Catalina-Manuela Daraban

Digitally signed by Catalina-Manuela Daraban
Date: 2025.02.11 11:51:56 +02'00'

Universitatea Națională de Știință și Tehnologie Politehnica București

Școala Doctorală de Electronică, Telecomunicații și Tehnologia Informației

Decizie nr. 303 din 17-01-2025

REZUMAT TEZĂ DE DOCTORAT

Ing. Dumitru ABRUDAN

APLICAȚII ALE MORFOLOGIEI MATEMATICE ÎN RECUNOAȘTEREA FORMELOR

COMISIA DE DOCTORAT

Prof. dr. Ing. Florin DRĂGHICI UNSTPB	Președinte
Prof. dr. Ing. Mihai CIUC UNSTPB	Conducător de doctorat
Prof. dr. Ing. Romulus TEREBEȘ Universitatea Tehnică din Cluj	Referent
Prof. dr. Ing. Cristian GRAVA Universitatea din Oradea	Referent
Prof. dr. Ing. Ioana MARCU UNSTPB	Referent

BUCUREȘTI 2025

Cuprins

Cuprins ..... **iii**
Capitolul 1 ..... **1**
Introducere **1**
Prezentarea domeniului tezei de doctorat 1
Scopul tezei de doctorat 2
Conținutul tezei de doctorat 2
Capitolul 2 ..... **4**
Algoritmi de detecție a formelor din imagini **4**
2.1 Algoritmul de detecție Viola–Jones 4
2.1.1. Descrierea și funcționalitatea algoritmului Viola-Jones 4
2.1.2. Cazuri de utilizare și evaluarea performanțelor algoritmului 5
2.2. Algoritmul de detecție *Aggregate Channel Features* (ACF) 5
2.2.1. Modalități de implementare a algoritmului ACF 5
2.2.2. Aplicabilitatea și evaluarea performanțelor algoritmului ACF 6
2.3. Operatorii morfologiei matematice (MMO) 6
2.3.1 Operații de bază ale morfologicei matematice: eroziunea și dilatarea 7
2.3.2 Operatori combinați ai morfologicei matematice: deschiderea și închiderea 7
2.4. Analiza comparativă a algoritmilor de detecție a obiectelor 7
2.4.1. Detecția formelor prin metode convenționale 8
2.5. Aplicații ale algoritmilor de detecție a formelor în analiza imaginilor 8
2.5.1. Studiu de caz: recunoașterea facială și purtarea măștii în pandemie 9
2.5.2. Studiu de caz: reducerea consumului de combustibil în aviația comercială 9
2.5.3. Concluzii privind aplicațiile propuse pentru detecția formelor din imagini 9
Capitolul 3 ..... **10**
Tehnici de filtrare a zgomotului din imagini **10**
3.1 Filtrarea neliniară 10
3.1.1. Filtrarea mediană 10
3.1.2. Filtrarea bilaterală 11
3.1.3. Filtrarea bazată pe morfologia matematică 11
3.2. Filtrarea liniară 12
3.2.1. Filtrarea prin mediere 12
3.2.2. Filtrare cu filtrul cu caracteristică de tip Gauss 12

3.2.3. Filtrarea Wiener 12
3.3. Criterii de evaluare a filtrelor în prelucrarea imaginilor 13
3.4. Implementare practică a filtrului MM în prelucrarea de imagini 13
3.4.1. Detecția nodurilor din lemnul de pin folosind filtre MM și RGB 13
3.4.2. Concluzii privind eficiența filtrului MM în studiul de caz propus 13
Capitolul 4 14
Contribuții la optimizarea soluțiilor de prelucrare a imaginilor prin integrarea MMO și CNN 14
4.1 Aspecte introductive legate de algoritmii de tip DL 14
4.2 Rețelele Neuronale Convoluționale (CNN) 14
4.3 VGG16 și VGG19: implementare, avantaje și dezavantaje 15
4.4 Fuziune practică a MMO și CNN: studii de caz 15
4.4.1. Detecția simbolurilor matematice scrise de mână afectate de zgomot 15
4.4.2. Recunoașterea literelor scrise de mână 16
4.4.3. Producerea de imagini sintetizate cu algoritm de augmentare 17
4.4.4. Determinarea modelelor de ambarcațiuni utilizând MMO și CNN 17
4.4.5. Optimizarea seturilor de date folosind tehnici MM 17
4.4.6. Evaluarea defectelor structurale induse de cutremur 18
4.4.7 Baza de date TRIB Crack: instrument util pentru detecția automată a fisurilor din infrastructura rutieră 18
Capitolul 5 i
Concluzii i
5.1 REZULTATE OBȚINUTE i
5.2 CONTRIBUȚII PERSONALE ii
5.3 LISTA LUCRĂRILOR ORIGINALE iii
5.4 PERSPECTIVE DE DEZVOLTARE ULTERIOARĂ v

Capitolul 1

Introducere

Prelucrarea imaginilor este un domeniu de cercetare permanent relevant, cu o importanță deosebită în diverse sectoare de activitate, precum sănătate, construcții și agricultură. Obiectivele procesării imaginilor includ identificarea și clasificarea formelor (de exemplu, oameni, obiecte, structuri), evidențierea sau ascunderea unor caracteristici ale formelor din imagini și minimizarea zgomotului introdus de metodele de achiziție sau defectele echipamentelor de achiziție a imaginilor.

Printre algoritmii proiectați pentru recunoașterea formelor în imagini se regăsesc algoritmi pentru detecția fețelor (atât în imagini statice, cât și în cele dinamice) și algoritmi de detecție a obiectelor (prin realizarea de operații de conturare și netezire a marginilor, de mărire și micșorare a anumitor zone din imaginile prelucrate). Precizia acestor algoritmi este crucială în domeniul medical (de ex., în imagistica medicală identificarea corectă a formelor permite diagnosticarea corectă a pacienților), în domeniul pazei și protecției persoanelor civile (de ex., în anumite perimetre aglomerate, detecția cu precizie a fețelor permite mai ușor identificarea oamenilor care comit infracțiuni), etc. Acuratețea tehnicilor de recunoaștere a formelor din imagini poate fi compromisă de zgomotul introdus în imagini, având ca efect nedorit distorsionarea informațiilor în imaginile digitale.

În acest context, contribuția personală la această activitate de cercetare constă în demonstrarea utilității și eficienței metodei bazate pe utilizarea operatorilor morfologiei matematice în recunoașterea formelor și eliminarea zgomotului din imagini. Operatorii de bază ai morfologiei matematice (MMO) sunt eroziunea și dilatarea și sunt utilizați pentru recunoașterea formelor, iar operatorii combinați ai morfologiei matematice (deschiderea și închiderea) se aplică pentru reducerea/eliminarea zgomotului din imagini.

Prezentarea domeniului tezei de doctorat

Procesarea digitală a imaginilor reprezintă procedeul prin care informații relevante sunt extrase din imagini utilizând diferite tipuri de metode. Astfel, un algoritm proiectat pentru prelucrarea digitală are ca date de intrare o imagine digitală, iar ieșirea poate fi o imagine digitală, anumite caracteristici ale imaginii/din imagine sau o versiune rafinată a imaginii de intrare. Din punctul de vedere al obiectivului final, procedeele de prelucrare digitală a

imaginilor conduc la obținerea unor imagini cu calități semnificativ îmbunătățite. Printre aceste tehnici pot fi enumerate *netezirea marginilor* sau *adăugarea de culori*.

Prelucrarea imaginilor (indiferent de scenariul de utilizare) este dependentă de metoda de achiziție a imaginilor, achiziție ce poate fi realizată cu ajutorul camerelor digitale, scanerelor sau aceste imagini pot fi obținute prin transferarea lor între diverse dispozitive la anumite locații țintă. Precizia acestor metode diferă și, ca urmare, imaginile digitale pot fi afectate de diferite tipuri de zgomot. O clasificare generală a acestora le definește ca: *zgomot de impuls*, *fotoelectronic* și *structurat*.

Scopul tezei de doctorat

Aplicarea tehnicilor de detecție a formelor (obiecte, oameni, animale, etc.) din imagini are o importanță deosebită în domenii precum imagistica medicală, controlul traficului aerian și terestru, detecția fraudelor, securitate (de ex. recunoașterea facială).

