

UNIVERSITATEA BABEȘ-BOLYAI
FACULTATEA DE MATEMATICĂ ȘI INFORMATICĂ

Învățare automată și tehnici avansate de viziune pe calculator pentru științe naturale

Rezumatul tezei de doctorat

Student doctorand: Horea-Bogdan Mureșan
Coordonator științific: Prof. Dr. Horia F. Pop

2023

Cuvinte cheie: rețele neuronale convolutive, învățare profundă, date sintetice, clasificare și detecție de obiecte din imagini

Cuprins

Cuprinsul tezei de doctorat	2
Listă de publicații	4
1 Introducere	6
1.1 Motivație	6
1.2 Obiective	8
2 Învățare automată și viziune computerizată pentru agricultură inteligentă	11
2.1 Contextul actual în agricultura inteligentă	11
2.2 Abordări propuse în agricultura inteligentă	11
2.3 Concluziile capitolului	13
2.4 Sumarul contribuțiilor	13
3 Învățare automată și viziune computerizată pentru diagnoză medicală	15
3.1 Contextul actual în diagnoză medicală	15
3.2 Abordări propuse în diagnoză medicală	16
3.3 Concluziile capitolului	16
3.4 Sumarul contribuțiilor	17
4 Învățare automată și viziune computerizată pentru educație colaborativă trans-disciplinară	18
4.1 Contextul educației colaborative transdisciplinară	18
4.2 Detalii despre curs	19
4.3 Concluziile capitolului	20
4.4 Sumarul contribuțiilor	20
5 Concluzii	21

Contents

List of Publications	8
1 Introduction	10
1.1 Motivation	10
1.2 Objectives	12
1.3 Thesis Structure	14
1.4 Original Contributions	16
1.4.1 Smart Agriculture	16
1.4.2 Medical diagnosis	17
1.4.3 Collaborative Trans-disciplinary Education	18
2 Machine Learning and Computer Vision for Smart Agriculture	19
2.1 Background for Smart Agriculture	20
2.1.1 Motivation for harvest estimation and plant disease detection . .	20
2.1.2 Related work on harvest estimation and plant disease detection .	21
2.1.2.1 Harvest estimation	21
2.1.2.2 Plant disease detection	32
2.2 Proposed Approaches for Smart Agriculture	39
2.2.1 State of the art in fruit classification and detection	40
2.2.2 Fruit classification and detection datasets	42
2.2.3 Proposed deep learning models	51
2.2.4 Sunflower yield estimation	64
2.2.5 Conclusions and future work	68
3 Machine Learning and Computer Vision for Medical Diagnosis	71
3.1 Background for Medical Diagnosis	71
3.1.1 Motivation for medical diagnosis	72
3.1.2 Related work on medical diagnosis	73
3.2 Proposed Approaches for Medical Diagnosis	76

3.2.1	Skin lesion diagnosis using deep learning	76
3.2.1.1	Methodology	76
3.2.1.2	Network structure	78
3.2.1.3	Experimental setup and results	82
3.2.2	Fracture risk detection	86
3.2.2.1	Medical data	86
3.2.2.2	Fast information retrieval	89
3.2.2.3	Data analysis	90
3.2.2.4	Case study on smoking habits data	91
3.2.2.5	Case study on body-mass index data	92
3.2.2.6	Case study on pharmacy data	92
3.2.2.7	Acknowledgments	94
3.2.3	Conclusion and next steps	94
3.2.3.1	Skin lesion diagnosis	94
3.2.3.2	Fracture risk estimation	98
4	Machine Learning and Computer Vision in Trans-disciplinary Education	99
4.1	Introduction	100
4.2	A novel teaching approach in AI models for climate change	100
4.2.1	Course details	101
4.2.1.1	Innovation and applicability	101
4.2.1.2	Collaboration and trans-disciplinarity	102
4.2.2	Platforms and tools	102
4.2.3	Teaching the course	102
4.2.4	Presented topics	103
4.2.4.1	Light pollution	104
4.2.4.2	Agent green	105
4.2.4.3	Climate change and human ecology biodiversity	105
4.2.4.4	Miscellaneous	107
4.3	Experimental approaches in content and evaluation	108
4.3.1	Artificial intelligence application guidelines	108
4.3.2	Student evaluation and results	110
4.3.3	Evaluating the course approach	112
4.4	Course conclusions	114
5	Conclusions and future work	116

Listă de publicații

Punctajul publicațiilor a fost realizat conform clasamentului pentru jurnale ¹ și pentru conferințe ² în Informatică din anul publicării. Evaluarea este în concordanță cu standardele CNATDCU din 1 Octombrie 2018.

Publicații în ISI Web of Knowledge

Publicații în ISI Conference Proceedings Citation Index

1. [Mur19] **Horea-Bogdan Mureșan**, Skin lesion diagnosis using deep learning, *IEEE 15th International Conference on Intelligent Computer Communication and Processing (ICCP)*, pp. 499–506, 2019, <https://doi.org/10.1109/ICCP48234.2019.8959661>.
CORE 2018, Rank C, 2 points, 7 citations
2. [MCC20b] **Horea-Bogdan Mureșan**, Adriana Mihaela Coroiu, Alina Delia Călin. Detecting leaf plant diseases using deep learning: A review, *2020 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, pp. 1–6, 2020, <https://doi.org/10.23919/SoftCOM50211.2020.9238318>.
CORE 2020, Rank D, 1 point, 0 citations
3. [MMC⁺21] Alexandru-Ion Marinescu, **Horea-Bogdan Mureșan**, Alina-Delia Căalin, Adriana-Mihaela Coroiu, Maria Talla. Freida - fracture risk evaluation using highly efficient information retrieval and analysis of large healthcare datasets. *IEEE International Conference on Big Data (Big Data)*, pp. 3917–3922, 2021, <https://doi.org/10.1109/BigData52589.2021.9671799>.
CORE 2021, Rank B, 1.33 points, 1 citation

