar valoarea scorului F1 ne arată că modelul nu se descurcă la fel de bine în a clasifica corect clasa minoritară, în cazul acesta imaginile sănătoase.

De aceea valoarea scorului F1 obținut cu DenseNet201 este mai mic decât cel obținut cu DenseNet121, iar acuratețea este mai mare.

## 5.5 Concluzii

Studiile și cercetările au demonstrat că utilizarea arhitecturii DenseNet în detectarea glaucomului poate obține performanțe remarcabile în termeni de acuratețe, sensibilitate și specificitate. Modelul DenseNet poate fi antrenat pe seturi de date mari și divers, ceea ce contribuie la generalizarea și capacitatea de a face față variațiilor în imagini.

Cu toate acestea, este important să se ia în considerare și alte aspecte în implementarea și utilizarea modelului DenseNet în practica clinică. Acestea includ selecția și pregătirea adecvată a setului de date, preprocesarea imaginilor, ajustarea hiperparametrilor modelului și validarea rezultatelor obținute.



În concluzie, utilizarea tehnicii DL și a arhitecturii DenseNet în detectarea glaucomului pe baza imaginilor digitale de fund de ochi reprezintă o abordare promițătoare și eficientă. Această metodă poate contribui la diagnosticarea precoce a glaucomului și la îmbunătățirea asistenței medicale pentru pacienții afectați de această afecțiune oculară. Cu toate acestea, este important să se continue cercetarea și dezvoltarea în acest domeniu pentru a valida și îmbunătăți performanța și utilizarea practică a modelelor DenseNet în detectarea glaucomului.

# Capitolul 6

## Concluzii

Această teză de doctorat abordează posibilitatea diagnosticării automate a glaucomului prin utilizarea algoritmilor de învățare automată. Conform Organizației Mondiale a Sănătății, glaucomul reprezintă a 2a cauză de orbire ireversibilă la nivel global, după cataractă. În plus, glaucomul este asimptomatic, fiind de cele mai multe ori diagnosticat doar atunci când pacientul și-a pierdut deja până la 70% din vedere. Mai mult decât atât, diagnosticarea glaucomului este un proces laborios, care implică utilizarea mai multor metode de analiză precum și expertiză medicală avansată. Acestea fac ca testarea pe scară largă a populației pentru diagnosticarea glaucomului să fie extrem de dificil de pus în practică. În plus, diagnosticarea glaucomului în fază incipientă, când leziunile produse de glaucom la nivel de retină sunt insesizabile, este și mai greu de realizat.

În acest context, algoritmi de învățare automată au potențialul de a juca un rol important în diagnosticarea corectă, rapidă și în fază incipientă a glaucomului.

Glaucomul produce modificări la nivelul retinei, atât la nivel structural cât și la nivel vascular. Modificările structurale ale retinei sunt vizibile cu ajutorul imaginii obținute cu OCT, iar cele vasculare cu ajutorul imaginii digitale sau cu OCTA.

În această lucrare s-au folosit doar imagini de fund de ochi, obținute cu camere optice digitale. Baza de date folosită a pus împreună mai multe baze de date existente împreună cu o bază de date proprietară, RETINA. Baza de date RETINA conține imagini de fund de ochi de la pacienți cu glaucom în stadiu incipient. Celelalte baze de date folosite sunt ACRIMA, ORIGA și HRF, însumând un total de 826 de imagini de retină, dintre care 460 imagini de la subiecți diagnosticați cu glaucom și 366 de la subiecți sănătoși.

Deoarece glaucomul afectează preponderent capul nervului optic și împrejurimile, aceasta fiind zona de interes, am folosit pentru antrenarea algoritmilor doar imaginile de fund de ochi decupate în jurul acestei zone.

Pentru diagnosticarea corectă a glaucomului, am folosit rețele neurale convoluționale cu diferite arhitecturi.

## 6.1 Rezultate obținute

În capitolul 4 am antrenat rețeaua neuronală ResNet cu 50 de nivele pentru a face clasificarea între imaginile de fund de ochi afectate de glaucom și cele sănătoase, punându-se accent pe diagnosticarea glaucomului în fază incipientă, acolo unde leziunile produse pe retină sunt insesizabile. Imaginile de glaucom din baza de date proprietară sunt de la subiecți cu glaucom în fază incipientă.

În urma antrenării rețelei ResNet50 cu 200 de epoci, folosind ca tehnică de optimizare SGD cu o rată de învățare de 0,0001 și un momentum de 0.9, s-a obținut o acuratețe de 0.9695 pentru setul de validare.