Întrucât calitatea unei imagini ce urmează a fi prelucrată depinde de zgomotul ce se suprapune peste ea în timpul realizării acesteia, diferite metode de filtrare a acestui zgomot (tehnici de filtrare liniară, neliniară, etc.) pot conduce la rezultate acceptabile. Deși anumite metode moderne implică cu precădere operații de filtrare efectuate pixel cu pixel, în urma revizuirii abordărilor existente, este evident că o soluție autonomă care să elimine cerința de inspecție vizuală de către un operator uman este o necesitate. Astfel, utilizarea unor combinații de metode de detecție a formelor împreună cu algoritmi DL poate reprezenta o soluție pentru eficientizarea procesului de prelucrare a imaginilor din punctul de vedere al interacțiunii umane (prin minimizarea prezenței acesteia), a intervalului de timp necesar pentru obținerea rezultatelor (prin minimizarea acestuia) și, implicit, a intervalului de timp de luarea a unor decizii pe baza rezultatelor obținute.

Conținutul tezei de doctorat

Activitatea doctorală a avut ca tematică principală studiul și analiza practică a unor "Aplicații ale Morfologiei Matematice în Recunoașterea Formelor". Etapele pentru îndeplinirea cu succes a obiectivelor s-au axat atât pe studiul aspectelor teoretice, cât și pe implementarea practică a operatorilor morfologiei matematice în diferite cazuri de utilizare pentru recunoașterea formelor, extragerea unor caracteristici și eliminarea zgomotului de tip impuls din imaginile analizate.

În cadrul **Capitolului 1** este prezentată o scurtă, dar cuprinzătoare, introducere în domeniul prelucrării imaginilor, accentul punându-se pe detecția formelor. Sunt amintite metodele tradiționale utilizate (algoritmul Viola-Jones, detectorul HOG și modelul DPM), dar și metodele moderne (rețelele CNN, algoritmul YOLO și operatorii morfologiei). Sunt enunțate domeniile de aplicabilitate practică pentru aceste metode

(perimetrele aeroporturilor, zonele de conflict, zonele de frontieră, etc.), fiind astfel definite raționamentele ce au stat la baza alegerii acestei activități de cercetare doctorală.

Capitolul 2 ilustrează detaliat metodele tradiționale și actuale de detecție a formelor pentru fiecare dintre metodele descrise anterior (algoritmii Viola-Jones, Aggregate Channel Features (ACF) și MMO), fiind indicate modalitățile de implementare, cazurile de utilizare și evaluarea performanțelor. În ultimul subcapitol sunt evidențiate rezultatele experimentale obținute folosind cele trei metode pentru: identificarea fețelor, ochilor și măștilor purtate de oameni în timpul pandemiei de COVID-19, precum și estimarea greutății pasagerilor de la bordul unei aeronave pe baza contururilor corporale pentru reducerea consumului de combustibil în aviația comercială. Anumite concluzii legate de performanțele acestor algoritmi se regăsesc la finalul capitolului.

Întrucât achiziția imaginilor poate fi afectată de zgomot ce se suprapune peste acestea, în **Capitolul 3** sunt descrise tehnicile de eliminare a zgomotului din imagini: filtrare neliniară și filtrare liniară. Operatorii morfologici matematici sunt prezentați în categoria filtrării neliniare, iar o analiză comparativă a tuturor tehnicilor de eliminare a zgomotului din imagini este evidențiată în acest capitol. Validarea eficienței utilizării MMO în scopul filtrării zgomotului este obținută într-un scenariu propriu ce presupune detecția defectelor în lemnul de pin, iar MMO sunt utilizați atât pentru eliminarea zgomotelor, cât și pentru și identificarea nodurilor existente. Zgomotul de tip impuls considerat în experimente este zgomotul de tip „*sare și piper*”. Pe baza rezultatelor experimentale, a fost realizată o analiză sumativă privind eficiența operatorilor morfologici și identificarea nevoilor de validare a acestora într-o abordare agregată cu tehnicile moderne de prelucrare a imaginilor (rețelele neuronale convoluționale).

Capitolul 4 conține modalitățile de validare a performanțelor MMO prin fuziune cu CNN. Sunt detaliate aspectele principale legate de algoritmii VGG16, VGG19 și rețele de tip CNN: descriere, avantaje și dezavantaje în funcție de domeniile de aplicabilitate. Ultima parte a capitolului ilustrează cazurile de utilizare în care a fost dovedită eficiența acestei abordări, aceste studii de caz incluzând: detecția simbolurilor matematice scrise de mână afectate de zgomot și, ulterior, detecția literelor scrise de mână, obținerea de imagini sintetizate folosind un algoritm de augmentare bazat pe model, identificarea corectă a unui modelul de ambarcațiune utilizând o bază de date și abordarea defectelor structurale cauzate de cutremure în lucrările civile. Este introdusă în cercetare și o nouă bază de date proprie TRIB Crack cu imagini ce conțin fisuri din infrastructura rutieră. Aceste imagini sunt prelucrate pentru a demonstra utilitatea acestui studiu în managementul infrastructurilor rutiere.

În ultimul capitol, **Capitolul 5**, sunt sintetizate principalele rezultate obținute împreună cu contribuțiile proprii și este prezentată o listă a lucrărilor originale publicate pe parcursul activității de cercetare doctorală. În cele din urmă, pe baza rezultatelor obținute în activitatea de cercetare doctorală sunt enunțate perspectivele de dezvoltare ulterioară în domeniul prelucrării imaginilor (într-un program de studii postdoctorale).

Capitolul 2

Algoritmi de detecție a formelor din imagini

Tehnicile de prelucrare a imaginilor pot fi utilizate pentru identificarea și clasificarea formelor detectate în imagini în vederea oferirii unor informații ce pot fi ulterior folosite în diferite scopuri în funcție de domeniul de aplicabilitate.

În urma studiilor realizate, au fost enunțate anumite concluzii legate de eficiența utilizării celor trei metode în identificarea diferitelor forme din imagini. În plus, sunt realizate comparații cu cercetări similare în domeniu și sunt evidențiate punctele forte și limitările abordării propuse în cadrul scenariului prezentat.

2.1 Algoritmul de detecție Viola–Jones

Algoritmul Viola-Jones este un algoritm de tip „învățare automată" (ML) conceput inițial pentru a detecta anumite regiuni ale feței umane, cum ar fi ochii, gura și nasul [1]. Deși acest algoritm oferă o precizie mai mică de recunoaștere a feței în comparație cu tehnicile recente bazate pe rețele CNN, acesta încă are avantajul de a rula eficient pe dispozitivele cu resurse limitate.

2.1.1. Descrierea și funcționalitatea algoritmului Viola-Jones

Algoritmul Viola-Jones a fost inițial dezvoltat pentru detecția fețelor, dar – ulterior- a fost antrenat să ajute la recunoașterea - din imagini- a diferitor tipuri de obiecte. Viteza de operare și precizia deosebite sunt avantaje ale algoritmului Viola-Jones datorate celor patru etape de realizare.

2.1.2. Cazuri de utilizare și evaluarea performanțelor algoritmului

O serie de aplicații au fost dezvoltate utilizând algoritmul Viola-Jones, acestea putând fi folosite cu succes pentru detecția formelor (față, obiecte, sisteme de securitate, elemente ce țin de siguranță rutieră, etc.).

Algoritmul Viola-Jones s-a dovedit eficient, de asemenea, în detecția în timp real a formelor. Prin folosirea unei abordări modulare a imaginii integrale, detecția feței în fluxurile video a fost optimizată pentru a îndeplini cerințele de procesare în timp real a cel puțin 30 de cadre pe secundă [2].

2.2. Algoritmul de detecție *Aggregate Channel Features* (ACF)

Algoritmul de detecție ACF a fost dezvoltat pentru a detecta obiecte mai degrabă rigide (de ex. pietoni, vehicule, fețe, etc.). Cu 30 de cadre pe secundă pentru un singur nucleu, detectorul ACF este un detector cu fereastră glisantă, rapid și eficient. Prin comparație cu detectorul Viola-Jones, acesta oferă o reducere de aproximativ 1000 de ori a valorilor false pozitive, menținând în același timp aceeași rată de detecție [3]. ACF evaluează caracteristici sub formă de valori de pixeli, necalculând sume dreptunghiulare.

