



**UNIVERSITATEA NAȚIONALĂ
DE ȘTIINȚE ȘI TEHNOLOGII
POLITEHNICA BUCUREȘTI**



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

Decision No. 202 from 21-09-2024

**REZUMAT TEZĂ DE
DOCTORAT**

Mobina KEYMASI

**METODE ADAPTIVE PENTRU RECUNOAȘTEREA ȘI
CLASIFICAREA IMAGINILOR SAR**

GOAL-DIRECTED COMPRESSIVE RADAR IMAGING

COMISIA DE DOCTORAT

Prof. dr. ing. Gheorghe BREZEANU Universitatea Națională de Științe și Tehnologii POLITEHNICA București	Președinte
Prof. Dr. Ing. Mihai DATCU Universitatea Națională de Științe și Tehnologii POLITEHNICA București	Îndrumător de Doctorat
Prof. Univ. Dr. Habil. Ing. Cătălin Daniel CĂLEANU Universitatea Politehnica Timișoara	Referent
Conf. dr. ing. Ștefan-Adrian TOMA Academia Tehnică Militară „Ferdinand I”	Referent
Prof. Dr. Ing. Habil. Andrei ANGHEL Universitatea Națională de Științe și Tehnologii POLITEHNICA București	Referent

BUCUREȘTI 2024

Table of contents

1	Introducere	1
1.1	Fundamentele Teledetecției	1
1.1.1	Tipuri de Teledetecție	1
1.2	Platforme de Teledetecție	1
1.3	Aplicații ale Teledetecției	2
1.4	Spectrul Electromagnetic	2
1.5	Motivație și Importanță	3
1.6	Domeniul Tezei	3
1.7	Structura Tezei	3
2	Conținutul Informațional al Observării Pământului	4
2.1	Introducere	4
2.2	Importanța Conținutului Informațional	4
2.2.1	Rezoluția Spațială	4
2.2.2	Rezoluția Spectrală	4
2.2.3	Rezoluția Temporală	4
2.2.4	Rezoluția Radiometrică	5
2.3	Prezentare Generală a Datelor SAR și Multispectrale	5
2.3.1	Date SAR	5
2.3.2	Date Multispectrale	5
2.3.3	Analiză Comparativă	5
2.4	Procesare și Studii de Caz	5
2.4.1	Monitorizarea Lavei: Date SAR și Multispectrale	5
2.4.2	Monitorizarea Deltei Dunării: Date SAR și Multispectrale	6
2.4.3	Monitorizarea Regiunii Eyjafjallajökull: Date SAR și Multispectrale	6
2.4.4	Monitorizarea Cetății Erbil: Date SAR și Multispectrale	8
2.4.5	Monitorizarea Regiunii Arctice: Date SAR și Multispectrale	9
2.5	Concluzie	9
3	Lanțul de Procesare al Observării Pământului	10
3.1	Importanța și Prezentarea Generală a Procesării Datelor în RS	10

3.1.1	Calibrarea și Preprocesarea Datelor	10
3.1.2	Analiza de Bază	10
3.1.3	Finalizarea	10
3.2	Prezentare Generală a SNAP	11
3.2.1	Misiuni Suportate și Capacitatea Multi-Misiune	11
3.2.2	Coregistrarea Datelor Sentinel-1 și Sentinel-2 Utilizând SNAP	11
3.2.3	Eliminarea Zgomotului Termic	11
3.2.4	Eliminarea Zgomotului de la Margine	11
3.2.5	Calibrarea Radiometrică	12
3.2.6	Corecția de Teren	12
3.2.7	Conversia Benzilor în dB	12
3.2.8	Subsetare	12
3.2.9	Subsetare	13
3.2.10	Colocare	13
3.3	Introducere în CS	13
3.3.1	Origini și Dezvoltare	14
3.3.2	Concepte de Bază și Fundamente Matematice	14
3.4	Prezentare Generală a Tehnicilor de IA	14
3.4.1	ML în RS	14
3.4.2	DL în RS	15
3.5	Abordarea Tezei	15
4	Capitolul Rezumat 4: Analiza Schimbărilor Temporale în Delta Dunării	16
4.1	Rezumat	16
4.2	Introducere	16
4.3	Metodologie	17
4.3.1	Extragerea Patch-urilor și Reprezentarea Caracteristicilor Gabor	17
4.3.2	Clustering prin K-means	18
4.3.3	Clasificare Supervizată prin SVM	19
4.4	Rezultate pe Date în Serii Temporale	19
4.5	Concluzie	19
5	Module Semantice Orientate pe Obiective pentru Detectarea Navelor SAR	20
5.1	Introducere	21
5.2	Metodologie	22
5.2.1	Preprocesarea Datelor	22
5.2.2	Structura Modelului YOLOv5s	22
5.3	Rezultate Experimentale	22
5.4	Concluzie	23

