

**UNIVERSITATEA DE MEDICINĂ ȘI FARMACIE
„CAROL DAVILA”, BUCUREȘTI**

ȘCOALA DOCTORALĂ
DOMENIUL MEDICINĂ



*Utilizarea inteligenței artificiale în corelațiilor morfologice ale
patologiei tumorale de la nivelul capului și gâtului*

REZUMATUL TEZEI DE DOCTORAT

Conducător de doctorat:

PROF. UNIV. DR. COSTACHE ADRIAN

Student doctorand:

TACIUC IULIAN-ALEXANDRU

ANUL 2026

Cuprins

Lista lucrărilor științifice publicate.....	6
Abrevieri și simboluri.....	8
Introducere	9
I. Partea generală.....	11
1. Tumorile maligne ale capului și gâtului, de la diagnostic la rezultatul anatomopatologic	11
1.1. Epidemiologie.....	11
1.2. Factori de risc.....	11
1.3. Clasificarea și delimitarea cancerelor din sfera capului și gâtului.....	12
1.4. Implicațiile ganglionilor.....	13
2. Rolul emergent al inteligenței artificiale în patologia din sfera ORL	17
2.1. Inteligența artificială.....	17
2.2. Rețele neuronale artificiale.....	18
2.2.1. Tipuri de rețele neuronale artificiale.....	18
2.2.2. Rețele neuronale convoluționale.....	19
2.2.3. Inteligența artificială generativă.....	19
2.3. Etichetarea datelor	21
2.4. Parametrii de antrenare.....	22
2.5. Instrumente de validare a performanței.....	22
2.6. Crearea unui program de inteligență artificială.....	23
2.7. Rolul inteligenței artificiale în parcursul pacientului cu cancer de cap și gât.....	25
2.7.1. Inteligența artificială în sistemul sanitar.....	25
2.7.2. Inteligența artificială în patologia ORL.....	25
2.7.3. Inteligența artificială în patologia oncologică de la nivelul capului și gâtului.....	26
2.8. Inteligența artificială în identificarea adenopatiilor infiltrate malign.....	28
2.9. Limitări generale ale programelor de inteligență artificială în domeniul sanitar.....	29
2.9.1. Limitări legate de date.....	29
2.9.2. Limitări tehnice.....	29
2.9.3. Limitări ce țin de implementarea clinică.....	30
2.9.4. Limitări dependente de operator.....	30

2.10. Limitări specifice ale inteligenței artificiale în detecția adenopatiilor infiltrate malign la imagistica medicală.....	30
II. Partea originală (contribuții personale).....	32
3. Ipoteza de lucru și obiectivele generale.....	32
4. Metodologia generală a cercetării.....	36
5. Performanța diagnostică în adenopatiile laterocervicale folosind caracteristicile morfologice la IRM și coeficientul de difuzie aparent.....	38
5.1. Introducere.....	38
5.2. Materiale și metode.....	39
5.2.1. Lotul de studiu.....	39
5.2.2. Protocolul IRM de achiziție a imaginilor.....	43
5.2.3. Analiza imaginilor.....	43
5.2.4. Colectarea datelor și programul de analiză statistică.....	44
5.2.5. Metode de analiză statistică aplicate.....	45
5.3. Rezultate.....	47
5.3.1. Analiza parametrilor morfo-imagistici.....	47
5.3.2. Importanța coeficientului de difuzie aparent.....	50
5.4. Discuții	54
6. Identificarea automată a adenopatiilor infiltrate malign folosind inteligența artificială: dezvoltarea unei rețele neuronale convoluționale și analiza comparativă a indicilor de performanță	61
6.1. Introducere	61
6.2. Materiale și metode.....	62
6.2.1. Baza de date.....	62
6.2.2. Preprocesarea și etichetarea imaginilor.....	63
6.2.3. Augmentarea datelor și constituirea bazei de date finale.....	64
6.2.4. Arhitectura rețelei neuronale.....	67
6.2.5. Procesul de antrenare.....	68
6.3. Rezultate.....	68
6.4. Discuții	71
7. Segmentarea automată a adenopatiilor cervicale cu suspiciune de malignitate pe imagini CT utilizând un model U-Net++.....	77
7.1. Introducere.....	77

7.2. Materiale și metode.....	78
7.2.1. Setul de date.....	78
7.2.2. Preprocesarea și etichetarea imaginilor.....	81
7.2.3. Augmentarea datelor	81
7.2.4. Implementarea arhitecturii U-Net++ în model.....	82
7.2.5. Protocolul de antrenare.....	83
7.3. Rezultate.....	84
7.3.1. Rezultate generale.....	84
7.3.2. Verificarea performanței pe setul de test.....	86
7.4. Discuții.....	90
8. Inteligența artificială generativă – evaluarea impactului asupra antrenării unei rețele neuronale convoluționale folosind imagini histopatologice.....	94
8.1. Introducere.....	94
8.2. Materiale și metode.....	96
8.2.1. Setul de date.....	96
8.2.2. Etichetarea imaginilor și preprocesarea datelor.....	97
8.2.3. Implementarea arhitecturilor.....	98
8.2.4. Programul de generare a imaginilor histopatologice sintetice.....	98
8.2.5. Rețeaua convoluțională utilizată pentru efectuarea testelor comparative.....	99
8.2.6. Indici de performanță utilizați și metoda de lucru.....	99
8.3. Rezultate.....	100
8.3.1. Rezultatele programului de inteligență artificială generativă.....	100
8.3.2. Rezultatele comparative ale rețelei convoluționale.....	101
8.4. Discuții	103
9. Integrarea rezultatelor și discuții transversale.....	108
10. Concluzii și contribuții personale.....	111
10.1. Concluzii.....	111
10.2. Contribuții personale.....	115
Bibliografie.....	117
Anexe	132

INTRODUCERE

Din punct de vedere medical, importanța temei abordate este susținută de incidența și impactul semnificativ al cancerelor din sfera capului și gâtului la nivel global. În anul 2022, au fost estimate aproximativ 1.750.871 cazuri noi și 527.226 decese asociate acestor neoplazii [1]. Majoritatea acestor tumori prezintă un tipar comun de diseminare limfatică regională, cu implicarea frecventă a ganglionilor limfatici cervicali. Astfel, statusul ganglionar reprezintă un element esențial în stadializarea TNM, influențând semnificativ prognosticul și deciziile terapeutice, ganglionii limfatici constituind o veritabilă interfață morfologică între tumora primară și diseminarea pe cale limfatică.

În paralel, la nivel internațional se remarcă un interes crescut pentru dezvoltarea și implementarea metodelor de inteligență artificială (IA) în medicină, în special în domeniul imagisticii medicale, cu aplicații în diagnostic, evaluarea prognosticului și ghidarea deciziilor terapeutice. Analiza bazelor de date științifice evidențiază o creștere exponențială a numărului de publicații care includ termenul „artificial intelligence”, cu un maxim de peste 126.000 de lucrări în anul 2025. La nivel național, integrarea acestor tehnologii în practica clinică este încă limitată, fiind restrânsă la câteva centre și aplicații punctuale. Această discrepanță subliniază necesitatea dezvoltării unor modele adaptate contextului local, cu aplicabilitate directă în practica medicală curentă.

Prezenta teză utilizează o abordare multimodală și multidisciplinară asupra patologiei tumorale din sfera capului și gâtului, având ca element central analiza corelațiilor morfo-imagistice și histopatologice. Adenopatiile cervicale suspecte sau infiltrate malign au fost utilizate ca model imagistic principal, datorită relevanței lor și a posibilității de evaluare prin metode imagistice convenționale (tomografie computerizată, imagistică prin rezonanță magnetică, respectiv ultrasonografie). Componenta histopatologică a tezei a avut în plan principal carcinomul scuamos oral, fiind utilizat ca model experimental controlabil pentru evaluarea impactului inteligenței artificiale generative, având în vedere omogenitatea relativ mai mare a acestui tip tumoral, comparativ cu metastazele ganglionare.

Un element de noutate al tezei îl constituie explorarea utilizării modelelor de inteligență artificială generativă în analiza imaginilor histopatologice, deschizând noi perspective în augmentarea datelor și îmbunătățirea performanței modelelor predictive.