¹<https://uefiscdi.gov.ro/scientometrie-reviste>

²<http://portal.core.edu.au/conf-ranks/>

4. [Mur22] **Horea-Bogdan Mureșan**. An automated algorithm for fruit image dataset building. *17th Conference on Computer Science and Intelligence Systems (FedCSIS)*, pp. 103–107, 2022, <https://dx.doi.org/10.15439/2022F58>.
CORE 2021, Rank B, Short paper, 2.66 points, 1 citation
(Reclassified as Multi-conference in November 2022)
5. [CCM22] Adriana Mihaela Coroiu, Alina Delia Călin, **Horea-Bogdan Mureșan**. Collaborative transdisciplinary educational approaches in AI. *International Conference on Computer Supported Education*, pp. 260-267, 2022, <https://doi.org/10.5220/0011039500003182>.
CORE 2021, Rank B, 4 points, 0 citations

Publicații în Jurnale Internaționale și conferințe

1. [MO18] **Horea Mureșan**, Mihai Oltean. Fruit recognition from images using deep learning, *Acta Universitatis Sapientiae, Informatica*, volume 10(1), pp. 26 – 42, 2018, <https://doi.org/10.2478/ausi-2018-0002>.
UEFISCDI 2018, Rank D, 0 points, 129 citations
note: the preprint of the article available at <https://arxiv.org/abs/1712.00580> has 384 citations
2. [MCC20a] **Horea-Bogdan Mureșan**, Alina Delia Călin, Adriana Mihaela Coroiu. Overview of recent deep learning methods applied in fruit counting for yield estimation. *Studia Universitatis Babeș-Bolyai Informatica*, volume 65(2), pp. 50–65, 2020, <https://doi.org/10.24193/subbi.2020.2.04>.
UEFISCDI 2020, Rank D, 1 point, 0 citations
3. [CCM23] Alina Delia Călin, Adriana Mihaela Coroiu, **Horea-Bogdan Mureșan**. Analysis of Preprocessing Techniques for Missing Data in the Prediction of Sunflower Yield in Response to the Effects of Climate Change. *Applied Sciences*, 2023, 13, 7415, <https://doi.org/10.3390/app13137415>.
4 points, 1 citation
UEFISCSI 2022 AIS, Rank B (Q3 5-th position, Eng. Multidisciplinary SCIE)
UEFISCSI 2023 AIS, Rank B (Q3 7-th position, Chem. Multidisciplinary SCIE)

Capitolul 1

Introducere

Acest capitol prezintă motivația din spatele problemelor abordate în această teză de doctorat și obiectivele pe care am propus să le îndeplinim.

1.1 Motivație

Informatica a avut întotdeauna impact asupra altor domenii de cercetare, prin introducerea unor metode inovatoare de prelucrare a datelor și a unor modalități mai bune și mai rapide de înțelegere a datelor. Mai mult, informatica a permis automatizarea sarcinilor care, în mod convențional, sunt consumatoare de timp atunci când sunt efectuate de oameni. În această lucrare vom prezenta metode aparținând a două subdomenii ale informaticii: învățarea automată (ML) și viziunea computerizată (inclusiv procesarea imaginilor cu învățare profundă). Această lucrare a fost concepută într-o perioadă în care inteligența artificială a fost integrată în procese din diferite industrii și servicii, cu scopul de a ajuta oamenii în activitatea lor. Viziunea computerizată (clasificarea și detectarea obiectelor din imagini/video) și învățarea automată evoluează într-un ritm rapid și oferă din ce în ce mai multă asistență în multe domenii. Utilizarea acestor tehnici pentru a optimiza, accelera, simplifica sau asista fie procesele de producție din agricultură sau industrie, fie procese legate de asistența medicală este o necesitate reală, deoarece cererea pentru acestea este în continuă creștere.

Accentul în această lucrare cade pe cercetarea modului de îmbunătățire a vederii computerizate și a tehnicilor de învățare automată atunci când sunt aplicate cu scopul de a automatiza procese existente. Cele două domenii principale pe care le-am explorat sunt agricultura și medicina, două domenii neînrudite, care demonstrează flexibilitatea

și adaptabilitatea viziunii computerizate și a algoritmilor de învățare automată.

Învățare automată și viziune computerizată pentru agricultură inteligentă - am ales acest domeniu deoarece agricultura este crucială pentru aprovizionarea globală cu alimente. Pe măsură ce populația globului continuă să crească și cantitatea de sol fertil este limitată, orice inovație care ajută la creșterea cantității de culturi/fructe recoltate constituie un plus valoare. Agricultura inteligentă în sine, la momentul în care a fost elaborată teza, este un domeniu care nu este explorat pe larg, dar deține mai multe direcții de cercetare cu potențial, cum ar fi estimarea automată a recoltei și detectarea bolilor frunzelor din imagini [JHB19, CSD⁺17, MLM⁺20, YWBZ19, EC19]. Prima poate fi folosită pentru estimarea timpurie a recoltei, oferind mai mult timp fermierilor pentru a aloca o cantitate adecvată de resurse pentru procesul efectiv de recoltare și pentru depozitare. Cea din urmă poate fi folosită pentru sisteme de avertizare care pot notifica fermierii în cazul în care apar modificări bruște ale colorării frunzelor plantelor, care pot indica o anumită boală. Ambele sisteme permit optimizarea proceselor în agricultură, ceea ce la rândul său ajută la creșterea randamentului.

Învățare automată și viziune computerizată pentru diagnoza medicală - serviciile medicale de calitate sunt printre pietrele de temelie ale civilizației moderne, ca atare, este firesc să încercăm să le optimizăm și să le îmbunătățim. După cum am menționat anterior, informatica și inteligența artificială s-au împletit cu multe domenii, sănătatea nefiind o excepție. Există un mare interes în comunitatea de cercetare pentru diagnosticarea asistată de calculator și prelucrarea datelor medicale [RIZ⁺17, RvKF12]. Din punct de vedere al diagnosticului, o problemă majoră este că nevoia de personal calificat depășește oferta. Astfel, automatizarea parțială sau totală a procesului ar putea atenua o parte din problemă. Un alt aspect care prezintă un mare interes în cercetare este înlocuirea proceselor de diagnostic invazive cu altele neinvazive [RGBM17], cum ar fi utilizarea doar a imaginilor medicale. În acest domeniu, unele modele depășesc deja oamenii [RIZ⁺17] atunci când lucrează cu imagini radiologice. Ca atare, există o mare promisiune în domeniul utilizării tehnicilor de viziune computerizată pentru diagnosticul medical. În plus, sistemul medical ar putea beneficia de un sistem automatizat de avertizare timpurie care ar putea identifica și programa persoanele pentru controale pe baza datelor lor medicale. Încă în preocupările serviciului de asistență medicală se lucrează cu cantități mari de date generate de colectarea istoricelor medicale. O îmbunătățire ar putea fi obținută prin analiza datelor folosind algoritmi nesupravegheați pentru a extrage caracteristici puternic corelate și reținând doar una dintre ele pentru a reduce volumul de date.