6	Învățare Compresivă SAR	24
6.1	Introducere	25
6.2	Metodologie	25
6.2.1	Compresie și Construcția Matricei de Senzori	25
6.2.2	Clasificare și Matrice Antrenabilă	26
6.3	Experimente	27
6.3.1	Seturi de Date și Antrenare	27
6.4	Rezultate	27
6.4.1	Performanța Clasificării și Reconstrucției	27
6.4.2	Antrenare Comună	27
6.5	Concluzie	27
7	Concluzii	29
7.1	Contribuții Principale	29
7.2	Publicații	29
7.2.1	Articole în Jurnale	29
7.2.2	Lucrări la Conferințe	30
7.3	Lucrări Viitoare	30
	References	31

Chapter 1

Introducere

Teledetecția (RS) permite monitorizarea non-invazivă a suprafeței Pământului, a atmosferei și a oceanelor prin analiza radiației electromagnetice (EMR) [5, 29]. Aceasta susține monitorizarea mediului, planificarea urbană, răspunsul la dezastre și gestionarea resurselor, în special prin intermediul radarului cu apertură sintetică (SAR) pentru imagini de înaltă rezoluție, indiferent de condițiile meteorologice [31]. Pentru a aborda provocările legate de datele RS, tehnica de Compressive Sensing (CS) reduce necesitatea achiziției de date, îmbunătățind aplicațiile în timp real [1, 7]. Integrarea inteligenței artificiale, în special a învățării automate (ML) și a învățării profunde (DL), automatizează în continuare procesarea datelor RS, sporind eficiența pentru observarea Pământului [7].

1.1 Fundamentele Teledetecției

RS capturează date prin analiza interacțiunilor EMR cu suprafața Pământului. Teledetecția modernă acoperă mai multe benzi spectrale, detectând fenomene dincolo de percepția vizuală. Componentele cheie includ platformele, senzorii și sistemele de procesare a datelor, avansând prognoza meteo și răspunsul în situații de urgență [5].

1.1.1 Tipuri de Teledetecție

- **Teledetecție Pasivă:** Capturează radiația naturală, utilizată pentru studiile de vegetație și acoperire a terenului [29].
- **Teledetecție Activă:** Emite energie pentru a măsura reflexiile; SAR oferă detalii topografice utile în cartografiere și monitorizare [31].

1.2 Platforme de Teledetecție

Platformele de colectare a datelor RS includ:




Fig. 1.1 Compararea sistemelor de teledetectie activă vs. pasivă.

- **Satelit:** Oferă monitorizare globală, esențială pentru studiile de mediu [17].
- **Avioane și Drone:** Permit aplicații localizate, de înaltă rezoluție, de exemplu, în agricultură de precizie [29].

1.3 Aplicații ale Teledetectiei

Aplicații cheie ale RS:

- **Monitorizarea Mediului:** Observă despăduririle și poluarea [5].
- **Dezvoltare Urbană:** Evaluează utilizarea terenurilor și infrastructura post-dezastru [31].
- **Agricultură:** Monitorizează sănătatea culturilor, optimizând utilizarea resurselor [29].

1.4 Spectrul Electromagnetic

RS utilizează diverse lungimi de undă, fiecare oferind informații despre caracteristicile Pământului pentru o analiză detaliată [5, 29].