Numai pe setul de date RETINA, 5 din 8 imagini clasificate ca glaucom de debut au fost clasificate corect de către modelul nostru. În același timp, toate imaginile din același set de date provenind de la subiecți sănătoși au fost clasificate corect. F1-score obținut pentru setul de date RETINA este de 0.769.

În capitolul 5, pentru a clasifica corect între glaucom și non-glaucom, s-a antrenat rețeaua DenseNet cu 121 de straturi pe imagini de retină, decupate în jurul capului de nerv optic și zona din jurul acestuia, fiecare imagine având o dimensiune de  $224 \times 224 \times 3$ .

La fel ca și în primul model, și aici rețeaua a fost prima dată pre-antrenată pe setul de imagini ImageNet. Ulterior rețeaua a fost antrenată pe o bază de date de imagini de fund de ochi obținută prin punerea în comun a bazei de date RETINA împreună cu bazele de date publice ACRIMA și RIM-ONE. În urma antrenării rețelei pe aceste imagini, după 50 de epoci s-a obținut acuratețea de 0.9563 și o valoare a funcției de pierdere de 0.1594. Mai exact, matricea de confuzie arată că 82 de imagini au fost clasificate ca fiind de la subiecți sănătoși (dintre care 81 sunt *true positive* și 1 *false negative*) și 88 au fost clasificate ca fiind de la pacienți care suferă de glaucom (dintre care 84 sunt *true negative* și 4 *false negative*). Valoarea sensibilității este de 0.952 iar specificitatea este de 0.988. Scorul F1 obținut este de 0.97.

Doar pentru imaginile din baza de date RETINA, care conțin imagini de retină afectate de glaucom în fază incipientă, unde modificările produse la nivel de vascularizație a retinei sunt extrem de subtile, rețeaua DenseNet121 a reușit să facă o clasificare destul de bună între cele 2 clase, glaucom și non-glaucom, obținându-se o valoare AUC de 0.971. Din rezultatele obținute cu rețeaua ResNet cu 50 de straturi și cele obținute cu rețeaua DenseNet cu 121 de straturi, putem observa că rețeaua DenseNet a ajuns la o acuratețe de 0.95 mult mai repede decât ResNet, după aproximativ 50 de epoci, pe când rețeaua DenseNet a ajuns la o acuratețe similară după 200 de epoci. În plus, modelul DenseNet a avut rezultate mai bune în diagnosticarea imaginilor de glaucom în fază incipientă. În

cea ce privește scorul F1 obținut cu DenseNet, acestea este mai mare decât cel obținut cu ResNet (0.97 vs. 0.79). Aceasta înseamnă că DenseNet este mai bun la a clasifica corect imaginile de glaucom față de cele sănătoase decât ResNet.

În capitolul 6, pe aceleași set de imagini folosit și în capitolele anterioare s-a antrenat rețeaua DenseNet cu 201 straturi. Rețeaua a fost în prealabil antrenată pe baza de date ImageNet. După o antrenare de 200 de epoci, s-a ajuns la o precizie de 0.97 și un scor F1 cu valoarea de 0.969. Conform matricei de confuzie, din 85 de imagini de retină care provin de la subiecți sănătoși, 81 au fost clasificate corect de către rețeaua DenseNet121 și 4 au fost clasificate ca provenind de la subiecți cu glaucom. Similar, din cele 85 de imagini de retină care provin de la subiecți cu glaucom, 84 au fost diagnosticate corect și doar 1 a fost diagnosticată ca fiind normală.

Rezultatele arată o capacitate destul de bună de diagnosticare corectă a imaginilor de glaucom versus non-glaucom în cazul rețelei DenseNet201.

Observăm că, deși cu rețeaua DenseNet201 ar trebui să se obțină rezultate semnificativ mai bune față de DenseNet121, aceasta fiind mai adâncă, rezultatele în ceea ce privește acuratețea sunt similare. Rețeaua DenseNet201 nu a putut ajunge la o acuratețe mai mare de 0.97 chiar și după 200 de epoci de antrenare. Având în vedere că ambele rețele au fost antrenate pe un set de date extrem de mic, limitarea în ceea ce privește acuratețea provine de la setul de date de antrenare. În schimb, rețeaua DenseNet201 a obținut rezultate mai bune în clasificarea corectă a imaginilor de glaucom față de DenseNet121 și ambele modele au obținut rezultate semnificativ mai bune față de ResNet50.