Învățare automată și viziune computerizată în educația colaborativă transdisci-

plinară - această zonă de cercetare combină tehnici de inteligență artificială, probleme din lumea reală și metodologii de predare. Pe măsură ce algoritmi inteligenți sunt integrați în tot mai multe domenii, capacitatea informaticienilor de a înțelege nevoile, cerințele și perspectivele cercetătorilor din alte domenii constituie un avantaj semnificativ în dezvoltarea modelelor. Ca atare, am considerat că ar fi util să introducem un curs axat pe încercarea de a rezolva probleme din lumea reală folosind metode de inteligență artificială, în timp ce modelăm problemele atât din perspectiva informaticianului, cât și din perspectiva unui expert din domeniul problemei. Acest lucru i-ar învăța pe studenți cum să-și lărgescă orizontul, să-și îmbunătățească creativitatea și gândirea critică atunci când rezolvă probleme. O motivație secundară pentru introducerea acestui curs a fost îmbunătățirea propriei perspective legate de tehnicile de inteligență artificială, deoarece în loc să aplicăm aceste tehnici ar trebui să le explicăm și să le prezentăm altora [BM19, BKSD10, LZHL18].

1.2 Obiective

Teza de doctorat constă în folosirea și rafinarea metodelor de inteligență artificială aplicate problemelor din lumea reală de clasificare, detecție, recunoaștere a modelelor și extracție de date. Toate cercetările originale efectuate au fost realizate sub supravegherea Prof. Dr. Horia F. Pop. Scopul acestei teze este de a propune soluții care automatizează, integral sau parțial, sarcini complexe din lumea reală. Acest lucru ar îmbunătăți eficiența costurilor și productivitatea proceselor vitale care necesită identificarea elementelor sau entităților cheie în datele structurate sau nestructurate (imagini, text). Pe baza revizuirii literaturii noastre, algoritmi ML și învățarea profundă pentru tehnicile de procesare a imaginilor sunt alegeri bune pentru obiectivele noastre, deoarece la un nivel înalt, aceste metode sunt capabile să extragă caracteristicile necesare pentru a lua decizii care pot ajuta oamenii, iar soluțiile bazate pe inteligența artificială pot ajuta procesele fiind în același timp mai ușor extensibile.

Cele două domenii principale care au fost selectate pentru cercetarea noastră au fost **Agricultură și Îngrijirea sănătății** pentru importanța lor în lumea reală și problemele practice pe care le conțin. Am efectuat, de asemenea, cercetări care, deși nu sunt centrale pentru scopul tezei, beneficiază de rezultatele și cunoștințele dobândite în urma acestor experimente, sub forma predării aplicării algoritmilor de inteligență artificială (ML, deep learning etc.) cu abordări centrate pe date în rezolvarea problemelor din lumea reală.

Agricultura inteligentă, pe baza analizei noastre de literatură, pune mai multe probleme și am formulat obiective centrate în jurul lor. Cea mai răspândită problemă a fost lipsa unor seturi de date adnotate, de înaltă calitate, disponibile public, cu imagini cu fructe. O altă problemă a fost dificultatea de a compara rezultatele obținute în agricultura inteligentă, deoarece seturile de date utilizate erau distincte, iar lucrările s-au concentrat pe obiective diferite. În ceea ce privește datele text, cum ar fi informațiile istorice referitoare la datele de însămânțare, locațiile sau tipul de recoltă, deși există mai multe astfel de seturi de date, acestea pot conține lipsuri. Ca atare, ne-am propus să abordăm aceste probleme. Primul obiectiv a fost de a aduna, centraliza și rezuma stadiul tehnicii în agricultura inteligentă. În continuare, următorul obiectiv a fost introducerea unui nou set de date de înaltă calitate, cu imagini de fructe, dintr-o varietate de specii, potrivite pentru sarcinile de clasificare. Pe lângă introducerea setului de date, am urmărit să introducem un model antrenat și testat pe setul de date pentru a stabili o performanță de bază. În plus, am plănuisit să extindem setul de date cu imagini și fișiere de adnotare potrivite pentru detectare printr-un algoritm care generează imaginile pe baza setului de date de clasificare. Un obiectiv legat de setul de date de detecție a fost introducerea unui detector antrenat pe imagini pur sintetice și compararea performanței acestuia cu detectoare de ultimă generație antrenate pe imagini din lumea reală pentru a reduce efortul dedicat achiziției de date. Pentru datele text, am studiat metodele de imputare pentru manipularea seturilor de date cu valori lipsă pentru a îmbunătăți un model care estimează randamentul pe baza datei de plantare. De asemenea, am evaluat utilizarea modelelor de eliminare a valorii aberante nesupravegheate pentru a spori și mai mult performanța unui estimator.

Pentru domeniul **Medical** am analizat lucrări performante și am selectat 2 obiective principale. În primul rând, odată cu apariția dermatoscopiei, o metodă neinvazivă de diagnosticare a leziunilor cutanate, ne-am propus să pregătim un clasificator care poate fi utilizat pentru a identifica mai multe tipuri de leziuni cutanate. Am extins în continuare această cercetare prin studierea impactului tehnicilor de supra-eșantionare asupra performanței clasificatorului și dacă aceste tehnici au fost suficiente pentru a aborda problema claselor subreprezentate. Un al doilea obiectiv a fost dezvoltarea unui model de învățare automată care estimează riscul de osteoporoză la pacienți pe baza istoricului lor medical. Un sub-obiectiv al acestui obiectiv a fost îmbunătățirea timpilor de recuperare a datelor pentru orice pacient dat, identificarea corelațiilor de date non-triviale și integrarea acestor funcționalități într-un software utilizat de specialiștii medicali.