Cercetările efectuate au avut un caracter interdisciplinar, implicând colaborarea între specialități precum, medicină nucleară, radiologie, anatomie patologică și otorinolaringologie (ORL), reflectând complexitatea domeniului abordat.

I. PARTEA GENERALĂ

1. Tumorile maligne ale capului și gâtului, de la diagnostic la rezultatul anatomopatologic

Tumorile maligne de la nivelul capului și gâtului ocupă locul șase ca frecvență la nivelul globului. În 2022 povara patologiei oncologice din sfera capului și gâtului rămâne predominantă în rândul bărbaților și al populației vârstnice [3].

Cunoașterea factorilor de risc (precum consumul de alcool, fumatul, infecția cu HPV) joacă un rol important în corelarea modificărilor morfologice și imagistice cu mecanismele biologice subiacente. Integrarea acestor informații permite o clasificare mai bună a leziunilor, contribuind la dezvoltarea unor modele predictive mai precise [4].

Adenopatiile pot avea etiologii variate, cel mai frecvent inflamatorii sau infecțioase, situații în care examenul clinic și investigațiile biologice sunt, de regulă, suficiente pentru stabilirea diagnosticului. Importanța acestora crește semnificativ în context oncologic, unde evaluarea imagistică este esențială pentru caracterizarea adenopatiilor suspecte de infiltrare malignă, utilizând criterii morfologice și parametri cantitativi specifici [5].

Caracteristicile imagistice sugestive pentru malignitate la nivelul ganglionilor limfatici sunt, în general, similare între diferitele modalități de investigație.

Ultrasonografia oferă o rezoluție spațială bună pentru ganglionii superficiali, însă evaluarea structurilor profunde este limitată. În plus, tehnica este dependentă de operator. Tomografia computerizată permite o evaluare rapidă și extinsă în funcție de necesități, dar implică expunere la radiații ionizante. În acest context, dezvoltarea unor metode automatizate de analiză imagistică, bazate pe inteligență artificială, poate contribui la o evaluare mai precisă și reproductibilă a adenopatiilor suspecte. Investigația IRM oferă un contrast tisular superior, însă este mai costisitoare, mai puțin accesibilă și susceptibilă la artefactele de mișcare [6].

Studii recente au propus utilizarea unui sistem standardizat de evaluare, Node-RADS 1.0 aplicabil metodelor imagistice de CT și IRM pentru a depăși limitările și capcanele asociate utilizării criteriilor RECIST 1.1 în evaluarea ganglionilor și adenopatiilor [7].

În plus, toate cele trei metode sunt caracterizate de variabilitate inter-observator, sensibilitate limitată în anumite contexte (spre exemplu artefact metalice) și suprapunere între caracteristicile adenopatiilor benigne și maligne, aspecte care pot influența acuratețea diagnosticului. Aceste limitări justifică necesitatea dezvoltării unor metode avansate de analiză, inclusiv prin programe de inteligență artificială, pentru a crește acuratețea și reproductibilitatea evaluării adenopatiilor.

2. Rolul emergent al inteligenței artificiale în patologia din sfera ORL

Interesul acordat IA a cunoscut o creștere semnificativă în ultimii ani (în special pentru aplicarea tehnicilor de IA în domeniul medical), reflectat printr-o creștere exponențială a numărului de publicații.

Învățarea profundă („deep learning”) reprezintă o supraspecializare a învățării automate. Aceasta folosește rețele neuronale artificiale, dispuse în mai multe straturi, capabile să formeze relații complexe și să extragă automat caracteristici relevante din datele oferite, fiind deosebit de eficientă în imagistica medicală [8].

Rețelele neuronale permit dezvoltarea unor modele flexibile și adaptive, capabile să își ajusteze parametrii interni în urma procesului de antrenare, în scopul optimizării performanței. Cunoașterea tipurilor de rețele neuronale are o importanță deosebită în crearea aplicațiilor de uz clinic. Rețelele neuronale artificiale pot fi clasificate în mai multe familii în funcție de arhitectura lor, de modul de procesare a informațiilor și tipul datelor vizate [9].

Rețelele neuronale convoluționale reprezintă una dintre cele mai importante arhitecturi din domeniul învățării profunde. În mod normal, rețelele neuronale sunt o matrice bidimensională. CNN-urile pe de altă parte sunt concepute pentru a procesa date cu structură spațială, precum imagini sau volume tridimensionale [10]. O arhitectură cunoscută este EfficientNet, care obține performanțe ridicate cu un număr redus de parametri datorită scalării echilibrate a adâncimii și lățimii rețelei [11].

Evaluarea performanței modelelor de învățare profundă se realizează cu ajutorul unor metrici specifice, în funcție de natura sarcinii (clasificare sau segmentare) dar și de caracteristicile datelor. Printre cele mai utilizate se numără acuratețea, precizia, sensibilitatea și specificitatea. În cazul segmentării imaginilor (spre exemplu conturarea corectă a unei adenopatii), indicatorii de performanță preferați sunt Coeficientul de Similaritate Dice (DSC) și indicele Jaccard (IoU) [12].

Numeroase studii din literatura de specialitate au urmărit dezvoltarea, îmbunătățirea și validarea unor modele de învățare profundă, pentru o clasificare și o segmentare cât mai precisă a adenopatiilor, în special cele infiltrate malign [13].

Necesitatea integrării IA în practica medicală este susținută și de limitările involuntare ale evaluării umane. Un exemplu relevant este studiul „The Invisible Gorilla”, care a demonstrat că un procent semnificativ de medici radiologi nu au identificat o anomalie (o gorilă mică de dimensiunea unui nodul pulmonar) într-un set de imagini de CT, în fereastră pulmonară. [14] Acest fenomen nu reflectă neglijență, ci limitări ale atenției umane în condiții

de volum mare de muncă și presiune temporală, subliniind rolul potențial al IA ca instrument de suport.

II. PARTEA ORIGINALĂ

3. Ipoteza de lucru și obiective

Ipoteza principală a tezei este că IA poate îmbunătăți semnificativ identificarea și corelarea caracteristicilor morfo-patologice în patologia oncologică de cap și gât prin integrarea datelor multimodale imagistice și histopatologice. De asemenea, se presupune că performanța modelelor de învățare profundă este dependentă de tipul și volumul datelor folosite pentru antrenare, iar utilizarea tehnicilor de inteligență artificială generativă pentru Augmentarea seturilor de date poate conduce la îmbunătățirea acurateții și preciziei modelelor în cazul patologiilor rare. O comparare directă între antrenarea pe seturi de date limitate și antrenarea pe date limitate și Augmentate cu IA generativă va aduce informații prețioase pentru direcțiile de perspectivă. În acest context, se urmărește identificarea strategiei optime de antrenare care să obțină cea mai bună performanță în condițiile unor seturi de date limitate.

Obiectivele tezei au fost structurate progresiv, urmărind un raționament logic de la fundamente teoretice către aplicațiile practice:

- 1) Identificarea obstacolelor și limitărilor care pot apărea într-un program IA în stadiul de demonstrare conceptuală.
- 2) Aprofundarea corelațiilor morfo-imagistice convenționale (CT, IRM ultrasonografie) în patologia ganglionilor limfatici.
- 3) Analiza etapelor necesare dezvoltării unui program de IA, cu identificarea principalelor obstacole și limitări.
- 4) Aprofundarea cunoștințelor despre tipurile de rețele neuronale și al principiilor de funcționare, avantajelor și dezavantajelor.
- 5) Evaluarea rolului ADC în imagistica IRM, atât ca parametru individual cât și integrat în context multiparametrici, prin corelarea cu rezultate histopatologice și aplicarea testelor statistice.
- 6) Dezvoltarea și antrenarea unui CNN în identificarea ganglionilor infiltrați malign pe imagini de ultrasonografie la nivelul regiunii cervicale, utilizând etichetarea bidimensională.
- 7) Optimizarea unei rețele preantrenate pe imagini de CT, pentru antrenarea sa în detectarea ganglionilor borderline sau cu suspiciune malignă, utilizând etichetare tridimensională.