2.2.1. Modalități de implementare a algoritmului ACF

Structura din Figura 2.11 ilustrează pașii de implementare a algoritmului de detecție ACF, iar aceștia sunt detaliați în continuare [3]-[5]:

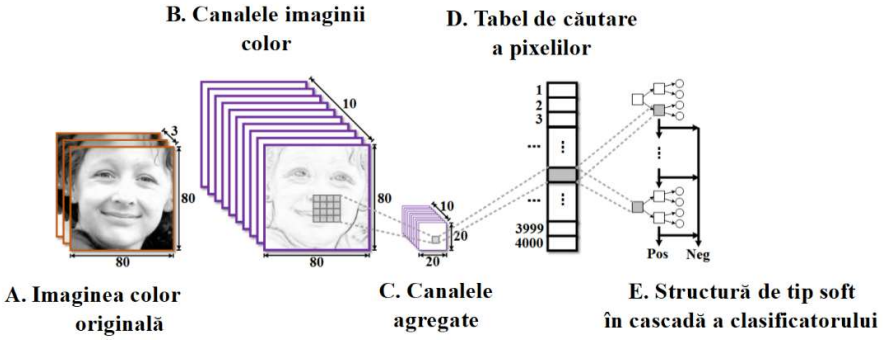


Figura 2.11 *Diagrama procesului de calcul ACF* [5]

2.2.2. Aplicabilitatea și evaluarea performanțelor algoritmului ACF

Aplicabilitatea ACF este variată, cuprinzând cazuri de utilizare precum detecția unui semafor pe timp de noapte [7], a autovehiculelor și pietonilor [8],[9], detecția aeronavelor în imagini satelitare [10], identificarea obiectelor în ecografii [11], etc.

Detecția corpului uman, nu numai a feței, este importantă în cazul pietonilor, a persoanelor rătăcite pe munte sau căzute din diverse motive (accidentate, persoane cu diverse afecțiuni medicale, etc.).

2.3. Operatorii morfologiei matematice (MMO)

Morfologia matematică este o tehnică de recunoaștere optimă a formelor din imagini, dar și filtrare a zgomotului din imagini în vederea îmbunătățirii calității acesteia. Etimologia cuvântului morfologie provine de la *formă* (*morpho* în limba greacă antică) și *cercetare* (*logos* în limba greacă antică).

Operațiile morfologice clasice folosesc un *element structurant* static (SE - Structuring Element) aplicat în mod consecvent în imagine. Această abordare poate fi suboptimă, determinând evoluția către filtrarea morfologică adaptivă care ajustează elementul de structurant pentru fiecare punct individual al imaginii analizate. SE este o matrice binară de dimensiuni reduse care respectă următoarele condiții: mărimea matricei definește dimensiunile SE; dispunerea elementelor de unu și zerouri îi determină forma, iar originea este -de obicei- un pixel în interiorul sau exteriorul matricei. Cele mai utilizate forme ale SE sunt ilustrate în Figura 2.15 [12]-[15].



Figura 2.15 *Modele diferite ale elementelor structurante* [13]

Formele elementelor structurante pot fi personalizate pentru a se potrivi cu formele semnalelor procesate.

2.3.1 Operații de bază ale morfologicei matematice: eroziunea și dilatarea

Eroziunea este operatorul morfologiei matematice prin care obiectele dintr-o imagine binară sunt reduse sau eliminate. În majoritatea aplicațiilor, această operație este însoțită de operatorul ***Dilatare***.

Din punct de vedere matematic, operațiile morfologicei pot fi scrise pe baza teoriei mulțimilor, mulțimile fiind formate din totalitatea punctelor ce descriu imaginea: fundal și prim-plan.

2.3.2 Operatori combinați ai morfologicei matematice: deschiderea și închiderea

Operatorii *deschidere* și *închidere morfologică* folosesc o combinație de operații morfologice de bază, dar în ordine diferită, obținând astfel rezultate diferite.

Operatorul *deschidere morfologică* constă în efectuarea procedeului de eroziune urmat de procedeul de dilatare. Efectul asupra obiectelor este de a le rafina limitele, de a separa conexiunile înguste (indicate cu săgeată în Figura 2.18) și a elimina prelungirile subțiri (cercul din Figura 2.18). Invers, operatorul *închidere morfologică* constă în efectuarea procedeului de dilatare urmat de eroziune (Figura 2.19). Pentru fiecare dintre cele două figuri, imaginea originală este cea din stânga, iar cea prelucrată cu operatorii morfologiei este cea din dreapta [16].

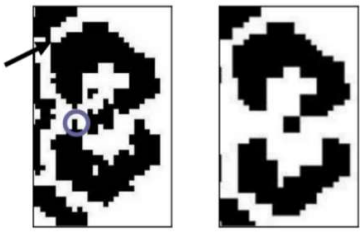


Figura 2.18 *MMO deschidere* [16]

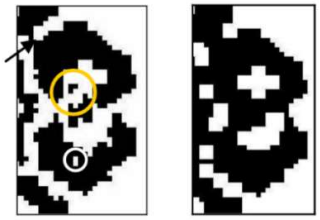


Figura 2.19 *MMO închidere* [16]

2.4. Analiza comparativă a algoritmilor de detecție a obiectelor

Detecția obiectelor se referă la identificarea precisă a unui obiect sau mai multor obiecte specifice dintr-o imagine, obiecte ce pot fi caracterizate prin specificații bine definite și distincte. Calitatea imaginii este crucială pentru analiza bazei de date deoarece

mediile de captare a imaginilor pot introduce elemente care pot afecta negativ acuratețea detecției obiectelor (umbre, efecte de ceață, etc.). Alte aspecte ce pot influența negativ detecția în imagini, pot fi unghiurile de realizare a imaginilor, diverse ocluzii parțiale sau totale ale unui obiect de către alte obiecte, etc.

2.4.1. Detecția formelor prin metode convenționale

Figura 2.20 prezintă o varietate de algoritmi convenționali pentru detecția formelor precum Viola-Jones, Canny Edge Detection, Speeded Up Robust Features (SURF), HOG, iar Tabelul 2.1 oferă elemente cheie folosite în cazul abordării convenționale în procesul de detecție a obiectelor.

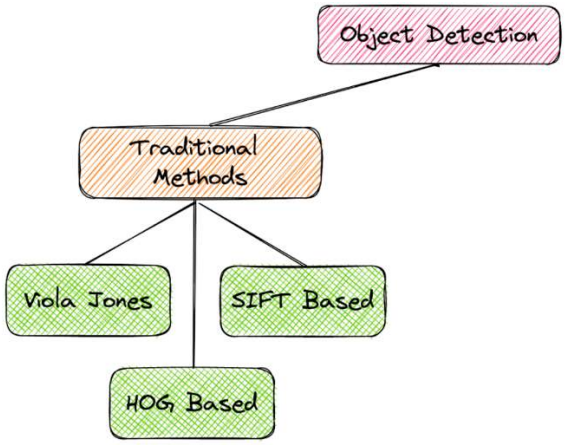


Figura 2.20 *Algoritmi convenționali de detecție a obiectelor* [17]

2.5. Aplicații ale algoritmilor de detecție a formelor în analiza imaginilor

Având în vedere rezultatele deosebite obținute în cercetări anterioare cu algoritmii Viola-Jones, ACF și MMO, scopul activității de cercetare prezentată în [PR1] l-a reprezentat detecția purtării pe față a unei măști conforme folosind algoritmii Viola Jones și ACF, precum și MMO. În timp ce majoritatea studiilor anterioare s-au concentrat pe compararea eficienței algoritmilor de detecție Viola-Jones și ACF, *această aplicație introduce o abordare inovativă* care integrează în mod unic trei tehnici distincte (Viola-Jones, ACF și MMO), fiecare servind unui scop precis, demonstrând totuși în mod colectiv o eficacitate deosebită.

2.5.1. Studiu de caz: recunoașterea facială și purtarea măștii în pandemie

Metodologia inovatoare propusă în acest caz a segmentat în faze distincte cerințele aplicației: detecția fețelor într-o fază, verificarea prezenței măștilor pe fețele detectate în altă fază și detecția purtării corecte sau incorecte a măștilor într-o fază distinctă. Această abordare secvențială a avut ca scop creșterea eficienței generale și reducerea erorilor rezultate din prelucrarea imaginilor.

2.5.2. Studiu de caz: reducerea consumului de combustibil în aviația comercială

Analiza în domeniul morfologiei matematice a continuat cu un alt scenariu, motivat fiind de cercetările existente care indică o corelație puternică între consumul de combustibil al unei aeronave, emisiile de carbon și greutatea pasagerilor.