Un alt obiectiv stabilit a fost introducerea unui curs de Învățare automată și Tehnici

avansate de viziune computerizată, destinat studenților. Ne-am propus să formăm tineri cercetători capabili să abordeze astfel de probleme cu o perspectivă mai largă, ținând cont de natura interdisciplinară a sarcinilor. Pe baza observațiilor noastre din literatura de specialitate, am remarcat, de asemenea, că procesarea și înțelegerea datelor este un element cheie pentru dezvoltarea unor modele viabile pentru problemele din lumea reală, idee pe care ne-am propus să o transmitem studenților. Ne-am propus să acoperim subiecte pornind de la modelarea problemelor, achiziția setului de date, explorarea, sanitizarea, creșterea și procesarea, selecția modelelor, instruirea și testarea și analiza și înțelegerea rezultatelor.

Capitolul 2

Învățare automată și viziune computerizată pentru agricultura inteligentă

2.1 Contextul actual în agricultura inteligentă

În această secțiune, prezentăm contextul și contribuțiile de ultimă oră pe care le-am valorificat în cercetările noastre legate de clasificarea și detectarea fructelor, precum și identificarea bolilor plantelor folosind învățarea profundă. Am revizuit aceste lucrări pentru a ne ajuta în contribuțiile noastre originale detaliate în [MO18,MCC20a,MCC20b, Mur22]. Se prezintă informațiile relevante domeniului și recenzii de ultimă generație. Există interes în dezvoltarea clasificatoarelor și detectorilor care utilizează imagini de fructe/plante și regresori folosind date text cu scopul de a optimiza procesele legate de agricultură, cum ar fi recoltarea, alocarea resurselor, distribuția tratamentului. Subliniem problemele aferente, cum ar fi: *recunoașterea fructelor din imagini folosind învățarea profundă, detectarea bolilor plantelor cu frunze din imagini, metode de învățare profundă pentru estimarea producției de fructe*. În cadrul acestei Secțiuni vom prezenta relevanța fiecărei probleme în contextul domeniului și raționamentul abordărilor de învățare profundă.

2.2 Abordări propuse în agricultura inteligentă

Se detaliază abordările noastre privind clasificarea bolilor fructelor și frunzelor, detectarea fructelor din imagini și estimarea randamentului pe baza datei de însămânțare

și a parametrilor meteorologici. Remarcăm că problema cea mai răspândită în acest domeniu este lipsa datelor disponibile. Astfel, în abordările noastre am urmărit să abordăm această problemă prin introducerea unui set de date mare cu imagini de înaltă calitate care conțin 90483 imagini aparținând de 131 specii de fructe. Descriem procesul folosit pentru a crea imaginile fructelor, studiem și viabilitatea utilizării setului de date împreună cu un model de învățare profundă (bazat pe VGG16 [SZ14]). Am comparat efectul modificărilor în arhitectura modelului și utilizarea diferitelor spații de culoare asupra performanței și am obținut o precizie de 98,66%. În comparație cu literatura de specialitate, un clasificator similar este prezentat în [XWL⁺19], obținând și o acuratețe de 89,06%. În continuare, prezentăm modul în care am modelat problema creării de imagini viabile pentru detectare. Ne-am propus să generăm imagini sintetice, pe baza celor pe care le-am colectat deja pentru clasificare și să le combinăm cu imagini de fundal. Această abordare nu a fost încercată înainte în contextul locațiilor în aer liber. Descriem algoritmul pe care l-am proiectat și implementat, structura detectorului pe care l-am folosit pentru a testa calitatea imaginilor generate și comparăm rezultatele noastre cu alte detectoare care au fost antrenate exclusiv pe date reale. Cel mai bun rezultat al nostru, în ceea ce privește metrica F1-Score (0,816) se clasează în același interval de performanță ca și alte detectoare (alte lucrări pe care le-am analizat se încadrează în intervalul (0,783, 0,849) pentru F1-Score). Folosind informații privind data de însămânțare și parametrii meteorologici, am antrenat un model de regresie pentru a identifica orice tipare pentru o estimare mai bună a randamentului. Am studiat eficacitatea a nouă metode diferite pentru imputarea valorii lipsă: valori medii, valori similare, interpolare liniară, spline și pad, regresie liniară, random fores, regresie de creștere a gradientului extrem și prin histogramă. În plus, am studiat eliminarea valorilor extreme folosind metode nesupravegheate, cum ar fi isolation forest, determinantul de covarianță minimă, factorul extrem local și SVM cu o singură clasă. Am obținut o creștere a performanței pentru estimatorul nostru (măsurată folosind metrica R^2) de la 0,723 (în cazul eliminării intrărilor cu attribute lipsă) la 0,938 când se utilizează random forest și un SVM cu o singură clasă. Prezentăm concluziile noastre legate atât de procesele de creare a seturilor de date, cât și de modelele de învățare profundă pe care le-am antrenat și urmărim planurile viitoare de cercetare.

2.3 Concluziile capitolului

Pe baza cercetărilor noastre în agricultura inteligentă, pe tema estimării recoltei, am introdus un set de date cu imagini de fructe, Fruits-360, potrivit pentru clasificare. Am extins și mai mult capacitatea de utilizare a setului de date Fruits-360 prin introducerea unui software care generează imagini sintetice și fișiere de adnotare care pot fi utilizate pentru sarcini de detectare. Am introdus o rețea neuronală convoluțională care a fost antrenată pe setul de date Fruits-360 și am testat-o, obținând o precizie în clasificare de 98,66%. Pentru algoritmul de generare a datelor, am studiat dacă imaginile create pot fi utilizate cu succes pentru a antrena un detector și l-am testat pe date reale. Pe baza scorului F1 de 0,816 și în comparație cu alte lucrări, am arătat că este fezabilă utilizarea datelor generate ca substitut pentru datele reale, fără o penalizare majoră a performanței. Utilizarea datelor istorice de producție și a condițiilor meteorologice la momentul însămânțării poate fi folosită cu succes pentru a crea estimatori preciși. În plus, am arătat că metodele de imputare și eliminarea valorilor extreme ar trebui efectuate pentru a obține o creștere semnificativă a performanței estimatorilor.

În concluzie, rezultatele noastre fac cercetarea agriculturii inteligente mai accesibilă, eliminând nevoia de a colecta imagini din lumea reală și adnotându-le manual. Mai mult, efectuarea unei analize comparative pe diferiți detectori se poate face mai ușor, deoarece datele pot fi generate pentru orice scenariu de detectare a fructelor. Deoarece am arătat că antrenamentul pe date sintetice produce rezultate satisfăcătoare în detectarea fructelor, alte domenii pot fi abordate într-o manieră similară, inspirate de aceste rezultate.