8) Antrenarea unui model bazat pe imagini histopatologice, comparând rezultatele obținute folosind date reale și cele obținute printr-un program de IA generativă cu performanța unui model antrenat exclusiv pe date reale.

Elementul de noutate al prezentei teze constă în abordarea integrată, multimodală, a corelațiilor morfo-imagistice și histopatologice, precum și în evaluarea comparativă a impactului tehnicilor de învățare profundă, respectiv al IA generative asupra performanței modelelor dezvoltate în condiții de date limitate.

4. Metodologia generală a cercetării

Studiile incluse în partea originală a prezentei teze utilizează seturi de date distincte și abordări metodologice diferite, adaptate fiecărui obiectiv specific. Cu toate acestea, majoritatea cercetărilor implică dezvoltarea, antrenarea și evaluarea unor modele de IA aplicate pe date imagistice și histopatologice, ceea ce permite definirea unor puncte comune din cadrul metodologic.

Deși studiul bazat pe IRM este proiectat pentru o analiză statistică și nu implică utilizarea directă a IA, acesta contribuie la fundamentarea relațiilor dintre parametrii imagistici și caracteristicile histopatologice, reprezentând o etapă importantă în validarea corelațiilor investigate ulterior prin metode de învățare profundă.

5. Studiul 1 - Performanța diagnostică în adenopatiile laterocervicale folosind caracteristicile morfologice pe IRM și coeficientul de difuzie aparent

5.1. Introducere

Ipoteza de lucru pornește de la presupunerea că integrarea parametrilor de difuzie, în special ADC, cu caracteristicile morfologice ale adenopatiilor laterocervicale poate îmbunătăți acuratețea diagnostică, în special în cazurile borderline sau în situațiile în care criteriile morfologice sunt neconcludente.

Astfel, obiectivele specifice ale studiului sunt:

- Evaluarea importanței diagnostice a ADC în diferențierea adenopatiilor laterocervicale infiltrate malign față de cele benigne, utilizând confirmarea histopatologică drept standard de referință;
- Analiza contribuției parametrilor morfologici în caracterizarea adenopatiilor;
- Evaluarea performanței combinând caracteristicile morfologice și ADC;

- Investigarea importanței ADC în cazurile în care criteriile morfologice sunt insuficiente pentru stabilirea diagnosticului.

5.2 Materiale și metode

S-a realizat un studiu retrospectiv, ce a inclus 88 de ganglioni limfatici cervicali proveniți de la 39 de pacienți care au efectuat examinări IRM ale regiunii capului și gâtului în perioada septembrie 2023 – decembrie 2025. Lotul a inclus entități maligne precum metastaze de carcinom scuamos, carcinom tiroidian, limfom non-Hodgkin, carcinom adenoid chistic și carcinom medular tiroidian, precum și adenopatii benigne/reactive, inflamatorii, asociate infecției CMV, tuberculoase, asociate tumorii Warthin și limfangiomului chistic. Examinările IRM au fost efectuate pentru indicații heterogene, incluzând evaluarea inițială a adenopatiilor cervicale palpabile, stadializarea oncologică, urmărirea post-biopsie, suspiciunea de recidivă și caracterizarea leziunilor benigne/inflamatorii; prin urmare, nu toți pacienții au efectuat IRM pentru aceeași indicație clinică. Majoritatea examinărilor au fost realizate în cadrul bilanțului diagnostic inițial, în timp ce șase cazuri au reprezentat evaluări de urmărire post-biopsie. Caracteristicile morfologice și valorile ADC au fost analizate utilizând testele Mann–Whitney U, Chi-pătrat, analiza ROC, testul DeLong, regresia logistică penalizată Firth, ecuații de estimare generalizată (GEE), reșantionare bootstrap la nivel de pacient și analiza calibrării. Analizele statistice au fost efectuate în Python, cu verificare exploratorie în JASP. Pragul de semnificație statistică a fost stabilit la $p < 0,05$.

5.3 Rezultate

Lotul a inclus 39 de pacienți, cu vârsta medie de 54 de ani (interval: 18–74 ani), dintre care 20 de bărbați și 19 femei. Dintre cei 88 de ganglioni limfatici, 33 au fost maligni și 55 benigni. Ganglionii maligni au prezentat valori ADC semnificativ mai scăzute comparativ cu cei benigni ($0,87 \pm 0,23$ vs. $1,25 \pm 0,22 \times 10^{-3} \text{ mm}^2/\text{s}$; $U = 207$, $p < 0,001$). ADC analizat izolat a demonstrat o performanță diagnostică bună, cu o valoare AUC de 0,886 (IC 95%: 0,803–0,960). Pragul optim ADC a fost de $0,900 \times 10^{-3} \text{ mm}^2/\text{s}$, determinând o sensibilitate de 75,8% și o specificitate de 89,1%. Modelul GEE final, care a inclus ADC, forma ganglionului și caracteristicile marginilor, ținând cont de dependența intra-pacient, a obținut o valoare AUC aparentă de 0,956. Validarea încrucișată de tip leave-one-patient-out a determinat o valoare AUC de 0,929, iar AUC corectată pentru optimism prin bootstrap a fost de 0,949. Testul DeLong a confirmat că modelul combinat a avut o performanță semnificativ superioară față de

ADC analizat izolat (creștere AUC = 0,070; $p = 0,006$). Reproducibilitatea inter- și intra-observator pentru ADC a fost excelentă.

5.4 Discuții

Prezentul studiu demonstrează integrarea caracteristicilor morfologice IRM cu valorile ADC obținute pe imaginile de difuzie conduce la o performanță diagnostică superioară în diferențierea adenopatiilor cervicale maligne de cele benigne. Deși atât caracteristicile morfologice, cât și valorile ADC au prezentat asocieri semnificative statistic în raport cu malignitatea în mod independent, combinarea acestora a determinat o creștere substanțială a capacității de diferențiere, atingând o valoare AUC de 0.956. Astfel, se demonstrează că abordarea multiparametrică structurată oferă un diagnostic mai precis în evaluarea ganglionilor limfatici cervicali.

Integrarea caracteristicilor cu valorile ADC poate crește încrederea diagnostică și poate optimiza selecția cazurilor pentru biopsie. Această abordare este în concordanță cu tendințele actuale din imagistica medicală, ce favorizează analiza multiparametrică. [15, 16]

În contexte inflamatorii nespecifice, adenopatiile reactive tind să păstreze valori ADC apropiate de normal. Un studiu longitudinal asupra adenopatiilor axilare post-vaccinare a arătat regresia dimensiunilor și a semnalului T2, în timp ce valorile ADC au rămas stabile [17]. Acest aspect sugerează că adenopatiile reactive nu determină, în mod obișnuit, restricție de difuzie semnificativă.

În concluzie, Valorile ADC, forma ganglionului și caracteristicile marginilor oferă informații diagnostice complementare pentru diferențierea ganglionilor limfatici cervicali benigni de cei maligni. O abordare IRM multiparametrică structurată a demonstrat performanță diagnostică ridicată, deși rezultatele trebuie interpretate în contextul designului retrospectiv, unicentric și al heterogenității histopatologice a lotului.

6. Studiul 2 – Identificarea automată a adenopatiilor infiltrate malign folosind inteligența artificială: dezvoltarea unei rețele neuronale convoluționale și analiza comparativă a indicilor de performanță

6.1 Introducere

Ipoteza acestui studiu este reprezentată de dezvoltarea unei CNN de la zero, folosind pentru antrenare imagini de US, cu scopul de a permite identificarea automată a adenopatiilor infiltrate malign, cu performanțe comparabile celor raportate în literatură. Se presupune de asemenea că în contextul seturilor de date de dimensiuni reduse, acuratețea poate supraestima

capacitatea reală de generalizare. În acest sens, studiul urmărește evaluarea unui set minim de metrice relevante pentru evaluarea capacității de segmentare a modelelor de AI aplicate în imagistica medicală, în vederea creșterii robusteții și credibilității acestora pentru scenariile clinice.