Din rezultatele obținute mai sus concluzionăm că, pentru un set de date mic, o rețea foarte adâncă (ex. 201 straturi) nu obține rezultate semnificativ mai bune față de o rețea adâncă (ex. 121 straturi). Diferența ar fi vizibilă probabil doar în cazul în care s-ar lucra pe un set de date mare, cu imagini diverse, în diferite stadii ale glaucomului.

## 6.2 Contribuții originale

Printre contribuțiile originale în această lucrare amintim:

- 1) Introducerea unui set de date proprietar (numit RETINA, nume dat de numele clinicii unde s-a realizat colectarea imaginilor) care conține imagini de retină de la subiecți cu glaucom în stadiu incipient precum și imagini de retină de la subiecți sănătoși. Imagini au fost obținute cu camere OCT și nu au fost prelucrate înainte de a fi introduse în setul de date. S-a urmarit, prin aceasta, să se antreneze modelele de algoritmi pe imagini reale, imagini folosite în spital, în condiții limitate de luminozitate, calitate, etc.

- 2) S-a pus accent pe diagnosticarea glaucomului în fază incipientă. Glaucomul în fază incipientă este aproape imposibil de diagnosticat și, de asemenea, este important să fie diagnosticat în fază de debut, pentru a putea încetini avansarea acestuia prin tratament, mai ales că este o boală ireversibilă. Identificarea unei soluții care să poate diagnostica glaucomul în faza de debut în mod automat, non-invasiv și care să nu necesite o multitudine de teste și expertiză medicală, este de o importanță majoră. Deoarece glaucomul în faza de debut este extrem de diagnosticat cu metodele de diagnosticare existente în prezent și foarte puțini pacienți cu glaucom în faza de debut ajung la medic pentru a fi diagnosticați, a fost destul de dificil să putem obține o bază de date cu mai multe imagini cu glaucom în fază incipientă.
- 3) Antrenarea rețelelor ResNet și DenseNet pentru a putea diagnostica glaucomul în fază incipientă. Aceste rețele au fost antrenate și testate astfel încât să se poate verifica eficiența lor în cazul glaucomului în fază de debut.

### 6.3 Lista lucrărilor originale

Această listă cuprinde numai lucrările publicate/communicate la care doctorandul este autor sau co-autor. La acestea se adaugă și rapoartele de cercetare din programul de doctorat și contractele la care doctorandul a lucrat. Toate aceste lucrări se regăsesc și la Bibliografie. Toate lucrările menționate trebuie să aibă un conținut legat de tematica tezei de doctorat.

1. An Exploratory Study for Glaucoma Detection using Densely Connected Neural Networks – articol de conferință, ISI, prim autor
2. Early Detection of Glaucoma Using Residual Networks – articol de conferință, ISI, prim autor
3. Deep Learning & Digital Fundus Images: Glaucoma Detection using DenseNet – articol de conferință, ISI, prim autor
4. A Review of Glaucoma Detection from Digital Fundus Images using Machine Learning Techniques - articol de conferință, ISI, autor secundar

### 6.4 Perspective de dezvoltare ulterioară

Ca perspective de dezvoltare ulterioară, se urmărește diagnosticarea glaucomului prin analiza modificărilor produse de acesta inclusiv la nivelul structural al retinei. Pentru aceasta, vom introduce un set de date care conține imagini 3D obținute cu ajutorul OCT. De asemenea, pentru a putea observa mai bine modificările produse de glaucom la nivelul vascularizației retinei, se vor folosi imagini obținute cu ajutorul OCTA.

Urmărim analiza acestor imagini cu algoritmi de învățare profundă in mai multe scenarii: antrenarea algoritmilor dezvoltati pe seturi de date unimodale (doar imagini de OCT sau OCTA ) sau antrenarea pe imagini multi-modale (combinație de OCT, OCTA si imagini digitale).

În felul acesta pot fi identificate cu precizie mai bună modificările produse de glaucom, inclusiv în faza de debut. În plus, sunt analizate si modificările la nivel de structură a straturilor retinei. Se poate analiza incluziv ce modificări apar prima data, o dată cu debutul bolii (dacă prima dată sunt afectate vasele de sânge sau apar modificări la nivel de structură).

În lucrarea actuală, pornind de la ideea ca glaucomul afectează mai mult capul nervului optic si zona din jurul acestuia, imaginile folosite pentru antrenarea algoritmilor au fost decupate in jurul zonei de interes. În viitor, ne dorim sa validăm această teorie si să analizăm dacă există semne ale retinei si în afara zonei reprezentată de capul nervului optic. Pentru aceasta, vom antrena modelele de algoritmi de învățare profundă pe imagini ale retinei care conțin întreaga retină, mai puțin capul nervului optic.