Uzual, pentru a determina cu precizie greutatea unui pasager, se face o cântărire individuală întrucât supraestimarea greutății acestora se transpune în transportul de combustibil suplimentar, ceea ce adaugă greutate aeronavei, care -la rândul său- consumă mai mult combustibil pentru a-și susține propria greutate. Abordarea acestui neajuns este prezentată în cadrul metodei propuse în [PR2].

2.5.3. Concluzii privind aplicațiile propuse pentru detecția formelor din imagini

Cazurile de utilizare prezentate în acest capitol sunt rezultate ale activității de cercetare doctorală în cadrul căreia au fost testați doar operatorii morfologicei matematice de bază (eroziunea și dilatarea). Rezultatele obținute sunt promițătoare și au fost validate de comunitatea științifică, fiind în prezent publicate în [PR1] și [PR2]. Pe baza acestora, se deschid noi oportunități de cercetare în vastul domeniu al prelucrări de imagini. Astfel, vor fi prezentate în continuare concluziile rezultate în urma cercetărilor efectuate.

Capitolul 3

Tehnici de filtrare a zgomotului din imagini

Progresele în dezvoltarea și optimizarea metodelor de achiziție a imaginilor digitale au condus la apariția a numeroase aplicații axate pe prelucrarea digitală a imaginilor. Zgomotul din imaginile digitale poate fi definit ca date suplimentare nedorite care distorsionează caracteristicile inerente ale imaginii. Acesta apare fie de la senzorul și circuitele unui scaner sau ale camerei digitale, fie din granulația filmului. Figura 3.1 prezintă, pe scurt, diferitele tipuri de zgomot în procesarea imaginilor [18],[19].

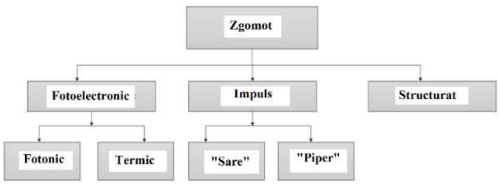


Figura 3.1 *Tipuri de zgomote în domeniul prelucrării de imagini* [19]

3.1 Filtrarea neliniară

Filtrarea neliniară este o tehnică de reducere a zgomotului din imagini în vederea modelării acestora pentru aplicații specifice. Datorită relației neliniare dintre semnalele de intrare și de ieșire, filtrarea neliniară poate avea o complexitate de calcul ridicată și o proiectare dificilă a parametrilor filtrului.

3.1.1. Filtrarea mediană

Acest tip de filtrare implică selectarea unei ferestre (nucleu-*kernel*) de formă pătratică, iar în interiorul ferestrei valoarea fiecărui pixel este înlocuită cu valoarea mediană a pixelilor din jurul acestuia. Mărimea ferestrei se alege în funcție de scop: o

imagine ce păstrează din detaliile fine presupune alegerea unei ferestre mai mici, iar selectarea unei ferestre mai mari conduce la obținerea unui efect de netezire mai evident.

3.1.2. Filtrarea bilaterală

Prin comparație cu filtrarea mediană, filtrarea bilaterală elimină zgomotul din imagini, dar păstrează intacte marginile acesteia. Menținerea marginilor se datorează faptului că algoritmul de filtrare ia în considerare cât de diferiți sunt pixelii din punctul de vedere al culorii, dar și cât de apropiați sunt. Algoritmul de calcul pentru obținerea unei noi imagini implică ajustarea valorii pixelilor dintr-o anumită locație la media valorilor pixelilor similari din apropiere.

3.1.3. Filtrarea bazată pe morfologia matematică

Conform [20] (Figura 3.5), filtrele MM sunt utilizate pentru detecția contururilor și pot, de asemenea, filtra imagini prin operații morfologice combinate. MMO de bază descrișe în Capitolul 2 au rolul de a mări imaginea ceea ce înseamnă micșorarea fundalului (prin operația de dilatare), respectiv de micșora imaginea și de a mări fundalul (prin operația de eroziune). Operatorii combinați ai morfologiei matematice au rolurile de a elimina obiectele mici cu scopul refacerii imaginii originale (deschidere morfologică) sau de a netezi contururile, umple golurile și elimina găurile mici (închidere morfologică).

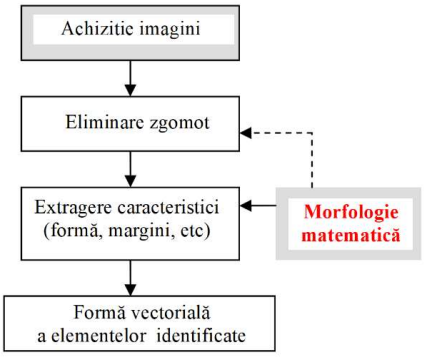


Figura 3.5 *Facilități ale morfologiei matematice* [20]

Filtrele MM convenționale optimizate și-au demonstrat eficiența în implementări complexe, producând imagini restaurate de calitate superioară. Un filtru *neclar* (“*fuzzy*”) calculează valoarea unui pixel folosind valorile pixelilor vecini, menținând în același timp caracteristicile esențiale ale imaginii. Principalul avantaj al acestui filtru îl reprezintă folosirea unor caracteristici de incertitudine pentru eliminarea cu succes a zgomotului [21], [22].

3.2. Filtrarea liniară

Prin *filtrare liniară* imaginile sunt îmbunătățite ca aspect, având modificate anumite componente din spectrul de frecvențe, modificare realizată cu un filtru liniar. La ieșirea filtrului se obține, prin operația de convoluție, o combinație între imaginea de intrare și funcția pondere a filtrului respectiv.

În general, filtrele liniare produc performanțe slabe în prezența zgomotului, și -ca urmare- atenuează marginile ascuțite, elimină liniile și deteriorează detaliile fine ale imaginii.

3.2.1. Filtrarea prin mediere

Face parte din categoria metodelor de filtrare convenționale și, în urma filtrării, efectul este de încețoșare (*blurring*) a imaginii dacă fereastra aleasă pentru filtrare are dimensiune mică sau de filtrare bună a zgomotului dacă fereastra aleasă are dimensiune mare. Fenomenul de încețoșare este evident în zonele imaginii în care variația intensităților pixelilor se face brusc.

3.2.2. Filtrare cu filtrul cu caracteristică de tip Gauss

Prin comparație cu filtrul de mediere, filtrul cu caracteristică de tip Gauss nu folosește o valoare medie uniformă pentru toți pixelii ferestrei, ci pixelul de interes (central) primește cea mai mare valoare ponderată, iar pixelii învecinați primesc valorii medii ponderate mai mici.

3.2.3. Filtrarea Wiener

Filtrul Wiener reduce zgomotul gaussian dintr-o imagine deteriorată prin ajustarea nivelului de netezire pe baza nivelurilor de zgomot, aplicând un nivel mai mic de netezire în regiunile cu contrast ridicat și mai mult în zonele cu contrast scăzut, depășind adesea alte filtre ca performanțe și ținând cont de deteriorarea în benzi de frecvență specifice [23], [24].

3.3. Criterii de evaluare a filtrelor în prelucrarea imaginilor

Calitatea unui filtru poate fi evaluată prin determinarea unor parametrii precum [25]:

- ***Raportul semnal-zgomot de vârf*** (PSNR - Peak Signal-to-Noise Ratio) este un parametru ce oferă o măsură a gradului de eroare dintre imaginea originală și cea reconstruită cu ajutorul metodelor de filtrare. Matematic este definit în ecuația (3.7):

$$PSNR = 20log_{10}\left(\frac{N}{MSE}\right) \tag{3.7}$$

unde *N* este valoarea maximă posibilă a unui pixel din imaginea originală, iar *MSE* reprezintă eroarea pătratică medie.

3.4. Implementare practică a filtrului MM în prelucrarea de imagini

3.4.1. Detecția nodurilor din lemnul de pin folosind filtre MM și RGB

Aplicarea morfologiei matematice a fost extinsă la detecția nodurilor în lemnul de pin, un defect cu implicații semnificative pentru utilizarea lemnului în construcții, inclusiv case, grinzi și uși.

Pentru a aborda această problemă, soluția dezvoltată în cadrul activității de cercetare [PR3] utilizează un filtru MM și un filtru RGB pentru a evidenția pixelii care diferă de valorile tipice de culoare ale lemnului de pin.