Obiectivele studiului sunt următoarele:

- Dezvoltarea unei CNN de la zero, incluzând proiectarea arhitecturii (numărul de straturi, tipul acestora și interconectivitate), cu scopul de a identifica automat adenopatiile laterocervicale infiltrate malign pe imaginile ecografice.

- Evaluarea și compararea indicilor de performanță, cu accent pe acuratețea convențională, coeficientul de similaritate Dice și intersecția uniunilor, în vederea evidențierii limitărilor fiecăruia și a utilității lor complementare.

- Analiza impactului volumului de date și a utilizării tehnicilor de Augmentare (rotire, ogindire) asupra capacității de generalizare a rețelei.

Indicii tradiționali de evaluare, precum acuratețea, pot să nu ofere întotdeauna o apreciere realistă a performanței de segmentare. Acest studiu abordează această limitare prin DSC și IoU.

6.2 Materiale și metode

A fost utilizat un set de date format din 992 de imagini cu ganglioni limfatici maligni, extrase din 166 de examinări ecografice cervicale și etichetate cu ajutorul instrumentului ImgLab. Rețeaua neuronală convoluțională a fost dezvoltată utilizând Python, Keras și TensorFlow, în mediul Jupyter Notebook. Arhitectura rețelei a inclus patru straturi neuronale, antrenate pentru identificarea ganglionilor limfatici maligni.

6.3 Rezultate

Rețeaua CNN a obținut o acuratețe de 97% pe setul de antrenare și de 99% pe setul de validare. Scorul DSC a fost de 0,984, indicând o performanță ridicată, însă această evaluare a fost limitată la capacitatea de detectare a ganglionilor maligni în cazurile pozitive. Evaluarea prin IoU, aplicată imaginilor din setul de testare, a evidențiat o suprapunere medie de 71% între etichetele de referință și predicțiile modelului, iar DSC o suprapunere medie de 76%. Acești indici oferă o apreciere net superioară a acurateții de segmentare.

6.4 Discuții

Tehnicile de „sliding window” și Augmentare a datelor folosite s-au dovedit adecvate în contextul unui set de date limitat, permițând detecția adenopatiilor fără a fi necesară o segmentare prealabilă a întregii imagini. Prin parcurgerea sistematică a imaginilor folosind

ferestre de dimensiuni progresiv mai mari, modelul a putut evalua local regiuni de interes. Limitarea oferită strict de această metodă constă în încadrările ROI-urilor de formă pătrată, ceea ce evident conduce la o aproximare imperfectă a conturului real al adenopatiilor.

Un aspect interesant observat în cadrul antrenărilor experimentale, a fost reprezentat de îmbunătățirea performanței modelului odată cu reducerea numărului de straturi ale rețelei neuronale. Acest fenomen poate fi explicat prin riscul crescut de supraadaptare („overfitting”) în cazul arhitecturilor mai complexe, în special atunci când sunt utilizate seturi de date limitate.

Rezultatele obținute în studiul actual se încadrează în intervalele raportate în literatura recentă, deși trebuie interpretate în contextul particular al metodei utilizate. Un studiu recent care a utilizat tehnicile de „învățare profundă” pentru evaluarea metastazelor ganglionare din cancerul tiroidian pe imagini de US, a raportat o acuratețe de 72% și un scor DSC de 0.83 [18]. Studiile bazate pe seturi de date mai mari au raportat rezultate variabile. De exemplu, un sistem de IA pentru clasificarea adenopatiilor cervicale, antrenat pe o bază de date ce depășește 2000 de imagini, a obținut valori ale acurateților între 69.85% și 78.53% și valori DSC între 98.46% și 77.19% [19].

În concluzie, valoarea DSC obținută de 0.98 a confirmat capacitatea modelului de a identifica imaginile cu adenopatii maligne. Pentru evaluarea gradului de suprapunere între etichetele de referință și predicțiile modelului, valorile medii au fost apropiate între IoU și DSC. Valori mai mici au fost înregistrate de IoU, acestea variind între 47% și 84%, sugerând că deși modelul are o capacitate bună de detecție, optimizări suplimentare sunt necesare pentru a ajusta precizia localizării și a segmentării. Din perspectivă clinică, modelul poate fi considerat un instrument util în identificarea adenopatiilor suspecte, în special pentru medicii tineri, cu experiență limitată în US cervicală.

7. Studiul 3 – Segmentarea automată a adenopatiilor cervicale cu suspiciune de malignitate pe imagini CT utilizând un model U-Net++

7.1 Introducere

Ipoteza prezentului studiu este reprezentată de adaptarea și optimizarea unei rețele neuronale preexistente (respectiv U-Net++) pentru segmentarea automată a adenopatiilor care prezintă modificări sugestive sau echivoce pe imagistica CT, contribuind astfel la evidențierea rapidă a leziunilor relevante. Se presupune de asemenea, că includerea imaginilor atât postcontrast cât și native în procesul de antrenare poate crește aplicabilitatea modelului în scenariile clinice din practica medicală curentă, inclusiv la pacienții la care administrarea substanței de contrast este contraindicată.

Obiectivele studiului sunt după cum urmează:

- Adaptarea și optimizarea unui model care să folosească o rețea U-Net++ pentru segmentarea adenopatiilor maligne și borderline pe imagini CT.
- Ajustarea parametrilor de antrenare și limitarea tehnicilor de Augmentare pentru dezvoltarea și validarea modelelor.
- Evaluarea robusteții modelului prin testarea performanței în raport cu structuri anatomice care pot mima adenopatiile pe imaginile de CT, respectiv în raport cu ganglioni localizați în alte regiuni anatomice.

7.2 Materiale și metode

A fost analizat retrospectiv un set de date alcătuit din 79 de examinări CT, efectuate în perioada ianuarie 2024 – decembrie 2025, incluzând 538 de ganglioni limfatici adnotați, clasificați Node-RADS 3–5. A fost implementată o rețea neuronală convoluțională 2D de tip U-Net++, antrenată secțiune cu secțiune, utilizând date în format NIfTI. Setul de date a fost împărțit în subseturi de antrenare și validare, iar augmentarea datelor a fost realizată prin rotații minime (+/- 10 grade) aleatorii ale imaginilor axiale, fără a modifica dimensiunea setului de date. Performanța modelului a fost evaluată utilizând coeficientul Dice (DSC), indicele Intersection over Union (IoU), sensibilitatea, specificitatea, precizia și acuratețea. Un set independent de 12 cazuri CT a fost utilizat pentru evaluarea calitativă.

7.3 Rezultate

Modelul a obținut o acuratețe de 99,8% pe setul de antrenare și de 99,7% pe setul de validare, specificitatea atingând constant 99,9%. Sensibilitatea a fost de 78% pe setul de antrenare și de 72% pe setul de validare, iar precizia a fost de 83%, respectiv 79%. Performanța de segmentare a fost caracterizată printr-un DSC de 0,79 pe setul de antrenare și 0,73 pe setul de validare, cu valori IoU de 0,67, respectiv 0,61. Modelul a demonstrat capacitatea de a exclude structuri anatomice mimetice, precum splina accesorie, glandele salivare, structurile vasculare și țesutul muscular. Evaluarea calitativă a evidențiat un număr limitat de rezultate fals negative, reprezentate de trei ganglioni echivoci, precum și două detecții fals pozitive corespunzătoare unor ganglioni benigni, clasificați Node-RADS 1.

7.4 Discuții

În ciuda utilizării unei arhitecturi bidimensionale, bazate pe procesarea secțiunilor axiale independente, modelul a demonstrat o capacitate bună de diferențiere a ganglionilor limfatici față de structuri anatomice cu aspect similar.

Sensibilitatea moderată obținută de model (78% pe setul de antrenare, respectiv 72% pe setul de validare) alături de specificitatea foarte ridicată (de 99.9%) sugerează profilul unui model conservator, cu probabilitate redusă de a eticheta eronat structuri care nu îndeplinesc criteriile stabilite.

Un factor posibil care a contribuit la performanța modelului este utilizarea unei funcții de pierdere combinate, alcătuită în cazul studiului de față din „Dice loss” și „binary cross-entropy loss”. Aceasta este o abordare recomandată în sarcinile de segmentare medicală, întrucât permite optimizarea simultană a suprapunerii spațiale precum și a clasificării corecte la nivel de pixel sau voxel.