2.4 Sumarul contribuțiilor

- Introducerea unui set de date de înaltă calitate (Fruits-360) de imagini cu fructe pentru clasificare (90483 imagini, 131 specii de fructe) constituie o contribuție originală, deoarece nu a fost lansat un astfel de set de date publice [MO18].
- Un model nou pentru clasificarea fructelor care este capabil să distingă 131 tipuri de fructe [MO18].
- Abordarea problemei deficitului de date pentru detectarea fructelor prin introducerea unui algoritm care construiește un set de date de detectare folosind imagini din setul de date Fruits-360 și creează fișiere de adnotare. Setul de date generat

poate fi personalizat de către utilizator pentru a se potrivi propriului scenariu de detectare a fructelor. Lucrarea constituie o contribuție originală, deoarece nu există abordări care să genereze seturi de date sintetice ținând cont de condițiile de mediu exterioare [Mur22].

- Am introdus un detector antrenat pe date generate sintetic și am obținut rezultate comparabile cu alte modele de ultimă generație antrenate exclusiv pe date din lumea reală. Nicio altă lucrare nu utilizează modele antrenate doar pe date sintetice și testate pe imagini din lumea reală [Mur22].
- Am antrenat un model de regresie pentru estimarea producției de floarea-soarelui pe baza datei de însămânțare și a parametrilor meteo. Am studiat eficacitatea mai multor metode pentru imputarea valorilor lipsă și am studiat eliminarea valorilor extreme folosind metode de învățare nesupravegheată. Am obținut creșteri semnificative ale performanței estimatorului comparativ cu antrenarea doar pe datele cărora nu lipsesc niciun atribut [CCM23].

Capitolul 3

Învățare automată și viziune computerizată pentru diagnoză medicală

3.1 Contextul actual în diagnoză medicală

În această secțiune, prezentăm contextul pentru diagnosticarea leziunilor cutanate și osteoporoza și fracturile cauzate de estimarea riscului de fragilitate osoasă pe care le-am utilizat în cercetarea noastră. Aceste cunoștințe au fost adunate pentru a ne ajuta în munca originală realizată în [Mur19, MMC⁺21]. Detaliem stadiul actual al tehnicii în diagnosticarea medicală asistată de calculator, prezentăm importanța dermatoscopiei, o tehnică neinvazivă de diagnosticare a leziunilor cutanate bazată pe imagini medicale. Lucrările actuale de ultimă oră în ceea ce privește clasificarea leziunilor cutanate folosind modele de învățare profundă obțin o acuratețe de 81,33% [RGBM17] și 78% [MdS18], totuși accentul principal cade doar pe leziunile maligne. Subliniem, de asemenea, necesitatea estimării riscului de fractură în vederea înscrierii pacienților cu risc ridicat în programele de prevenire. Au fost create programe care calculează riscul de fractură pe baza atributelor din istoricul medical al unei persoane, cum ar fi FRAX și XRAIT [KBB⁺21] cu o sensibilitate de 70% și o specificitate de 92%. În ciuda acestui fapt, nu a fost găsit niciun alt program care să calculeze acest factor de risc în timp real.

3.2 Abordări propuse în diagnoză medicală

Această secțiune prezintă experimentele noastre cu tehnici ML și algoritmi de viziune computerizată aplicați pentru diagnosticul medical. Munca noastră include aplicarea rețelelor neuronale convoluționale pe imaginile cu leziuni ale pielii, compararea mai multor metode de lucru cu seturi de date dezechilibrate, precum și munca noastră în aplicarea algoritmilor de învățare automată pentru crearea unui program optimizat de căutare și analiză a datelor medicale cu dimensiuni mari pentru identificarea riscului de fractură la pacienți. Se începe prin a prezenta abordarea noastră asupra sarcinii de clasificare a leziunilor cutanate. Accentul în stadiul actual al tehnicii a fost pe distingerea leziunilor cutanate maligne unele de altele, totuși, în lumea reală, clasa predominantă de leziuni este benignă. Astfel, pentru a crea un model care să poată oferi ajutor în cazul general, am optat pentru utilizarea setului de date HAM-10000 [TRK18], deoarece include și leziuni benigne. Acest lucru adaugă un alt strat de complexitate, deoarece leziunile benigne pot fi vizual foarte asemănătoare cu leziunile maligne. Apoi discutăm despre modelul pe care l-am selectat pentru sarcină și despre metodologia folosită pentru a aborda datele dezechilibrate din set. În continuare, discutăm rezultatele noastre (83,96% acuratețe) și le comparăm cu cele obținute în literatură. În continuare prezentăm munca depusă în colaborare cu medici specialiști din cadrul National Health System Scotland axată pe analiza datelor medicale anonimizate și extragerea de informații care ar putea fi folosite pentru a detecta automat pacienții cu risc ridicat de fracturi. Apoi prezentăm un program pe care l-am dezvoltat în paralel cu cercetarea noastră, care ajută la vizualizarea datelor pacienților.

3.3 Concluziile capitolului

În urma acestei cercetări, am introdus un model bazat pe arhitectura Inception-ResNet capabil să clasifice leziunile cutanate din imagini medicale. Acest lucru are un impact asupra dermatoscopia asistată de computer, crescând viabilitatea acesteia ca înlocuitor pentru procesul actual de diagnostic invaziv. De asemenea, am efectuat un studiu comparativ al efectului supraeșantionării aleatoare și metoda ADASYN asupra performanței modelului propus. Am ajuns la concluzia că ambele tehnici de supra-eșantionare îmbunătățesc performanța modelului, dar algoritmul ADASYN oferă un beneficiu mai mare, depășind lucrări similare prezentate în [RGBM17] (81,33%) și [MdS18] (78%).