Fig. 1.2 Spectrul electromagnetic, arătând lungimile de undă de la raze gamma la unde radio. Teledetectia multispectrală utilizează de obicei porțiunile vizibile și infraroșii, în timp ce SAR operează în cadrul lungimilor de undă mai lungi ale microundelor.

1.5 Motivație și Importanță

Această cercetare abordează necesitatea gestionării eficiente a volumelor mari de date RS, în special SAR, care cer stocare și procesare optimizată [1]. Tehnica de Compressive Sensing (CS) reduce achiziția de date, menținând calitatea și permițând procesare mai rapidă [7]. Integrarea IA și ML automatizează analiza datelor SAR, susținând aplicații în schimbările climatice și urbanism [31].

1.6 Domeniul Tezei

Teza dezvoltă tehnici CS pentru imagistica SAR, minimizând cerințele de date, și explorează metode ML/DL pentru analiza SAR.

Domenii cheie:

- Fundamentele CS și aplicațiile SAR [1].
- Reducerea redundanței în imagistica radar [31].
- Procesarea SAR bazată pe IA pentru extracția caracteristicilor [7].
- Aplicații în mediu și urbanism [5].
- Provocări în CS pentru radar [1].

1.7 Structura Tezei

Structura tezei:

- **Capitolul 1: Introducere** - Prezentare RS, CS, IA și structura tezei.
- **Capitolul 2: Date de Observare a Pământului** - Tipuri și aplicații SAR și multispectrale.
- **Capitolul 3: Procesarea Datelor** - Metode CS și ML pentru extracția caracteristicilor.
- **Capitolul 4: CS în RS** - Aplicații CS pentru SAR.
- **Capitolul 5: IA pentru Analiza SAR** - Tehnici IA/ML în procesarea SAR.
- **Capitolul 6: Experimente și Rezultate** - Configurarea și rezultatele analizei SAR.
- **Capitolul 7: Concluzie** - Rezumat și direcții viitoare.

Această structură detaliază cum CS și IA pot îmbunătăți teledetecția radar pentru EO eficient [5, 31].

Chapter 2

Conținutul Informațional al Observării Pământului

2.1 Introducere

Acest capitol explorează conținutul informațional al Observării Pământului (EO), concentrându-se pe datele SAR și multispectrale. Odată cu avansurile în Teledetecție (RS), crește volumul de date necesar pentru luarea deciziilor. Factorii esențiali—**rezoluții spațială, spectrală, temporală și radiometrică**—determină calitatea datelor [29]. Studii de caz precum urmărirea **fluxurilor de lavă** și monitorizarea **schimbărilor de mediu** în Delta Dunării demonstrează valoarea EO [39, 25].

2.2 Importanța Conținutului Informațional

Valoarea EO este amplificată de **rezoluțiile spațială, spectrală, temporală și radiometrică**, îmbunătățind analiza în diverse aplicații.

2.2.1 Rezoluția Spațială

Esencială pentru detectarea obiectelor mici în mediul urban și natural [5].

2.2.2 Rezoluția Spectrală

Permite diferențierea materialelor; multispectralul sprijină monitorizarea agricolă cu NDVI [33].

2.2.3 Rezoluția Temporală

Reflectă frecvența de reobservare, esențială pentru monitorizarea mediilor dinamice [17].

2.2.4 Rezoluția Radiometrică

Capturează variații subtile de intensitate, sprijinind aplicații precum monitorizarea umidității solului [5].

2.3 Prezentare Generală a Datelor SAR și Multispectrale

Această secțiune compară datele **SAR** și **multispectrale** pentru mediu, agricultură și răspuns la dezastre.

2.3.1 Date SAR

Oferă imagini de înaltă rezoluție pentru **dezastre** și **monitorizare ambientală** [17].

2.3.2 Date Multispectrale

Capturează benzi multiple, utile în agricultură, silvicultură și clasificarea terenurilor [5].

2.3.3 Analiză Comparativă

- **Rezoluție:** SAR oferă detalii spațiale; multispectralul oferă profunzime spectrală [17].
- **Acoperire:** SAR funcționează în orice condiții; multispectralul necesită cer senin [35].
- **Aplicații:** SAR e potrivit pentru monitorizarea structurală; multispectralul excellează în vegetație și utilizarea terenurilor [29].