3.4.2. Concluzii privind eficiența filtrului MM în studiul de caz propus

Detecția nodurilor în lemnul de pin a implicat testarea a doi MMO (eroziunea și dilatarea) spre deosebire de cazurile prezentate în Capitolul 2 în care a fost utilizat doar câte un MMO. Rezultatele obținute sunt promițătoare și au fost validate de comunitatea științifică, fiind în prezent publicate în [PR3]. Pe baza acestora, se deschid noi oportunități de cercetare în domeniul prelucrărilor de imagini.

Capitolul 4

Contribuții la optimizarea soluțiilor de prelucrare a imaginilor prin integrarea MMO și CNN

Pentru a evalua eficacitatea soluției de fuziune a tehnicii MMO cu rețele neuronale convoluționale (CNN), o soluție sofisticată și actuală în aplicațiile tehnologice de astăzi, vor fi evidențiate în acest capitol o serie de cazuri de utilizare pe care le-am conceput cu acest scop. Odată cu optimizarea soluțiilor propuse și examinarea amănunțită a potențialului tehnicii de fuziune MMO cu CNN, vor fi prezentate și contribuțiile personale la evidențierea beneficiilor tehnicii de filtrare bazată pe MMO.

4.1 Aspecte introductive legate de algoritmii de tip DL

O scurtă prezentare a metodei DL și o comparație cu metodele tradiționale de prelucrare a imaginilor sunt date în Capitolul 2. În cadrul acestui capitol, metoda DL este prezentă detaliat pentru a face trecerea către rețelele DNN, CNN și pentru a identifica principalele modalități de implementare pentru prelucrarea imaginilor.

Metoda DL se încadrează în categoria mai largă a inteligenței artificiale (AI), fiind o diviziune în cadrul învățării automate (ML -Machine Learning). În esență, în timp ce toate ML și DL sunt forme de AI, nu toată AI implică ML.

4.2 Rețelele Neuronale Convoluționale (CNN)

CNN reprezintă cea mai proeminentă tehnică DL pentru procesarea imaginilor, utilizând straturile convoluționale pentru a extrage caracteristici complexe, permițând astfel capabilități predictive exacte. Pentru a obține cea mai mare precizie în recunoașterea formelor și a obiectelor din imagini, o rețea CNN trebuie să fie pre-antrenată pe un set de date extins de imagini adnotate, fiecare conținând formele vizate sau obiectele destinate

detecției. În timpul fazei de antrenare, rețeaua CNN își calibrează sistematic capacitatea de a mapa caracteristicile extrase la etichetele lor corespunzătoare prin propagare inversă iterativă și algoritmi de optimizare avansați. La finalizarea operațiilor de antrenare, rețeaua poate extrapola predicții pentru imagini necunoscute, propagându-le prin rețea și selectând eticheta asociată cu probabilitatea maximă prezisă [26].

4.3 VGG16 și VGG19: implementare, avantaje și dezavantaje

Arhitecturile clasice ale rețelelor VGG16 și VGG19, împreună cu identificarea straturilor, sunt ilustrate în Figura 4.4 (VGG16), Figura 4.5 (VGG19) [27].

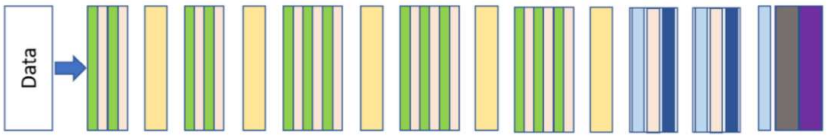


Figura 4.4 *Organizarea straturilor în rețeaua VGG16* [27]

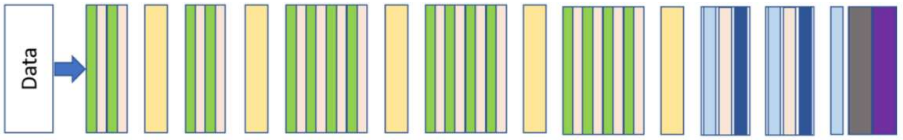


Figura 4.5 *Organizarea straturilor în rețeaua VGG19* [27]

Ambele arhitecturi conțin un număr semnificativ de unități convoluționale, precum și structuri repetitive de straturi (convolutional, ReLu și de grupare maximizată). Pentru optimizarea rezultatelor, în VGG19 au fost introduse straturi suplimentare ReLu care ajută la îmbunătățirea abilităților rețelei de recunoaștere și detecție a obiectelor.

4.4 Fuziune practică a MMO și CNN: studii de caz

4.4.1. Detecția simbolurilor matematice scrise de mână afectate de zgomot

Simbolurile matematice (SM) sunt universale, iar recunoașterea exactă a SM scrise de mână este esențială pentru verificarea corectitudinii ecuațiilor care combină atât simboluri, cât și litere. Această aplicație se concentrează pe recunoașterea SM scrise de

mână afectate de zgomot pe întreg procesul de achiziție al imaginii. *Arhitectura algoritmului propus modelează o rețea DNN în scopul eliminării zgomotului dintr-o bază de date cu ajutorul filtrelor MM*. După eliminarea zgomotului, se verifică dacă imaginea procesată cu ajutorul filtrelor poate fi identificată și clasificată.

Așa cum a fost descris în Capitolul 3, zgomotul suprapus peste imagini poate fi zgomot gaussian (Figura 4.8 b)) sau zgomot de tip „sare și piper" (Figura 4.8 c)) [PR4].



a) b) c)

Figura 4.8 *a) Imaginea originală b) Imaginea afectată de zgomot gaussian c) Imaginea afectată de zgomot de tip „sare și piper"* [PR4]

4.4.2. Recunoașterea literelor scrise de mână

Încurajat de rezultatele promițătoare obținute în cadrul aplicației anterior propuse, am avansat ideea recunoașterii literelor scrise de mână ce compun alfabetul limbii române datorită faptului că alfabetul românesc are 5 litere speciale (scrise cu diacritice). Utilizarea corectă a acestor litere speciale este vitală pentru formarea corectă a cuvintelor deoarece utilizarea greșită poate schimba sensul cuvintelor și al propozițiilor.

Scrisul de mână este vital în învățământ, stilul fiecărui individ – care variază în mărime, lățime și spațiere, aducând elemente necunoscute pentru recunoașterea modelelor. Recunoașterea scrisului de mână este o inovație cheie care transformă textul scris de mână în formă digitală prin achiziția de imagini.

Pentru implementarea algoritmului propus în acest studiu de caz, în Figura 4.15 am detaliat fluxul de lucru [PR5].

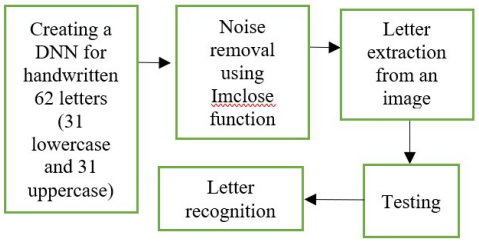


Figura 4.15 *Fluxul de lucru al algoritmului propus pentru recunoașterea literelor alfabetului limbii române* [PR5]

4.4.3. Producerea de imagini sintetizate cu algoritm de augmentare

Analizele imaginilor realizate de oameni pot conduce la rezultate diferite datorită nivelurilor de cunoștințe diferite, dar analiza pe calculator oferă rezultate mai consistente și mai complexe. Tehnicile din categoria *computer vision* automatizează procesele de recunoaștere a modelelor pentru detecția și clasificarea obiectelor în funcție de analiza bazelor de date cu imagini de calitate foarte bună și de crearea unui set de date diversificat. Un model robust în prelucrarea de imagini se obține utilizând augmentarea imaginilor, iar metodele de realizare sunt [28]:

- *deplasarea circulară*: metodă de augmentare a imaginii independentă de proprietățile inerente ale acesteia, aplicabilă oricăror tipuri de imagini din baza de date.
- *rotația*. Augmentările de rotație implică rotirea imaginii originale în jurul unei axe cu 1º până la 359º.
- *translația*. Augmentările obținute schimbă imaginile în orice direcție, prevenind problemele de deplasare a datelor.

Abordarea personală a implicat analiza efectelor procedeelor de augmentare a imaginilor digitale cu MMO. Metoda de lucru este ilustrată în Figura 4.21 [PR6].