Comparativ cu studii publicate anterior privind segmentarea ganglionilor limfatici pe imagini de CT din regiunea capului și gâtului, performanța modelului propus se încadrează într-un interval comparabil având în vedere complexitatea bazei de date. Totuși, compararea directă a indicilor de performanță trebuie efectuată cu prudență, deoarece există diferențe privind designul studiilor, protocoalele utilizate (atât la achiziția cât și etichetarea imaginilor) care influențează în mod direct valorile DSC și IoU. Un review recent, care a analizat opt studii dedicate segmentării ganglionilor limfatici din regiunea capului și gâtului, a raportat valori DSC cuprinse între 0.66 și 0.90 [20].

Din perspectiva clinică, modelul propus trebuie interpretat ca un instrument de semnalare automată a regiunilor suspecte, nu ca un sistem autonom de diagnostic. Rolul său principal intervine în evidențierea potențialelor adenopatii care necesită atenție suplimentară, mai ales în contextul unui volum mare de muncă. Interpretarea finală trebuie să rămână dependentă de medicul radiolog, în corelație cu contextul clinic.

În concluzie, modelul bazat pe arhitectura U-Net++ a demonstrat o performanță bună de segmentare și identificare a adenopatiilor cu scoruri Node-RADS 3-5, obținând valori mari ale acurateții și specificității. Deși sensibilitatea rămâne moderată, în special în cazurile borderline, modelul poate contribui la evidențierea leziunilor suspecte și la orientarea mai rapidă a interpretării investigațiilor.

8. Studiul 4 - Inteligența artificială generativă – evaluarea impactului asupra antrenării unui rețele neuronale convoluționale folosind imagini histopatologice

8.1 Introducere

Ipoteza studiului este că imaginile sintetice generate printr-un model de IA generativă pot contribui la îmbunătățirea performanței unui CNN. Se presupune că integrarea datelor

generate artificial într-un set de antrenare mixt, alcătuit din imagini reale sintetice, poate crește valorile indicilor de performanță ai modelului comparativ cu antrenarea exclusivă pe un set redus de imagini reale.

Obiectivele studiului sunt reprezentate de:

- Adaptarea, implementarea și optimizarea unui model generativ de tip WGAN-GP (Wasserstein Generative Adversarial Network cu Gradient Penalty) pentru generarea de imagini histopatologice sintetice de carcinom scuamos oral;

- Antrenarea modelului generativ pe un set limitat de imagini histopatologice reale, în vederea producerii unui set suplimentar de imagini sintetice;

- Antrenarea unui CNN utilizând exclusiv un set limitat de date reale.

- Antrenarea aceleiași rețele CNN pe un set de date combinat alcătuit din date reale și datele generate artificial;

- Compararea performanțelor obținute între modelele antrenate pe date reale limitate și cele antrenate pe seturi mixte;

- Explorarea pragului inferior al volumului de date reale necesare pentru antrenarea unui IA generativ capabil să producă imagini sintetice utilizabile în procesul de Augmentare.

Prin această studiul urmărește să evalueze în ce măsură datele sintetice pot suplini parțial lipsa datelor reale și dacă acestea pot contribui la îmbunătățirea performanței modelelor de învățare profundă în histopatologia digitală.

8.2 Materiale și metode

A fost utilizată o bază de date publică cu imagini histopatologice de carcinom scuamos oral, achiziționate folosind un microscop Leica ICC50 HD și preprocesate pentru antrenarea modelelor. Pentru generarea imaginilor sintetice a fost implementat și antrenat un model generativ de tip WGAN-GP. Ulterior, a fost utilizat un model CNN bazat pe arhitectura EfficientNetB0 preantrenată pe ImageNet, fără stratul final de clasificare, peste care a fost adăugat un cap de clasificare binară personalizat. Modelul a fost evaluat în trei scenarii experimentale: antrenare pe imagini reale neaugmentate, antrenare pe imagini reale combinate cu imagini sintetice și antrenare pe imagini reale augmentate convențional prin rotații și oglindiri. Imaginile sintetice au fost introduse exclusiv în setul de antrenare, seturile de validare și testare fiind alcătuite doar din imagini reale. Un set suplimentar de imagini generate cu ChatGPT a fost format ca set de date sintetice de rezervă.

8.3 Rezultate

În primul scenariu, bazat exclusiv pe imagini reale neaugmentate, modelul a obținut o acuratețe de 84,0% pe setul de testare, cu o sensibilitate de 76,2%, specificitate de 89,7%, precizie de 84,2% și scor F1 de 80,0%. În al doilea scenariu, în care au fost introduse imagini sintetice în setul de antrenare, acuratețea pe setul de testare a fost de 78,0%, sensibilitatea de 61,9%, specificitatea de 89,7%, precizia de 81,3%, iar scorul F1 de 70,3%. În al treilea scenariu, bazat pe imagini reale augmentate convențional, modelul a obținut cele mai bune rezultate, cu o acuratețe de 86,0%, sensibilitate de 81,0%, specificitate de 89,7%, precizie de 85,0% și scor F1 de 82,9%. Modelul generativ WGAN-GP nu a produs imagini sintetice cu fidelitate histopatologică suficientă, acestea prezentând artefacte persistente și claritate redusă, ceea ce a limitat utilitatea lor directă în augmentarea datelor. Astfel, pentru realizarea testelor a fost utilizat setul de imagini sintetice generate cu ChatGPT.

8.4 Discuții

În interpretarea rezultatelor, primul scenariu experimental trebuie considerat principalul reper al studiului. Acesta simulează situația unei baze de date reale reduse, fără intervenții suplimentare de augmentare convențională sau sintetică. Prin urmare, performanțele obținute în scenariile ulterioare trebuie analizate în raport cu acest punct de referință, inclusiv valorile funcției de pierdere. Aceasta poate reflecta atât capacitatea de învățare a modelului, cât și efectul modificării distribuției datelor prin augmentare.

Utilizarea imaginilor sintetice generate prin ChatGPT a reprezentat o strategie exploratorie auxiliară, după ce modelul generativ antrenat local nu a produs imagini cu fidelitate histologică satisfăcătoare. În cadrul evaluării vizuale, unele imagini au prezentat artefacte morfologice precum artefacte intranucleare neobișnuite, structuri grafice repetitive, zone necrotice discutabile, aspecte stromale slab integrate sau elemente care nu pot fi atribuite credibil unor modificări histopatologice reale.

În literatura de specialitate, instrumentele de IA pentru anatomopatologi au mai fost studiate. Un astfel de exemplu este reprezentat de o aplicație de a detecta metastazele ganglionare pe lame histopatologice sporind indicii de performanță peste 90% în toate categoriile. Însă majoritatea bazei de date a fost alcătuită din metastaze ganglionare provenite din tumori mamare [21].

O direcție recentă de dezvoltare a inteligenței artificiale generative în histopatologie este reprezentată de generarea virtuală a imaginilor imunohistochimice pornind de la colorații HE. Astfel de modele pot reduce consumul de țesut, timpul necesar procesării și problemele de aliniere între secțiuni consecutive, oferind în același timp informații biologice suplimentare.

Această abordare extinde rolul IA generative dincolo de simpla augmentare a datelor, către generarea de informații moleculare sau imunohistochimice cu potențial impact asupra predicției clinice [22].

În concluzie, rezultatele sugerează că augmentarea convențională a imaginilor reale a avut un impact mai favorabil asupra performanței modelului CNN decât introducerea imaginilor sintetice generate artificial. Deși modelul generativ implementat nu a produs imagini histopatologice suficient de fidele pentru utilizare directă, studiul evidențiază dificultățile reale ale aplicării inteligenței artificiale generative în histopatologia digitală. Utilitatea datelor sintetice trebuie evaluată nu doar vizual, ci și funcțional, prin impactul asupra performanței modelelor antrenate ulterior.