De asemenea, urmărim extinderea bazei de date, inclusiv cu mai multe imagini de retina cu glaucom în fază incipientă si antrenarea unor algoritmi care să clasifice nu doar binar (glaucom versus non-glaucom), dar să poate clasifica glaucomul în mai multe stadii ale evoluției bolii.

În lucrarea prezentă s-a lucrat doar pe imagini de glaucom de la pacienți care nu aveau alte patologii în afara de glaucom. Ca dezvoltări următoare, ne dorim includerea în setul de date imagini de retină de la pacienți care au si alte patologii, cum ar fi diabet, cataractă, tensiune arterială crescută si evident, antrenarea unor algoritmi de învățare profundă care să recunoască modificările specifice glaucomului la nivelul retinei, deși retina a fost afectată si de alte patologii, cum ar fi diabetoretinopatia. Identificarea caracteristicilor glaucomului si efectelor specifice pe care acesta îl produce la nivel retinei, atunci când retina este afectată si de alte boli, este un subiect de cercetare care poate duce la dezvoltarea unor tratamente de tratare/prevenire a glaucomului.

Pe termen lung, urmărim crearea unei soluții robuste care să poată diagnostica nu doar glaucomul, dar mai multe patologii care afectează ochiul uman si care să funcționeze ca un software de screening al ochiului. Pentru început, un astfel de software ar lucra doar ca un instrument de screening, iar cazurile suspecte de glaucom sau o altă boală, vor fi trimise către o analiză mai detaliată pentru a fi diagnosticate corectă. Pe termen lung, un astfel de software poate funcționa ca un instrument de diagnostic, punând un diagnostic direct. O astfel de soluție nu doar ca are potențialul de a ajuta la diagnosticarea rapidă, corectă si automată a bolilor de ochi, dar ar putea si să permită accesul oricui la astfel

de teste, mai ales pacienți care nu au acces cu ușurință la un medic oftalmolog cu experiență sau la un centru medical.

Aceasta sunt doar câteva dintre direcțiile de cercetare viitoare în analiza imaginilor de retină folosind algoritmi de DL. Avansurile în aceste direcții pot aduce beneficii semnificative în domeniul medical și pot contribui la îmbunătățirea diagnosticului și tratamentului afecțiunilor oculare.

# Bibliografie

- [1] Y. Jeong, Y.-J. Hong și J.-H. Han, „Review of Machine Learning Applications Using Retinal Fundus Images,” *Diagnostics (Basel)*, vol. 12(1), nr. 134, 2022.
- [2] D. E. Zahoi, D. Sztika, E. Daescu și L. Stoican, ANATOMIA OMULUI, Timisoara: Editura „Victor Babeș”, 2018.
- [3] „www.optimsano.ro,” [Interactiv]. Available: <https://optimsano.ro/anatomia-fascinanta-a-ochiului-uman/>.
- [4] Z. Zhang, R. Srivastava și H. Liu, „A survey on computer aided diagnosis for ocular diseases,” în *BMC Medical Informatics and Decision Making volume*, 20.
- [5] M. D. Abràmoff , . M. K. Garvin, și M. Sonka, „Retinal imaging and image analysis,” *IEEE Reviews in Biomedical Engineering*, vol. 2, pp. 169 - 208, 10 December 2010.
- [6] „Retina,” [Interactiv]. Available: <https://en.wikipedia.org/wiki/Retină>.
- [7] „World Health Organization. Eliminating Avoidable Visual Disability Due to Refractive Errors: Report of an Informal Planning Meeting,” Geneva, 3-5 July 2000.
- [8] Y. Li, . X. Xia și . Y. M. Paulus, „Advances in Retinal Optical Imaging,” 5 Jun 2018 .
- [9] S. Muchuchuti și S. Viriri, „Retinal Disease Detection Using Deep Learning Techniques: A Comprehensive Review,” *J. Imaging*, vol. 9, nr. 4, 2023.
- [10] L. D. Hubbard , Rosemary J Brothers BS și William N King MS, „Methods for evaluation of retinal microvascular abnormalities associated with hypertension/sclerosis in the atherosclerosis risk in communities study,” *Ophthalmology*, vol. 12, nr. 106, 1999.
- [16] F. Li, H. Chen și Z. Liu, „Deep learning-based automated detection of retinal diseases using optical coherence tomography images,” *Biomed Opt Express*, vol. 10(12), p. 6204–6226., 2019 Dec 1.
- [17] N. M. Bressler, „Age-related macular degeneration is the leading cause of blindness.,” *PubMed Disclaimer*, 2004.
- [18] J. A. Wells, . A. R. Glassman și A. R. Ayala, „Aflibercept, Bevacizumab, or Ranibizumab for Diabetic Macular Edema: Two-Year Results from a Comparative Effectiveness Randomized Clinical Trial,” *Ophthalmology* , 2016.
- [19] . M. Bashour și D. W. Suh, „Retinopathy of Prematurity Ophthalmologic Approach,” *Ophthalmology* , 2023.
- [20] „Eye examination in infants, children, and young adults by pediatricians: organizational principles to guide and define the child health care system and/or improve the health of all children,” *American Academy of Ophthalmology*, 2003.