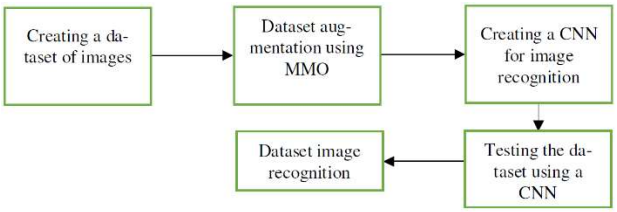


Figura 4.21 *Fluxul de lucru pentru augmentarea imaginilor* [PR6]

4.4.4. Determinarea modelelor de ambarcațiuni utilizând MMO și CNN

Abordarea pe care am propus-o în [PR7] a avut ca scop aducerea unei contribuții în domeniul clasificării ambarcațiunilor din imagini cu ajutorul unei rețele CNN antrenată pe imagini cu diferite tipuri de ambarcațiuni (imagini de suprafață ale navelor private), folosind morfologia matematică pentru a reduce zgomotul din imagini.

4.4.5. Optimizarea seturilor de date folosind tehnici MM

Luând în considerare aspectele menționate anterior, acest studiu de caz urmărește să evalueze impactul tehnicii MMO asupra îmbunătățirii acurateței și preciziei rețelelor VGG16 și VGG19 în detecția și clasificarea fisurilor cauzate de cutremure.

Tabelul 4.16 conține valorile pentru acuratețe, timpul de rulare, estimatele valorilor pozitive și negative, toate obținute pe un număr de epoci egali cu 2, respectiv 3.

Tabelul 4.16 *Metrici pentru estimarea performanțelor soluției propuse* [PR8]

	Număr de epoci = 2				**Număr de epoci = 3**			
Model CNN	**Acuratețe**	**Timpul de rulare**	**PPV**	**NPV**	**Acuratețe**	**Timpul de rulare**	**PPV**	**NPV**
VGG16	98.83%	704 minute	99.10	98.10	98.83%	621 minute	98.95	98.90
VGG19	98.88%	504 minute	99.60	97.75	92.20%	600 minute	99.35	87.20

4.4.6. Evaluarea defectelor structurale induse de cutremur

În ciuda numeroaselor studii pe această temă, acest studiu este motivat de rezultatele din subcapitolul 4.4.5, unde MMO deschidere a îmbunătățit semnificativ acuratețea detecției cu rețelele VGG16 și VGG19. Scopul nostru principal este de a îmbunătăți acuratețea rețelelor neuronale pre-antrenate cu imagini afectate de zgomot în ingineria civilă. Am folosit un set de date cu trei clase de imagini: fisuri, fără fisuri și zgomot.

Determinând valorile de acuratețe pentru fuziunea dintre VGG16, VGG19 și MMO, s-a observat că cele mai bune valori și cel mai mic timp de rulare se obțin folosind MMO deschidere (Tabelul 4.20).

Tabelul 4.20 *Evaluarea acurateței și timpului de rulare* [PR9]

Model CNN utilizat	**Acuratețe [%]**	**Timpul de rulare**
VGG16	74.64	916 minute
VGG19	78.63	1016 minute
VGG16 și MMO dilatare	76.74	821 minute
VGG16 și MMO erodare	77.60	1279 minute
VGG16 și MMO deschidere	**80.83**	**763 minute**
VGG16 și MMO închidere	77.37	763 minute

4.4.7 Baza de date TRIB Crack: instrument util pentru detecția automată a fisurilor din infrastructura rutieră

În procesarea imaginilor, fiabilitatea și precizia rezultatelor depind în mare măsură de calitatea imaginilor prelucrate. Astfel, în timp ce cercetările mele anterioare s-au bazat în primul rând pe procesarea imaginilor din surse online disponibile gratuit, dezvoltarea unei baze de date dedicate adaptate unui anumit studiu de caz a devenit esențială. Pornind de la conceptul de identificare a defectelor structurale cauzate de cutremure, descris în subcapitolul 4.4.6, această secțiune detaliază metodologia pentru construirea unei baze de date cu imagini care captează fisurile existente în infrastructura rutieră, modalitățile de prelucrare și utilitatea acestora.

Capitolul 5

Concluzii

5.1 REZULTATE OBȚINUTE

Teza de doctorat prezintă, într-o formă integrată, activitatea de cercetare desfășurată pe parcursul studiilor doctorale, cercetare care a constat atât în studiul aprofundat al elementelor teoretice necesare, al stadiului actual al cercetărilor în domeniu, dar și în publicarea de articole științifice ce abordează dintr-o perspectivă proprie tematica de actualitate a detecției formelor, recunoașterii formelor, dar și a clasificării acestora.

Capitolul 1 oferă o imagine de ansamblu cuprinzătoare a domeniului ales, stabilind motivația alegerii temei de cercetare. Sunt prezentate domeniul de aplicare a tematicii abordată în teza de doctorat, obiectivele studiului și rezumatul detaliat al conținutului tezei.

În Capitolul 2 este prezentat studiului teoretic legat de algoritmii de detecție a formelor. Considerând eficiența lor dovedită în diverse studii, accentul este pus pe detalierea algoritmilor Viola-Jones, ACF și operatorii morfologiei matematice.

Capitolul 3 prezintă teoria legată de principalele metode de filtrare a zgomotului din imagini, abordând în același timp metodele de detecție și identificare a structurilor geometrice a obiectelor prezente în imagini. Sunt detaliate aspecte legate de filtrarea neliniară, iar clasificarea acestora (în filtrare prin mediere, bilaterală și filtrare MM) este descrisă.

În cadrul Capitolului 4 au fost introduse aspecte legate de algoritmii DL, în vederea avansării activității de cercetare doctorală către tehnicile actuale de prelucrare a imaginilor. Au fost definite metrici de performanță (acuratețea, precizia, rata de detecție) și a fost realizată o clasificare a DL în trei mari categorii de învățare automată: supervizată, nesupervizată și hibridă.

Ultimele secțiuni ale tezei prezintă pe scurt rezultatele relevante obținute și prezentate pe capitole, contribuțiile personale identificate în activitatea de cercetare prezentată în cadrul tezei, lista de publicații ale autorului tezei, precum și viziunea proprie pentru continuarea activităților de cercetare în acest domeniu.

5.2 CONTRIBUȚII PERSONALE

Contribuțiile personale la activitatea de cercetare prezentată în această teză constau în:

1. Analiza detaliată a metodelor de detecție a formelor, analiză axată pe eficiența algoritmilor Viola-Jones, ACF și operatorilor morfologiei matematice (MMO) în vederea detecției precise (cu resurse și timp de procesare minime) a fețelor și a obiectelor din imagini în [PR1].
2. Aplicarea eficientă a erodării (MMO fundamental) a fost realizată în dezvoltarea unei metode de determinare a greutății corpului uman pentru a reduce consumul de combustibil și emisiile de carbon în aviația civilă. Având în vedere numeroasele studii ce enunță dependența consumului de combustibil al unei aeronave de încărcătura de la bord*, scenariul propus a avut ca scop dezvoltarea unei metode de determinare a greutății corporale umane printr-o metodă alternativă celei clasice de cântărire*. *Erodarea a fost metoda de filtrare MM propusă pentru detecția corectă a siluetei unui pasager prin eliminarea zgomotului din imaginile testate* [PR2].
3. Efectuarea unei revizuiri amănunțite a literaturii din domeniul prelucrării de imagini și clasificarea zgomotului în trei categorii, permițând un studiu detaliat al tehnicilor de filtrare relevante pentru fiecare dintre aceste tipuri de zgomote în [PR3].
4. *Superioritatea filtrelor MM față de filtrele mediane* a fost demonstrată și în aplicația descrisă în [PR4], în care *am combinat filtrele MM cu o rețea DNN* în vederea recunoașterii și clasificării cu precizie a imaginilor digitale, prin alegerea unui filtru adecvat de eliminare a zgomotului de tip "sare și piper".
5. Pe baza rezultatelor din [PR4], *o abordare inovativă a reprezentat-o detecția și recunoașterea literelor din alfabetul limbii române, principala provocare reprezentând-o detecția literelor cu diacritice.* Soluția optimizată ce folosește filtre MM a inclus implementarea tehnicilor de augmentare și optimizare Adam și a analizei pe baza numărului de epoci [PR5].
6. *O contribuție importantă privind tehnica de augmentare a imaginilor* a fost evidențiată în [PR6] prin compararea rezultatelor obținute prin reducere dimensiunii datelor și a filtrului MMO d*eschidere*.
7. Abordarea proprie, detaliată în [PR7], oferă o alternativă viabilă la camerele RGB și datele satelitare pentru recunoașterea bărcilor. Prin integrarea filtrelor MM cu rețelele CNN, soluția noastră demonstrează avantaje semnificative față de metode similare.
8. *Alte contribuții relevante* în domeniul prelucrării imaginilor prin fuziunea MMO cu CNN le-am avut în scenariile legate de detecția fisurilor din infrastructura civilă prezentate în [PR8] și [PR9]. *Proiectarea optimă a datelor pentru antrenarea rețelelor VGG16* și *VGG19, alegerea tehnicilor de optimizare adecvate* (augmentare și algoritmul Adam), precum și *testările extinse ale tuturor combinațiilor dintre rețelele CNN și MMO* (eroziune, dilatare, deschidere și închidere) *au facilitat*, pe seturi de date

diferite, pentru numere diferite ale epocilor, *atingerea unor valori pentru acuratețea metodelor propuse de peste 98%* în cazul fuziunii dintre MMO și CNN.