Referitor la estimarea riscului de fracturi, am dezvoltat o aplicație demonstrativă

a conceptului care utilizează căutarea rapidă a datelor și prezentarea datelor pentru a ajuta deciziile clinice. Datele pacientului sunt preluate în mai puțin de două secunde. Într-o fază de cercetare ulterioară, după extinderea setului de date medicale, algoritmi de învățare automată pot fi antrenați pentru a identifica candidații pentru Fracture Liaison Service. Procesul clinic ar permite unui algoritm inteligent să ruleze periodic și să producă o listă de pacienți sortați în funcție de un scor de risc. Fișele medicale ale acelor pacienți pot fi apoi analizate de către un specialist folosind interfața dezvoltată care prezintă cele mai relevante informații medicale despre pacient. Astfel, ne propunem să reducem întârzierea de 6 săptămâni în identificarea pacientului care apare din cauza prelucrării manuale a datelor.

3.4 Sumarul contribuțiilor

- Introducem abordări noi ale clasificării leziunilor cutanate folosind învățare profundă (model bazat pe Inception-ResNet) și dermatoscopia, o tehnică de diagnostic neinvazivă. Un element de originalitate provine din includerea leziunilor benigne (prin setul de date HAM-10000 [TRK18]) în experimentele noastre, pentru a testa modelul nostru în condiții care sunt mai apropiate de situațiile din lumea reală. Am studiat impactul metodelor de eșantionare (supra-eșantionare simplă și ADASYN [HBAGL08]) pentru a gestiona seturile de date dezechilibrate [Mur19].
- Prezentăm o analiză a datelor medicale istorice care sunt legate de afecțiunile structurii osoase, date furnizate de National Health System Scotland care au fost anonimizate. Caracteristicile cu cel mai mare impact asupra riscului de fractură sunt izolate pentru a fi utilizate într-un model care poate estima automat acest risc [MMC⁺21].
- Introducem un program inedit, constituind o contribuție originală, care să fie folosit de echipa clinică pentru căutarea rapidă a istoricului medical pentru orice pacient, accelerând viteza cu care se pot selecta candidați buni pentru a fi înscriși în Fracture Liaison Service [MMC⁺21].

Capitolul 4

Învățare automată și viziune computerizată pentru educație colaborativă transdisciplinară

4.1 Contextul educației colaborative transdisciplinară

În acest capitol prezentăm rezultate care, deși nu aparțin investigației centrale a tezei, au demonstrat un mare potențial și au reprezentat o oportunitate de a transfera cunoștințele și înțelegerile dobândite în celelalte experimente și analize ale noastre. Pe lângă experimentele noastre privind aplicațiile tehnicilor de inteligență artificială pentru agricultură și asistență medicală, am urmărit să învățăm și să instruim studenți cum să integreze mai bine algoritmi de inteligență artificială în rezolvarea problemelor complexe din lumea reală. Majoritatea lucrărilor de ultimă oră se concentrează pe identificarea unor mici îmbunătățiri ale modelelor pe care le folosesc, totuși, calitatea datelor de antrenare/validare/testare este foarte importantă și este mult mai puțin abordată. Obținerea sau crearea unui set de date de înaltă calitate este un factor cheie în introducerea unui model performant, sarcină care poate fi consumatoare de timp și dificilă. În plus, învățarea automată și viziunea computerizată sunt aplicate împreună cu unul sau mai multe domenii, cum ar fi agricultura, medicina, științele sociale, fizica etc. Înțelegerea modului de măsurare a calității unui set de date este un aspect care necesită o înțelegere a domeniului în pe care urmează să fie utilizat modelul. Astfel, prezentăm un curs care încurajează studenții să abordeze problemele multidisciplinare ținând cont de informații din mai multe perspective, să recadreză aceste probleme ast-

fel încât să poată fi abordate folosind metode de inteligență artificială și să înțeleagă cum să analizeze, să modeleze și să proceseze datele care vin din alte domenii. Vom detalia structura cursului, ideile principale pe care ne propunem să le predăm, metoda de evaluare și feedback-ul pe care l-am primit după acest curs. Acest lucru nu servește doar ca mijloc de pregătire a viitoarelor generații de cercetători, ci și ca mijloc de a ne consolida propria înțelegere asupra abordărilor transdisciplinare și interdisciplinare ale rezolvării problemelor.

4.2 Detalii despre curs

Cursul combină mai multe tehnici din domeniul inteligenței artificiale cu cunoștințe de specialitate din domeniul schimbărilor climatice, solidificând aspectele multi și transdisciplinare ale cursului. O altă caracteristică nouă a cursului este abordarea modernă a învățării colaborative și experiențiale pentru studenți, profesori și specialiști externi. Metodologia de evaluare, reflectând și abordarea colaborativă, implică autoevaluare și interevaluare. Calitatea soluțiilor pentru problemele legate de schimbările climatice a fost legată de aplicarea tehnicilor multidisciplinare în crearea acestor soluții, cu toate acestea, gestionarea acestor metode este un factor cheie în probabilitatea obținerii unei soluții bune [BM19], astfel colaborarea și experimentarea joacă un rol important.

Proiectele au abordat teme precum: predicția secetei și inundațiilor, clasificarea și precizarea evoluției calității aerului, clasificarea fructelor și detectarea lor din imagini, detectarea animalelor din imagini, detectarea formațiunilor de furtună, monitorizarea defrișărilor, prognozarea apariției incendiilor din păduri, irigarea inteligentă a plantelor, monitorizarea automată a serelor, estimarea evoluției vremii și temperaturii, analiza metabolismului orașului, clasificarea caselor de îngrijire și a orfelinatelor în funcție de nevoi și priorități, monitorizarea consumului de energie electrică al gospodăriilor, prognoza stării traficului din marile orașe aplicată celor orașelor din Europa. Metodele aplicate includ LSTM, clusterizare K-Means, analiza componentelor principale, rețele neuronale (regresori, clasificatoare, cu și fără convoluții) precum DeepWeeds, Inception-v3, ResNet-50, Suport vector machines, Random forest. Toate echipele au putut să obțină date adecvate de instruire și testare folosind site-uri web precum Kaggle, Google Datasets sau contactând autorii seturi de date care nu sunt liber accesibile. În plus, toate echipele au reușit să configureze conducte pentru instruire, validare și testare a modelelor alese, obținând rezultate explicabile.