9. Integrarea rezultatelor și discuții teransversale

Având în vedere abordarea multimodală a prezentei teze, integrarea transversală a rezultatelor este necesară pentru formularea unor concluzii coerente privind rolul inteligenței artificiale în evaluarea patologiei tumorale din sfera capului și gâtului. Studiile incluse au utilizat metode, tipuri de date și obiective diferite, însă converg către aceeași direcție generală: evaluarea modului în care parametrii morfologici, funcționali și computaționali pot contribui la identificarea, segmentarea sau clasificarea leziunilor relevante clinic.

Primul studiu, bazat pe analiza IRM a adenopatiilor cervicale, nu a utilizat direct metode de inteligență artificială, însă a avut rolul de a fundamenta statistic relația dintre parametrii imagistici și statusul histopatologic. Prin integrarea caracteristicilor morfologice cu valorile ADC, studiul a demonstrat că aceste variabile conțin informație diagnostică relevantă și cuantificabilă. Astfel, acest studiu oferă o ancorare clinică și statistică a tezei, susținând ideea că modelele automate trebuie dezvoltate pornind de la relații biologice și imagistice demonstrabile.

O temă transversală importantă a fost reprezentată de alegerea și interpretarea indicilor de performanță. În sarcinile de segmentare, acuratețea poate supraestima performanța reală, mai ales atunci când regiunea de interes ocupă o proporție redusă din imagine. Din acest motiv, utilizarea metricilor bazate pe suprapunere, precum Dice Similarity Coefficient și Intersection over Union, este esențială. Totuși, utilitatea fiecărei metrici depinde de context: în studiul ecografic, unde etichetarea s-a realizat prin chenare de localizare, IoU a fost mai adecvat pentru evaluarea încadrării spațiale a adenopatiei; în studiul CT, unde etichetele volumetrice manuale au avut un aspect mai pixelat, iar predicțiile modelului au fost mai continue, DSC a oferit o evaluare mai tolerantă a micilor diferențe de contur. Aceste observații arată că nu există un

indice universal optim, iar performanța trebuie interpretată în funcție de obiectivul modelului, tipul etichetării și relevanța clinică a erorilor.

Volumul și calitatea datelor au reprezentat o altă temă comună. În aplicațiile clinice ale inteligenței artificiale, seturile de date robuste includ adesea mii sau zeci de mii de exemple, ideal provenite din surse multiple. Prin comparație, studiile bazate pe câteva zeci sau sute de cazuri trebuie considerate dezvoltate în condiții de date limitate. Această limitare are implicații diferite în funcție de tipul datelor: în CT și IRM, fiecare pacient contribuie cu un număr redus de leziuni; în ecografie, o investigație poate furniza mai multe imagini, dar variabilitatea operator-dependentă rămâne importantă; în histopatologie, un număr redus de lame întregi poate genera multe regiuni de interes, în timp ce fragmentele izolate pot rămâne insuficiente dacă etichetarea este binară și nu include delimitarea regiunilor patologice.

În studiile efectuate, augmentarea convențională s-a dovedit, în această etapă, mai eficientă decât introducerea imaginilor sintetice generate prin inteligență artificială. Transformările geometrice precum rotațiile și oglinzirile păstrează caracteristicile reale ale imaginilor, în timp ce datele sintetice pot introduce artefacte sau structuri morfologice insuficient fidele. Prin urmare, utilitatea imaginilor generate artificial trebuie evaluată funcțional, prin impactul asupra performanței unui model ulterior, nu doar prin aspectul vizual.

Tipul arhitecturii utilizate a influențat, de asemenea, rezultatele. Modelele preantrenate sau arhitecturile deja validate pentru sarcini similare au demonstrat avantaje față de rețelele dezvoltate complet de la zero, mai ales în contextul datelor limitate. Comparația dintre modelul ecografic dezvoltat de la zero și modelul U-Net++ adaptat pentru segmentarea CT susține această observație. Astfel, o strategie echilibrată pentru dezvoltarea modelelor medicale ar trebui să includă arhitecturi validate, augmentare convențională, extinderea treptată a bazelor de date și validare pe loturi independente.

În ansamblu, rezultatele susțin rolul inteligenței artificiale ca instrument de suport decizional și de fluidizare a fluxului de muncă, nu ca substitut al medicului. Modelele dezvoltate pot contribui la semnalarea unor regiuni suspecte, standardizarea evaluării, accelerarea interpretării și reducerea variabilității inter-observator. Cu toate acestea, interpretarea finală trebuie să rămână dependentă de medic, de contextul clinic, de corelarea multimodală și de confirmarea histopatologică atunci când este necesară. Rolul realist al inteligenței artificiale, în această etapă, este de a amplifica capacitatea medicului de a analiza date complexe, nu de a înlocui raționamentul clinic.

10. Concluzii și contribuții personale

10.1 Concluzii

Principalele obiective ale tezei au fost atinse, în grade diferite, în funcție de specificul fiecărui studiu și de complexitatea metodologică a sarcinilor abordate. În primul rând, au fost identificate obstacolele și limitările care pot apărea în dezvoltarea unui program de inteligență artificială aflat în stadiul de demonstrare conceptuală, în special în raport cu disponibilitatea datelor, etichetarea, alegerea arhitecturii, metricile de performanță și capacitatea de generalizare. De asemenea, teza a analizat corelațiile morfo-imagistice în patologia ganglionilor limfatici utilizând metode imagistice convenționale, precum CT, IRM și ultrasonografia.

Obiectivul privind evaluarea corelațiilor morfo-imagistice a fost atins prin primul studiu, bazat pe imagistica IRM, care a demonstrat valoarea combinată a caracteristicilor morfologice și a coeficientului de difuzie aparent în diferențierea adenopatiilor benigne de cele maligne. Obiectivul privind dezvoltarea modelelor de inteligență artificială a fost abordat prin studiile II, III și IV, aplicate pe imagini ecografice, CT și histopatologice, acestea demonstrând fezabilitatea detecției, segmentării și clasificării automate în condiții de date limitate. Totodată, obiectivul privind compararea indicilor de performanță a fost atins în studiul ecografic, unde s-a evidențiat faptul că acuratețea poate supraestima performanța modelului, iar pentru sarcinile de segmentare sunt necesare metrici bazate pe suprapunere, precum DSC și IoU.

Obiectivul privind dezvoltarea unui program de inteligență artificială generativă a fost atins parțial, deoarece implementarea modelului WGAN-GP a evidențiat dificultăți metodologice reale și a generat rezultate suboptimale din punctul de vedere al fidelității histopatologice. Cu toate acestea, obiectivul privind compararea performanțelor obținute prin utilizarea imaginilor sintetice a fost atins. În contextul analizat, utilizarea imaginilor sintetice generate cu ChatGPT nu a îmbunătățit performanța modelului CNN comparativ cu augmentarea convențională a imaginilor reale în clasificarea imaginilor histopatologice cu OSCC. În ansamblu, integrarea multimodală a modelelor de inteligență artificială rămâne o direcție viitoare importantă, însă prezenta teză oferă un cadru metodologic pentru dezvoltarea acesteia, prin corelarea datelor imagistice, histopatologice și computaționale într-o abordare unitară.

Direcțiile în care trebuie continuată cercetarea:

Rezultatele obținute în cadrul prezentei teze deschid mai multe direcții de cercetare viitoare. O primă direcție, aplicabilă tuturor studiilor incluse, este reprezentată de extinderea

bazelor de date prin includerea unor loturi multicentrice, provenite de la instituții diferite, cu protocoale de achiziție și echipamente variate. Validarea externă rămâne esențială pentru aprecierea reală a generalizabilității modelelor și pentru evaluarea stabilității indicilor de performanță în contexte clinice diferite. De asemenea, este necesară explorarea unor metrice suplimentare de segmentare, precum IoU generalizat, Boundary IoU sau distanța Hausdorff, care pot oferi informații mai detaliate despre calitatea conturului și erorile de localizare.

Pentru componenta IRM, direcțiile viitoare vizează integrarea parametrilor radiomici și a modelelor de învățare automată sau profundă în evaluarea adenopatiilor cervicale. Având în vedere caracterul multiparametric al IRM, dezvoltarea unor modele eficiente necesită alinierea informațiilor provenite din secvențe diferite, precum T1, T2, T2 cu supresia grăsimii, DWI și hărțile ADC, precum și colaborarea strânsă cu medici radiologi pentru validarea etichetărilor și a criteriilor relevante.