- [21] Khan M.U, Aslam N și Qaiser I, „Deep learning-based automatic diagnosis of refractive errors using retinal images,” *Biomed. Signal Process. Control*, 2020.
- [22] Zhang Y, Liu X, Gao X și Zhang L, „Deep learning-based refractive error prediction from optical coherence tomography images,” *J. Biomed. Opt.*, 2021.
- [23] Schmitz-Valckenberg S., Pfau M., Fleckenstein M, Staurenghi G și Sparrow J, „Fundus autofluorescence imaging,” *Prog. Retin. Eye Res.*, 2021.
- [24] Roorda A, Romero-Borja F și Donnelly W.J., „Adaptive optics scanning laser ophthalmoscopy,” *Adaptive optics scanning laser ophthalmoscopy. Opt. Express.*, 2002.
- [25] Takayama K, Ooto S, Hangai M și Arakawa N, „High-resolution imaging of the retinal nerve fiber layer in normal eyes using adaptive optics scanning laser ophthalmoscopy,” *PLoS ONE*, 2012.
- [26] Jiang Z., Feng S., Huang Z., Peng Y. și Guo J, „A super-resolution method-based pipeline for fundus fluorescein angiography imaging,” *Biomed. Eng. Online*, 2018.
- [27] Lin P.H și Saines M., „Assessment of lower extremity ischemia using smartphone thermographic imaging,” *J. Vasc. Surg. Cases Innov. Tech*, 2017.
- [28] „World Health Organization,” [Interactiv]. Available: <https://www.who.int>.
- [29] „Glaucom vs Normal,” [Interactiv]. Available: <https://mediqlens.ro/en/glaucomul/>.
- [30] Y. X. Wang, L. Xu și W. B. Wei, „Intraocular pressure and its normal range adjusted for ocular and systemic parameters,” *PLOS ONE*, 2011.
- [31] „Eye anatomy,” [Interactiv]. Available: <https://glaucoma.org/eye-anatomy/>.
- [32] „OCT,” [Interactiv]. Available: <https://www.reviewofoptometry.com/article/12-ways-to-get-more-out-of-your-oct>.
- [33] G. Wollstein și J. Schuman, „OCT for glaucoma diagnosis, screening and detection of glaucoma progression,” *Br J Ophthalmol*, 2014.
- [34] N. K. Waheed, T. E de Carlo și A. Romano, „A review of optical coherence tomography angiography (OCTA),” *International Journal of Retina and Vitreous*, vol. 1, 2015.
- [35] „TOMOGRAFIA ÎN COERENȚĂ OPTICĂ - OCT,” [Interactiv]. Available: <https://ochidoc.ro/tomografia-in-coerenta-optica-oct/>.
- [36] M. Byrne , *AI in Clinical Medicine – A Practical Guide for Healthcare Professionals*, 2023.
- [37] I. Sarker, „Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions,” *SN Computer Science* , vol. 2, 2021.
- [38] M. Sewak, R. Karim și P. Pujari, *Practical Convolutional Neural Networks*, 2018.
- [39] S. Balaji, „Binary Image classifier CNN using TensorFlow,” 29 August 2020. [Interactiv]. Available: <https://medium.com/techiepedia/binary-image-classifier-cnn-using-tensorflow-a3f5d6746697>.

- [40] M. F. Byrne, N. Parsa, A. T. Greenhill , D. Chahal, O. Ahmad și U. Bagci, AI in Clinical Medicine – A Practical Guide for Healthcare Professionals, Wiley-Blackwell, 2023.