9. Ulterior, în [PR10] am prezentat *contribuția majoră pe care am adus-o în domeniul prelucrării imaginilor prin realizarea propriei baze de date TRIB Crack*, bază ce conține imagini cu fisuri din diferite puncte ale infrastructurii rutiere din București. Pentru demonstrarea validității acesteia, *am realizat operații de separare și redimensionare a acestora (de la 2160 x 2160 pixeli la 256 x 256 pixeli), am folosit cu succes pentru clasificarea imaginilor (cu sau fără fisuri) două CNN (respectiv Darknet-19 și Darknet-53), iar eliminarea zgomotului din imagini ca urmare a operației de segmentare a fost realizată cu trei MMO așezați în serie. În plus, am propus o modalitate de determinare a dimensiunilor fisurilor pentru a putea sublinia utilitatea și importanța acestor prelucrări în managementul infrastructurii rutiere.*

5.3 LISTA LUCRĂRILOR ORIGINALE

Preocuparea mea personală pentru algoritmilor de detecție a formelor în imagini (cu analiza detaliată a operatorilor morfologiei matematice), optimizarea performanțelor globale ale algoritmilor analizați împreună cu rețele neurale convoluționale este demonstrată de cele 9 articole științifice publicate din care: *1 articol în jurnal ISI indexat Q2 [PR9], 2 conferințe internaționale indexate ISI [PR6] și [PR7], 3 conferințe în curs de indexare ISI, anul acesta momentan fiind indexate IEEE Xplore și ACM [PR3]- [PR5], și două articole prezentate la conferințe indexate în alte BDI (SPIE).* În plus în [PR10] sunt prezentate datele articolului aflat în evaluare în prezent la un jurnal indexat Q2. Este important de menționat că la toate articolele publicate sunt prim autor.

În continuare voi enumera publicațiile rezultate în activitatea de cercetare doctorală:

[PR1] **D. Abrudan**, A.-M. Drăgulinescu, R.-O. Preda, and N. Vizireanu "*COVID-19 approved mask detection using mathematical morphology*", Proc. SPIE 12493, Advanced Topics in Optoelectronics, Microelectronics, and Nanotechnologies XI, 124932O, 2023, https://doi.org/10.1117/12.2642041 (BDI: SPIE Digital Library)
Rezultatele din articolul [PR1] au fost incluse în Secțiunea 2.4.

[PR2] **D. Abrudan**, A.-M. Drăgulinescu, R.-O. Preda, and N. Vizireanu "*Fuel burn reduction in commercial aviation using mathematical morphology*", Proc. SPIE 12493, Advanced Topics in Optoelectronics, Microelectronics, and Nanotechnologies XI, 124932Y, 2023, https://doi.org/10.1117/12.2643287 (BDI: SPIE Digital Library) (**1 citare** proceeding paper SpringerLink)
Rezultatele din articolul [PR2] au fost incluse în Secțiunea 2.4.

[PR3] **Abrudan Dumitru**, A. Drăgulinescu and N. Vizireanu, "*Pinewood Knot Detection Method Using Color Analysis*", 2023 15th International Conference

on Electronics, Computers and Artificial Intelligence (ECAI), Bucharest, Romania, **June 29-30, 2023**, pp. 01-05, doi: 10.1109/ECAI58194.2023.10193948 (BDI: IEEE Xplore)

Rezultatele din articolul [PR3] au fost incluse în Secțiunea 3.4.

[PR4] **Abrudan Dumitru**, A.-M. Drăgulinescu and N. Vizireanu, "*Recognition of Handwritten Mathematical Symbols Affected by Noise using DNN*", 2023 15th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), Bucharest, Romania, **June 29-30, 2023**, pp. 01-04, doi: 10.1109/ECAI58194.2023.10194115 (BDI: IEEE Xplore)

Rezultatele din articolul [PR4] au fost incluse în Secțiunea 4.4.1.

[PR5] **Abrudan Dumitru**, A. -M. Drăgulinescu and N. Vizireanu, "*Handwritten letter recognition using mathematical morphology*", 2023 IEEE 29th International Symposium for Design and Technology in Electronic Packaging (SIITME), Craiova, Romania, 18-22 **October 2023**, pp. 20-23, doi: 10.1109/SIITME59799.2023.10431387 (BDI: IEEE Xplore)

Rezultatele din articolul [PR5] au fost incluse în Secțiunea 4.4.2.

[PR6] **D. Abrudan**, I. M. Marcu, N. Vizireanu, "*Digital images augmentation using mathematical morphology operators*", In: Yang, XS., Sherratt, S., Dey, N., Joshi, A. (eds) Proceedings of Ninth International Congress on Information and Communication Technology. ICICT 2024. Lecture Notes in Networks and Systems, vol 1012. Springer, Singapore. https://doi.org/10.1007/978-981-97-3556-3_45. **Feb 2024**) (WOS: 001326995600045)

Rezultatele din articolul [PR6] au fost incluse în Secțiunea 4.4.3.

[PR7] **D. Abrudan**, A.-M. Drăgulinescu, N. Vizireanu, "*Boats Imagery Classification using Deep Learning*", In: Rocha, Á., Adeli, H., Dzemyda, G., Moreira, F., Poniszewska-Marańda, A. (eds) Good Practices and New Perspectives in Information Systems and Technologies. WorldCIST 2024. Lecture Notes in Networks and Systems, vol 987. Springer, Cham. https://doi.org/10.1007/978-3-031-60221-4_43 **May 2024** (indexare baza de date *SpringerLink*) URL: https://link.springer.com/chapter/10.1007/978-3-031-60221-4_43#citeas (WOS: 001267237000043)

Rezultatele din articolul [PR7] au fost incluse în Secțiunea 4.4.4.

[PR8] **D. Abrudan**, I. M. Marcu, A.-M. Claudia Dragulinescu, N. Vizireanu, "*Images data set improvement using mathematical morphology operators*", CACML '24: Proceedings of the 2024 3rd Asia Conference on Algorithms, Computing and Machine Learning, Pp. 450 – 455, https://doi.org/10.1145/3654823.365491 **May 2024** (BDI: ACM Digital Library)

Rezultatele din articolul [PR8] au fost incluse în Secțiunea 4.4.5.

[PR9] **D. Abrudan**, A.-M. Claudia Dragulinescu, N. Vizireanu, "*Applications of mathematical morphology operators in civil infrastructures*", EARTH

SCIENCE INFORMATICS, ISSN: 1865-0473, https://doi.org/10.1007/s12145-024-01379-3 **June 2024** (**ISI, Q2, IF: 2.7, WOS: 001254810900001**)

Rezultatele din articolul [PR9] au fost incluse în Secțiunea 4.4.6.

[PR10] **D. Abrudan**, "*TRIB Crack Dataset: Automatic Recognition System for Road Cracks Detection*", trimis spre recenzare la jurnalul EARTH SCIENCE INFORMATICS, ISSN: 1865-0473, **October 2024** (**ISI, Q2, IF: 2.7**)

Rezultatele din articolul [PR10] au fost incluse în Secțiunea 4.4.7.