În cazul ecografiei, cercetările viitoare ar trebui să urmărească extinderea modelului de la detecție către clasificarea benign/malign, prin includerea informațiilor Doppler și elastografice. De asemenea, compararea rețelei dezvoltate de la zero cu arhitecturi preantrenate pe imagini ecografice ar permite evaluarea beneficiului adus de transfer learning și ar putea îmbunătăți performanța în condiții de date limitate.

Pentru studiul CT, o direcție importantă este extinderea modelului către toate categoriile Node-RADS, astfel încât acesta să poată realiza nu doar segmentarea adenopatiilor suspecte, ci și stratificarea automată a riscului. Acest obiectiv necesită includerea unui număr suficient de cazuri pentru fiecare categorie Node-RADS. O altă direcție este reprezentată de trecerea de la arhitecturi 2D la arhitecturi 3D sau hibride, capabile să integreze informația dintre secțiuni și să îmbunătățească detecția ganglionilor mici sau neregulați. Arhitectura U-Net++ ar putea fi, de asemenea, adaptată ulterior pentru segmentarea tumorilor primare de cap și gât.

Componenta histopatologică rămâne o direcție deschisă importantă, în special prin dezvoltarea unor modele generative capabile să producă imagini sintetice cu fidelitate morfologică adecvată. Cercetările viitoare trebuie să includă baze de date mai mari, provenite din surse multiple, preprocesare standardizată, selecția riguroasă a regiunilor de interes și validarea histopatologică a imaginilor generate. Utilitatea datelor sintetice trebuie evaluată nu doar vizual, ci și funcțional, prin impactul asupra performanței modelelor CNN antrenate ulterior.

Pe termen lung, o direcție integrativă este reprezentată de reunirea modelelor dezvoltate într-o platformă digitală comună, cu rol de suport decizional. O astfel de aplicație ar putea include module de analiză pentru ecografie, CT, IRM și histopatologie, cu posibilitatea

integrării datelor clinice, imagistice și histopatologice într-o fișă digitală a pacientului. Scopul unei astfel de platforme nu ar fi înlocuirea medicului, ci organizarea informației, semnalarea elementelor relevante și susținerea procesului decizional multidisciplinar.

10.2. Contribuții personale

Prezenta teză aduce o contribuție originală prin abordarea multimodală a patologiei tumorale din sfera capului și gâtului, integrând metode statistice clasice, modele de învățare profundă și tehnici de inteligență artificială generativă. O primă contribuție este reprezentată de realizarea unei analize multiparametrice IRM a adenopatiilor laterocervicale, prin corelarea parametrilor morfologici și funcționali cu rezultatul histopatologic. Au fost evaluate valorile ADC, forma ganglionului, caracteristicile marginilor, necroza și prezența hilului gras, acestea fiind integrate într-un model statistic multivariat. Consolidarea metodologică a acestui studiu a fost realizată prin utilizarea unor analize adaptate structurii datelor, incluzând ecuații de estimare generalizată pentru dependența intra-pacient, validare internă, bootstrap, analiză ROC, test DeLong, calibrare și evaluarea reproductibilității inter- și intra-observator.

O altă contribuție importantă este dezvoltarea unei rețele neuronale convoluționale pentru identificarea adenopatiilor suspecte pe imagini ecografice B-mode. Aceasta a inclus selecția imaginilor, etichetarea manuală, aplicarea unor tehnici clasice de augmentare, construirea unei rețele neuronale de la zero și evaluarea performanței prin metrici de clasificare și segmentare. În cadrul acestui studiu a fost evidențiat faptul că o arhitectură neuronală mai complexă nu determină în mod necesar o performanță superioară, reducerea numărului de straturi fiind asociată cu o îmbunătățire a performanței în contextul unui set de date limitat.

În domeniul imagisticii CT, teza contribuie prin adaptarea și antrenarea unui model U-Net++ pentru segmentarea adenopatiilor cervicale suspecte pe imagini native și postcontrast. Modelul a fost orientat către identificarea adenopatiilor Node-RADS 3–5, fiind conceput ca instrument de semnalare a leziunilor echivoce sau suspecte, nu ca sistem complet de clasificare a tuturor ganglionilor limfatici. Prin includerea imaginilor CT native și postcontrast, precum și prin testarea calitativă pe cazuri independente și structuri anatomice mimetice, a fost explorată performanța modelului în condiții imagistice variate și au fost evidențiate limitele generalizării acestuia.

Teza aduce, de asemenea, o contribuție transversală prin evaluarea comparativă a metricilor de performanță utilizate în modelele de inteligență artificială medicală. Au fost evidențiate limitările acurateții, în special în sarcinile de segmentare, precum și necesitatea utilizării unor metrici complementare, precum sensibilitatea, specificitatea, precizia, scorul F1,

coeficientul Dice și indicele IoU. Această analiză a permis o interpretare mai nuanțată a performanței modelelor, în funcție de tipul sarcinii, forma etichetării și relevanța clinică a erorilor.

În componenta histopatologică, contribuția principală constă în evaluarea impactului imaginilor sintetice asupra performanței unui model CNN în condiții de date limitate. Au fost comparate scenarii de antrenare bazate pe imagini reale neaugmentate, imagini reale augmentate convențional și imagini reale combinate cu date sintetice. Rezultatele au evidențiat faptul că, în contextul metodologic analizat, augmentarea convențională a fost mai eficientă decât introducerea datelor sintetice. Totodată, studiul a subliniat dificultățile reale ale utilizării inteligenței artificiale generative în histopatologia digitală, în special în ceea ce privește fidelitatea morfologică a imaginilor generate și utilitatea lor funcțională în antrenarea modelelor.

Prin integrarea studiilor bazate pe IRM, ecografie, CT și histopatologie digitală, teza propune un cadru multimodal de analiză a patologiei tumorale din sfera capului și gâtului. Acest cadru reunește corelații morfo-imagistice, modele CNN, segmentare automată, metrici de performanță și inteligență artificială generativă, contribuind la conturarea unei perspective realiste asupra utilizării AI ca instrument de suport decizional, nu ca substitut al medicului.

Articole publicate în reviste de specialitate:

1. **Taciuc IA**, Dumitru M, Vranceanu D, Gherghe M, Manole F, Marinescu A, Serboiu C, Neagos A, Costache A. Applications and challenges of neural networks in otolaryngology (Review). Biomed Rep. 2024 Apr 19;20(6):92. Review, FI - 2.7/2024, Capitolul 2, paginile 17-19, 22-25.
<https://doi.org/10.3892/br.2024.1781>
<https://pubmed.ncbi.nlm.nih.gov/38765859/>
2. **Taciuc IA**, Dumitru M, Vranceanu D, Marinescu A, Serboiu C, Costache A, Anton A. Multiparametric MRI Assessment of Cervical Lymphadenopathy: Combined Diagnostic Performance of Morphological Features and Apparent Diffusion Coefficient. Healthcare (MDPI), 2026, FI – 2.7/2026, Q2 capitolul 5, paginile 40-60.
Articol acceptat, în curs de publicare.
3. **Taciuc IA**, Dumitru M, Vranceanu D, Marinescu A, Anton A, Costache A. Deep Learning-Based Detection of Malignant and Equivocal Cervical Lymph Nodes on CT Imaging Using a 2D U-Net++ Model. MAEDICA – a Journal of Clinical Medicine. 2026 Jun 2, indexată în PubMed, capitolul 7, paginile 79-93.
<https://doi.org/10.26574/maedica.2026.21.2.296>,
Articol acceptat, în curs de publicare.
4. **Taciuc I-A**, Dumitru M, Marinescu A, Serboiu C, Musat G, Gherghe M, Costache A, Vranceanu D. Enhancing Malignant Lymph Node Detection in Ultrasound Imaging: A Comparison Between the Artificial Intelligence Accuracy, Dice Similarity Coefficient and Intersection over Union. Journal of Mind and Medical Sciences. 2025; 12(1):29, indexată în BDI, capitolul 6, paginile 63-71.
<https://doi.org/10.3390/jmms12010029>.
<https://www.mdpi.com/2392-7674/12/1/29>
5. Dumitru M, Berghi ON, **Taciuc IA***, Vranceanu D, Manole F, Costache A. Could Artificial Intelligence Prevent Intraoperative Anaphylaxis? Reference Review and Proof of Concept. Medicina (Kaunas). 2022 Oct 26;58(11):1530. Mdicina (MDPI), 58(11), 2022, FI - 2.9/2022, Q2, capitolul 2, pagina 25.
<https://doi.org/10.3390/medicina58111530>
<https://pubmed.ncbi.nlm.nih.gov/36363487/>