4.3 Concluziile capitolului

Abordarea cursului introdus a fost nouă în contextul facultății și a reprezentat o experiență nouă pentru studenți. Feedback-ul lor și interesul manifestat de invitații externi indică faptul că metodele ar putea obține un succes și mai mare în iterațiile viitoare. În măsura cunoștințelor noastre, această metodă de predare a cursurilor este unică în facultățile de informatică din România. La nivel internațional, această metodă a fost văzută în cursuri precum „AI for Social Good” de la Universitatea Stanford, „Climate Change and AI” de la Universitatea din Oxford și „AI for the Study of Environmental Risks” de la Universitatea din Cambridge. .

4.4 Sumarul contribuțiilor

- Am introdus un nou curs axat pe o varietate de tehnici de inteligență artificială (cum ar fi ML și învățare profundă) aplicate la subiecte care necesită cunoștințe din alte discipline precum fizica, biologia sau chimia. Contribuția originală constă în colaborarea cu mai mulți specialiști externi pentru organizarea de prelegeri cu scopul de a prezenta o perspectivă diferită asupra problemelor abordate de studenții înscriși [CCM22].

Capitolul 5

Concluzii

Am studiat și aplicat câteva modele de învățare profundă bazate pe arhitecturi precum VGG [SZ14], Residual Network [HZRS15] și SSD [LAE⁺15] și le-am aplicat sarcinii de clasificare și detecție a fructelor pe baza imagini realizate în medii de livezi și plantații. Am abordat problema majoră a deficitului de date în domeniul agriculturii inteligente prin introducerea setului de date Fruits-360 [OMa, OMb] care conține 131 tipuri de fructe care totalizează 90483 imagini în scopul clasificării. Am extins capacitatea de utilizare a setului de date prin adăugarea unui algoritm care generează imagini sintetice de fructe și adnotări cu casete de delimitare, care este potrivit pentru sarcinile de detecție. Am introdus un model bazat pe arhitectura SSD pentru detectarea merelor din imagini antrenate exclusiv pe imagini sintetice și testate pe imagini din lumea reală. Performanța obținută a fost similară cu lucrări recente care au folosit doar imagini din lumea reală. Metodele noastre propuse au fost validate de publicații în conferințe internaționale, demonstrând că abordarea noastră este utilă și de interes atât pentru inteligența artificială, cât și pentru comunitățile din agricultură inteligentă.

În ceea ce privește rezultatele noastre, am revizuit și agregat multiple lucrări de ultimă oră în domeniul detectării fructelor și identificării bolilor frunzelor pentru o mai bună înțelegere a provocărilor existente în acest domeniu. Recenziile noastre au fost publicate în [MCC20a, MCC20b]. Am introdus setul de date Fruit-360 și am stabilit o performanță de bază pentru clasificatoare folosind un model bazat pe arhitectura VGG16, care a fost publicat în [MO18]. Apoi, am introdus o metodă de generare a imaginilor de fructe sintetice cu casete de delimitare adnotate pentru detecție, am testat performanța care poate fi obținută utilizând numai date sintetice pentru antrenament și am obținut rezultate în același interval de performanță ca proiectele care utilizează exclusiv lumea reală. date. Am publicat aceste rezultate în [Mur22].

Munca noastră viitoare se va concentra pe rafinarea în continuare a algoritmului de generare a datelor pentru a crea imagini cu aspect mai natural care ar putea îmbunătăți și mai mult performanța detectorilor antrenați. O posibilitate este utilizarea rețelelor generative adversare antrenate pe imaginile fructelor din setul de date Fruits-360 și aplicate pe imagini cu fundal asemănător unei livezi.

Pentru domeniul diagnozei medicale, am prezentat un model bazat pe Inception-ResNet [SIV16] capabil să clasifice șapte tipuri de leziuni cutanate din imagini medicale. Am analizat impactul aplicării algoritmilor de supra-eșantionare pe seturile de date de imagine asupra performanței clasificatorilor antrenați. Am abordat, de asemenea, problema estimării riscului de osteoporoză și apariția fracturilor de fragilitate folosind mai mulți algoritmi de învățare automată pe datele furnizate de NHS Scotland. Metodele noastre propuse au fost validate de publicații în conferințe internaționale, demonstrând că abordarea noastră este utilă și de interes pentru învățarea automată și comunitățile medicale.

Rezultatele legate de clasificarea leziunilor cutanate au fost publicate în [Mur19]. Am arătat că prin utilizarea unei metode de eșantionare sintetică adaptivă pe imaginile cu leziuni cutanate, performanța clasificatorului se îmbunătățește, obținând în același timp rezultate mai bune decât lucrările anterioare de ultimă generație. Pentru evaluarea riscului de osteoporoză am aplicat algoritmi de învățare automată pentru a selecta un subset al tuturor caracteristicilor colectate de specialiștii medicali și pentru a identifica modele într-un volum mare de date. De asemenea, am implementat un algoritm de căutare rapidă a datelor care ajută personalul medical să consulte datele istorice ale pacientului. Aceste rezultate au fost publicate în [MMC⁺21].

În viitor, intenționăm să extindem cercetarea prin integrarea analizei texturii în sarcina de clasificare a leziunii și să studiem impactul acestei adăugări atunci când încercăm să separăm melanom și nevi melanocitari. Pentru estimarea riscului de osteoporoză, ne vom concentra pe selectarea unui subset de caracteristici care nu sunt puternic corelate între ele și ne vom proiecta un model de inteligență artificială care poate calcula un scor de risc pentru a ajuta clinicienii. Pentru aceasta, totuși, depindem de mai multe date medicale care trebuie furnizate pentru a crea un set de antrenament solid.

Bibliography

- [BKSD10] Marlies Baeten, Eva Kyndt, Katrien Struyven, and Filip Dochy. Using student-centred learning environments to stimulate deep approaches to learning: Factors encouraging or discouraging their effectiveness. *Educational Research Review*, 5(3):243–260, 2010.
- [BM19] Lino Briguglio and Stefano Moncada. The benefits and downsides of multidisciplinary education relating to climate change. *Climate Change and the Role of Education*, pages 169–187, 2019.
- [CCM22] Adriana Mihaela Coroiu, Alina Delia Călin, and Horea-Bogdan Mureșan. Collaborative transdisciplinary educational approaches in ai. In *International Conference on Computer Supported Education CSEDU (2)*, pages 260–267, 2022.
- [CCM23] Alina Delia Călin, Adriana Mihaela Coroiu, and Horea Bogdan Mureșan. Analysis of preprocessing techniques for missing data in the prediction of sunflower yield in response to the effects of climate change. *Applied Sciences*, 13(13), 2023.
- [CSD⁺17] Steven W Chen, Shreyas S Shivakumar, Sandeep Dcunha, Jnaneshwar Das, Edidiong Okon, Chao Qu, Camillo J Taylor, and Vijay Kumar. Counting apples and oranges with deep learning: A data-driven approach. *IEEE Robotics and Automation Letters*, 2(2):781–788, 2017.
- [EC19] Ngozi Clara Eli-Chukwu. Applications of artificial intelligence in agriculture: A review. *Engineering, Technology & Applied Science Research*, 9(4):4377–4383, 2019.