5.4 PERSPECTIVE DE DEZVOLTARE ULTERIOARĂ

Detecția formelor atât în imagini statice, cât și în timp real reprezintă provocări semnificative în conceperea de soluții eficiente pentru diverse aplicații. Pe baza cercetărilor efectuate în timpul programului de doctorat, am identificat câteva domenii cheie pentru dezvoltare viitoare:

- pentru identificarea corectă și cu precizie a contururilor siluetelor umane din imagini statice și în mișcare, va fi exploatată ulterior activității de cercetare doctorală în scenarii cât mai diferite și pe imagini achiziționate în timp real. În plus, analize mai complexe vor implica testarea noilor metode adaptive de filtrare, precum și combinații ale acestora.
- Îmbunătățirea tehnicii MMO pentru o estimare mai precisă a greutății, luând în considerare factori precum părul și îmbrăcămintea largi care afectează acuratețea globală și includerea estimatului greutății din imaginile capturate de camerele video din aeroport.
- Aplicarea soluției combinate MMO și CNN pentru detecție, recunoaștere și clasificare în imagini color, precum și analiza altor algoritmi de prelucrare a imaginilor.
- Examinarea metodelor de recunoaștere a dimensiunii fisurilor induse de cutremur, utilizarea acelor dimensiunile ca și criteriu pentru alte analize, precum și explorarea altor metode de îmbunătățire a preciziei metodelor studiate.

Bibliografie

[1] P. Viola, M. Jones, *Rapid object detection using a cascade of simple features*, Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001, Kauai, HI, USA, 2001, pp. I-I, doi: 10.1109/CVPR.2001.990517.

[2] H. T. Ngo, R. C. Tompkins, J. Foytik and V. K. Asari, *An area efficient modular architecture for real- time detection of multiple faces in video stream*, 6th International Conference on Information, Communications & Signal Processing, Singapore, 2007, pp. 1-5, doi: 10.1109/ICICS.2007.4449885.

[3] P. Dollár, R. Appel, S. Belongie and P. Perona, *Fast Feature Pyramids for Object Detection*, in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 36, no. 8, pp. 1532-1545, Aug. 2014, doi: 10.1109/TPAMI.2014.2300479.

[4] B. Yang, J. Yan, Z. Lei and S. Z. Li, *Aggregate Channel Features for Multi-view Face Detection*, In IEEE International Joint Conference on Biometrics, IEEE, (29 September 2014 - 02 October 2014, Clearwater, FL, USA), DOI: https://doi.org/10.1109/BTAS.2014.6996284.

[5] L. Bourdev and J. Brandt, *Robust object detection via soft cascade*, IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, CA, USA, 2005, pp. 236-243 vol. 2, doi: 10.1109/CVPR.2005.310.

[6] M.B. Jensen, M.P. Philipsen, T.B. Moeslund, M. Trivedi, (2016). *Comprehensive Parameter Sweep for Learning-Based Detector on Traffic Lights*, In: Bebis, G., et al. Advances in Visual Computing. ISVC 2016. Lecture Notes in Computer Science(), vol 10073. Springer, Cham. https://doi.org/10.1007/978-3-319-50832-0_10

[7] M. A. S. Sajat, H. Hashim and N. M. Tahir, *Detection of Human Bodies in Lying Position based on Aggregate Channel Features*, 16th IEEE International Colloquium on Signal Processing Its Applications (CSPA), pp. 313-317, Feb. 2020.

[8] J. Hua, Y. Shi, C. Xie, H. Zhang and J. Zhang, *Pedestrian- and Vehicle-Detection Algorithm Based on Improved Aggregated Channel Features*, in IEEE Access, vol. 9, pp. 25885-25897, 2021, doi: 10.1109/ACCESS.2021.3057616.

[9] A. Zhao et al., *An Effective Method Based on ACF for Aircraft Detection in Remote Sensing Images*, in IEEE Geoscience and Remote Sensing Letters, vol. 14, no. 5, pp. 744-748, May 2017, doi: 10.1109/LGRS.2017.2677954.

[10] F. Astuti Hermawati, H. Tjandrasa, N. Suciati, *Combination of Aggregated Channel Features (ACF) Detector and Faster R-CNN to Improve Object Detection Performance in Fetal Ultrasound Images*, International Journal of Intelligent Engineering and Systems, Vol.11, No.6, 2018 DOI: 10.22266/ijies2018.1231.07

[11] J. Zhang, Z. Zeng, L. Zhang, Q. Lu, K. Wang, *Application of Mathematical Morphological Filtering to Improve the Resolution of Chang'E-3 Lunar Penetrating Radar Data*, Remote Sens. 2019, 11, 524. https://doi.org/10.3390/rs11050524

[12] B.A. Landman, I. Lyu, Y. Huo, A. J. Asman, *Chapter 6 - Multiatlas segmentation (6.2.6.4 Morphology correction)*, Handbook of Medical Image Computing and Computer Assisted Intervention, The Elsevier and MICCAI Society Book Series, 2020, Pages 137-164

[13] N. Efford, *Digital Image Processing: A Practical Introduction Using Java*, Publisher: Addison Wesley, ISBN-10: 0201596237, 2000 (Chapter 11 "Morphological image processing")

[14] A. Yousuf, H. Khawaja, M. S. Virk, *Conceptual design of cost-effective ice detection system based on infrared thermography*, Cold Regions Science and Technology, Volume 215, Nov. 2023, 103941 https://doi.org/10.1016/j.coldregions.2023.103941

[15] A. R. Kof, *Revised Mathematical Morphological Concepts: Dilation, Erosion, Opening and Closing*, Kwame Nkrumah University of Science and Technology, Kumasi, 2014 Online: https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=14b6f54a6358ae3b052eaa54583e1ad528fcdc3a

[16] N. Jamil, T. M. T. Sembok and Z. A. Bakar, *Noise removal and enhancement of binary images using morphological operations*, 2008 International Symposium on Information Technology, Kuala Lumpur, Malaysia, 2008, pp. 1-6, doi: 10.1109/ITSIM.2008.4631954.

[17] *Introduction to object detection with deep learning*, Online: https://www.superannotate.com/blog/object-detection-with-deep-learning, Sept 2023 Accesat la 03.08.2024

[18] D.Y. Pimenov, L.R.R. da Silva, A. Ercetin, et al., *State-of-the-art review of applications of image processing techniques for tool condition monitoring on conventional machining processes*, Int J Adv Manuf Technol 130, 57–85 (2024). https://doi.org/10.1007/s00170-023-12679-1

[19] A. Kaur, G. Dong, *A Complete Review on Image Denoising Techniques for Medical Images*, Neural Process Lett 55, 7807–7850 (2023). https://doi.org/10.1007/s11063-023-11286-1

[20] M. Kowalczyk, P. Koza, P. Kupidura, J. Marciniak, *Application of Mathematical Morphology Operations for Simplification and Improvement of Correlation of Images in Close-Range Photogrammetry*, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B5. Beijing 2008

[21] H. H. Kareem, R. Husain A. Ali, G. A.Hafedh Jaber, *Noise Removed by Processing the Lightness and Chromatic Components Basic on YCbCr Color Space*, Journal of Babylon University: Journal of Applied and Pure Sciences, Volume 24, Issue 9, December 2016, Pages 2332-2345

[22] S. V. Vaseghi, *WIENER FILTERS* ,Advanced Digital Signal Processing and Noise Reduction,Second Edition, John Wiley & Sons Ltd ISBNs: 0-471-62692-9, 2000

[23] *Integral Image*, Online: https://www.mathworks.com/help/images/integral-image.html, Accesat la data de 24.07.2024

[24] S. Ehsan, A.F. Clark, N. ur Rehman, K.D. McDonald-Maier, *Integral Images: Efficient Algorithms for Their Computation and Storage in Resource-Constrained Embedded Vision Systems*, Sensors (Basel). 2015 Jul 10;15(7):16804-30. doi: 10.3390/s150716804. PMID: 26184211; PMCID: PMC4541907.

[25] R. Mohan, S.P. Chokkalingam, Kirupa Ganapathy, A. Rama, *Comparative Image Quality Analysis of Spatial Filters for Pre-processing of CT Abdominal Images*, Webology, Volume 18, Special Issue on Computing Technology and Information Management, September 2021

[26] M. Krichen, *Convolutional Neural Networks: A Survey*, Computers 2023, 12, 151. https://doi.org/10.3390/computers12080151

[27] M.Shaha, M. Pawar, *Transfer learning for image classification*, Proceedings of the 2nd International conference on Electronics, Communication and Aerospace Technology (ICECA 2018) IEEE Conference Record # 42487; IEEE Xplore ISBN:978-1-5386-0965-1

[28] K. Zhang, Z. Cao and J. Wu, *Circular Shift: An Effective Data Augmentation Method For Convolutional Neural Network On Image Classification*, IEEE International Conference on Image Processing (ICIP), Abu Dhabi, United Arab Emirates, 2020, pp. 1676-1680, doi: 10.1109/ICIP40778.2020.9191303