Lucrări prezentate la manifestări științifice:

1. **Taciuc IA**, Dumitru M, Vrînceanu D, Costache A. The use of Artificial Intelligence in ENT. Discoveries in the field. 8th European Otolaryngology ENT – Surgery Conference 21-22 Nov 2022, Rome, Italy.
2. Dumitru M, **Taciuc IA**, Vrînceanu D, Costache A. Artificial intelligence in management of nasal tumors – review and perspectives. ERS-ISIAN 2023, Sofia, Bulgaria
3. Dumitru M, **Taciuc IA**, Vrînceanu D, Costache A. Artificial Intelligence – The ENT Perspective. 7th Congress of European ORL-HNS, June 2024, Dublin, Ireland.
4. **Taciuc IA**, Dumitru M, Vrînceanu D, Costache A. Sisteme de inteligență artificială în prevenția complicațiilor din cadrul patologiei ORL. Conferința SUUB, Ediția a VIII-a, Complicațiile procedurilor ORL. Cum le gestionăm?, Octombrie 2024, București, România.
5. Dumitru M, **Taciuc IA**, Costache A, Marinescu A, Vrînceanu D. Are we ready to accept artificial intelligence in rhinology imaging? 30th Congress of the European Rhinologic Society, June 2025, Budapest, Hungary.
6. **Taciuc IA**. Inteligența artificială în managementul specimenelor anatomopatologice cervico-faciale. Conferința națională multidisciplinară ORL – SUUB Ediția a IX-a. Octombrie 2025, București, România.
7. Dumitru M, **Taciuc IA**, Costache A, Serboiu C, Marinescu A, Vrînceanu D. Neck lymph nodes detection using AI on ultrasound images.

Premii și distincții obținute:

1. Certificat de apreciere pentru activitatea științifică deosebită din anul 2024.
2. Premiul iMAGO-MOL „Promising Young Scientist in Nuclear Medicine” 2025 Edition.

BIBLIOGRAFIE

1. Sun H, Yu M, An Z, et. al. Global burden of head and neck cancer: Epidemiological transitions, inequities, and projections to 2050. *Front Oncol.* 2025 Sep 25;15:1665019.
2. Theodosiou AA, Read RC. Artificial intelligence, machine learning and deep learning: Potential resources for the infection clinician. *J Infect.* 2023 Oct;87(4):287-294.
3. Sun H, Yu M, An Z, et. al. Global burden of head and neck cancer: Epidemiological transitions, inequities, and projections to 2050. *Front Oncol.* 2025 Sep 25;15:1665019.
4. Gandini S, Botteri E, Iodice S, et al. Tobacco smoking and cancer: a meta-analysis. *International Journal of Cancer* 2008; 122(1):155–164.
5. Xu Z, Jiang G, Dai J. Tumor therapeutics in the era of "RECIST": past, current insights, and future prospects. *Oncol Rev.* 2024 Oct 18;18:1435922.
6. Murtaza G, Gao K, Liu T, Tariq I, Sajjad A, Akram MR, Niu M, Liu G, Mehmood Z, Tian G. Current and future lymphatic imaging modalities for tumor staging. *Biomed Res Int.* 2014;2014:714674.
7. Elsholtz F.H.J., Asbach P., Haas M., Becker M., Beets-Tan R.G.H., Thoeny H.C., Padhani A.R., Hamm B. Introducing the Node Reporting and Data System 1.0 (Node-RADS): A Concept for Standardized Assessment of Lymph Nodes in Cancer. *Eur. Radiol.* 2021;31:6116–6124.
8. F. Wang, L.P. Casalino, D. Khullar, Deep learning in medicine—promise, progress, and challenges, *JAMA Intern Med* 179 (3), 2019, p293–294.
9. **Taciuc IA**, Dumitru M, Vrinceanu D, Gherghe M, Manole F, Marinescu A, Serboiu C, Neagos A, Costache A. Applications and challenges of neural networks in otolaryngology (Review). *Biomed Rep.* 2024 Apr 19;20(6):92.
10. Alzubaidi, L., Zhang, J., Humaidi, A.J. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data* 8, 53 (2021).
11. Wang J, Liu Q, Xie H, Yang Z, Zhou H. Boosted EfficientNet: Detection of Lymph Node Metastases in Breast Cancer Using Convolutional Neural Networks. *Cancers (Basel).* 2021 Feb 7;13(4):661.
12. Wang C, Li J, Zheng H, Li J, Huang H, Jiang L. Research on Medical Image Segmentation Method Based on Improved U-Net3. *Crit Rev Biomed Eng.* 2024;52(4):1-15.
13. Michelutti L, Tel A, Zeppieri M, Ius T, Sembronio S, Robiony M. The Use of Artificial Intelligence Algorithms in the Prognosis and Detection of Lymph Node Involvement in

- Head and Neck Cancer and Possible Impact in the Development of Personalized Therapeutic Strategy: A Systematic Review. *J Pers Med*. 2023 Nov 21;13(12):1626.
14. Drew T, Võ ML, Wolfe JM. The invisible gorilla strikes again: sustained inattention blindness in expert observers. *Psychol Sci*. 2013 Sep;24(9):1848-53.
 15. Haisma MS, Plaat BEC, Bijl HP, Roodenburg JLN, Diercks GFH, Romeijn TR, Terra JB. Multivariate analysis of potential risk factors for lymph node metastasis in patients with cutaneous squamous cell carcinoma of the head and neck. *J Am Acad Dermatol*. 2016 Oct;75(4):722-730.
 16. Hazra A, Gogtay N. Biostatistics Series Module 10: Brief Overview of Multivariate Methods. *Indian J Dermatol*. 2017 Jul-Aug;62(4):358-366.
 17. Kanemaru N, Yoshikawa T, Miki S, etc. Axillary Lymphadenopathy after COVID-19 Vaccination: Follow-up for Enlarged Lymph Nodes on MR Imaging. *Magn Reson Med Sci*. 2025 Apr 1;24(2):176-183.
 18. Zhao, H.N.; Yin, H.; Liu, J.Y.; Song, L.L.; Peng, Y.L.; Ma, B.Y. Deep learning-assisted ultrasonic diagnosis of cervical lymph node metastasis of thyroid cancer: A retrospective study of 3059 patients. *Front. Oncol*. 2024, 14, 1204987.
 19. Yanting, L.; Junjuan, Z.; Quanyong, L.; Chentian, S.; Ren, W.; Xuehai, D. Automated classification of cervical lymph-node-level from ultrasound using Depthwise Separable Convolutional Swin Transformer. *Comput. Biol. Med*. 2022, 148, 105821.
 20. Wu W, Laville A, Deutsch E, Sun R. Deep learning for malignant lymph node segmentation and detection: a review. *Front Immunol*. 2025 Apr 28;16:1526518.
 21. Vazzano J, Challa B, Arole V, Shilo K, Reuss S, Kobalka P, Satturwar S, Xie J, Chung D, Shafi S, Kellough D, Palermini E, Li Z, Chen W, Parwani A, Sun S. AI for pathologists: a universal lymph node metastasis detection app that enhances efficiency while preserving diagnostic accuracy. *J Pathol Clin Res*. 2026 Jan;12(1):e70073.
 22. Pati, P., Karkampouna, S., Bonollo, F. et al. Accelerating histopathology workflows with generative AI-based virtually multiplexed tumour profiling. *Nat Mach Intell* 6, 1077–1093 (2024).