BIBLIOGRAPHY

- [HBAGL08] Haibo He, Yang Bai, Edwardo A. Garcia, and Shutao Li. Adasyn: Adaptive synthetic sampling approach for imbalanced learning. In *IJCNN*, pages 1322 – 1328, 07 2008.
- [HZRS15] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. *CoRR*, abs/1512.03385, 2015.
- [JHB19] F Jakjoud, A Hatim, and A Bouaaddi. Deep learning application for plant diseases detection. In *Proceedings of the 4th International Conference on Big Data and Internet of Things*, pages 1–6, 2019.
- [KBB⁺21] Nithin Kolanu, A Shane Brown, Amanda Beech, Jacqueline R Center, and Christopher P White. Natural language processing of radiology reports for the identification of patients with fracture. *Archives of Osteoporosis*, 16(1):1–8, 2021.
- [LAE⁺15] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott E. Reed, Cheng-Yang Fu, and Alexander C. Berg. SSD: single shot multibox detector. *CoRR*, abs/1512.02325, 2015.
- [LZHL18] Bin Liu, Yun Zhang, DongJian He, and Yuxiang Li. Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, 10(1):11, 2018.
- [MCC20a] Horea-Bogdan Mureșan, Alina Delia Călin, and Adriana Mihaela Coroiu. Overview of recent deep learning methods applied in fruit counting for yield estimation. *Studia Universitatis Babeș-Bolyai Informatica*, 65(2):50–65, 2020.
- [MCC20b] Horea-Bogdan Mureșan, Adriana Mihaela Coroiu, and Alina Delia Călin. Detecting leaf plant diseases using deep learning: A review. In *2020 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, pages 1–6, 2020.
- [MdS18] Danilo Barros Mendes and Nilton Correia da Silva. Skin lesions classification using convolutional neural networks in clinical images. *CoRR*, abs/1812.02316, 2018.
- [MLM⁺20] Shihan Mao, Yuhua Li, You Ma, Baohua Zhang, Jun Zhou, and Kai Wang. Automatic cucumber recognition algorithm for harvesting robots in the

- natural environment using deep learning and multi-feature fusion. *Computers and Electronics in Agriculture*, 170:105254, 2020.
- [MMC⁺21] Alexandru-Ion Marinescu, Horea-Bogdan Mureşan, Alina-Delia Călin, Adriana-Mihaela Coroiu, and Maria Talla. Freida - fracture risk evaluation using highly efficient information retrieval and analysis of large healthcare datasets. In *2021 IEEE International Conference on Big Data (Big Data)*, pages 3917–3922, 2021.
- [MO18] Horea Mureşan and Mihai Oltean. Fruit recognition from images using deep learning. *Acta Universitatis Sapientiae, Informatica*, 10(1):26 – 42, 2018.
- [Mur19] Horea-Bogdan Mureşan. Skin lesion diagnosis using deep learning. In *2019 IEEE 15th International Conference on Intelligent Computer Communication and Processing (ICCP)*, pages 499–506, 2019.
- [Mur22] Horea-Bogdan Mureşan. An automated algorithm for fruit image dataset building. In *2022 17th Conference on Computer Science and Intelligence Systems (FedCSIS)*, pages 103–107, 2022.
- [OMa] Mihai Oltean and Horea Muresan. Fruits 360 dataset on github. <https://github.com/Horea94/Fruit-Images-Dataset>. [Online; accessed 15.06.2021].
- [OMb] Mihai Oltean and Horea Muresan. Fruits 360 dataset on kaggle. <https://www.kaggle.com/moltean/fruits>. [Online; accessed 15.06.2021].
- [RGBM17] A. Romero Lopez, X. Giro-i-Nieto, J. Burdick, and O. Marques. Skin lesion classification from dermoscopic images using deep learning techniques. In *2017 13th IASTED International Conference on Biomedical Engineering (BioMed)*, pages 49–54, Feb 2017.
- [RIZ⁺17] Pranav Rajpurkar, Jeremy Irvin, Kaylie Zhu, Brandon Yang, Hershel Mehta, Tony Duan, Daisy Ding, Aarti Bagul, Curtis Langlotz, Katie Shpanskaya, Matthew P. Lungren, and Andrew Y. Ng. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *CoRR*, abs/1711.05225, 2017.
- [RvKF12] Dirk J Ruiter, Marlieke TR van Kesteren, and Guillen Fernandez. How to achieve synergy between medical education and cognitive neuroscience?

- an exercise on prior knowledge in understanding. *Advances in health sciences education*, 17(2):225–240, 2012.
- [SIV16] Christian Szegedy, Sergey Ioffe, and Vincent Vanhoucke. Inception-v4, inception-resnet and the impact of residual connections on learning. *CoRR*, abs/1602.07261, 2016.
- [SZ14] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556, 2014.
- [TRK18] Philipp Tschandl, Cliff Rosendahl, and Harald Kittler. The HAM10000 dataset: A large collection of multi-source dermatoscopic images of common pigmented skin lesions. *CoRR*, abs/1803.10417, 2018.
- [XWL⁺19] Qian Xiang, Xiaodan Wang, Rui Li, Guoling Zhang, Jie Lai, and Qingshuang Hu. Fruit image classification based on mobilenetv2 with transfer learning technique. In *Proceedings of the 3rd International Conference on Computer Science and Application Engineering*, pages 1–7, 2019.
- [YWBZ19] Rongjian Yang, Minghui Wu, Zhaohua Bao, and Pei Zhang. Cherry recognition based on color channel transform. In *Proceedings of the 2019 International Conference on Artificial Intelligence and Computer Science*, pages 292–296, 2019.