2.4 Procesare și Studii de Caz

Procesarea datelor SAR și multispectrale oferă perspective acționabile, ilustrate în **monitorizarea lavei și conservarea mediului**.


2.4.1 Monitorizarea Lavei: Date SAR și Multispectrale

Monitorizarea lavei sprijină prognoza și siguranța, cum s-a demonstrat în erupția Kīlauea din 2018, folosind date SAR și multispectrale.

Senzorii multispectrali acoperă un spectru larg de lungimi de undă, utili pentru detectarea schimbărilor de suprafață și a anomaliilor termice în regiunile vulcanice. Figura 2.1 arată utilizarea datelor SAR și multispectrale pentru urmărirea fluxurilor



(a) Imagine compozită RGB multispectrală a fluxului de lavă Kīlauea (22 iulie 2018). Regiunile întunecate indică fluxul de lavă, vegetația este reprezentată în verde, iar norii sunt vizibili în alb.



(b) Imagine SAR cu polarizare VV a fluxului de lavă Kīlauea (31 iulie 2018). Regiunile întunecate indică fluxuri de lavă proaspete cu suprafețe netede, în timp ce zonele mai luminoase corespund terenului vulcanic accidentat și vegetației.

Fig. 2.1 Analiză combinată a fluxului de lavă Kīlauea folosind date SAR și multispectrale. Integrarea acestor seturi de date evidențiază zonele active de lavă și rugozitatea suprafeței.

de lavă și analiza rugozității suprafeței în timpul erupției Kīlauea, oferind informații valoroase pentru evaluări în timp real.

2.4.2 Monitorizarea Deltei Dunării: Date SAR și Multispectrale

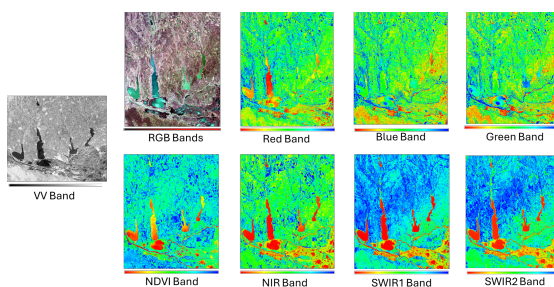
Delta Dunării, un hotspot de biodiversitate, necesită monitorizare ecologică precisă. Combinarea datelor SAR și multispectrale oferă perspective detaliate asupra acoperirii terenului, vegetației, calității apei și schimbărilor ecologice.

Figura 2.2 arată integrarea datelor SAR și multispectrale pentru monitorizarea sănătății vegetației și calității apei în Delta Dunării, sprijinind conservarea zonelor umede.


2.4.3 Monitorizarea Regiunii Eyjafjallajökull: Date SAR și Multispectrale

Vulcanul Eyjafjallajökull din Islanda prezintă provocări de monitorizare din cauza activității și terenului complex. Datele SAR și multispectrale oferă informații despre caracteristicile vulcanice, rugozitatea suprafeței și proprietățile termice.

Figura 2.3 arată cum integrarea datelor SAR și multispectrale poate monitoriza activitatea vulcanică și schimbările de suprafață în Eyjafjallajökull, oferind informații esențiale pentru evaluarea riscurilor.




(a) Compozit RGB multispectral al Deltei Dunării folosind benzile Sentinel-2. Vegetația este redată în diferite nuanțe de verde, în timp ce corpurile de apă apar în albastru și turcoaz.




(b) Imagine SAR cu polarizare VV a Deltei Dunării, oferind o analiză în tonuri de gri a caracteristicilor de suprafață. Zonele mai luminoase reprezintă vegetația densă și suprafețele accidentate, în timp ce regiunile mai întunecate indică corpurile de apă netede.

Fig. 2.2 Analiză combinată a Deltei Dunării utilizând benzile multispectrale Sentinel-2 și datele SAR. Fuziunea seturilor de date dezvăluie sănătatea vegetației și caracteristicile de suprafață.



(a) Compozit RGB multispectral al regiunii Eyjafjallajökull (octombrie 2022). Sunt prezentate terenul vulcanic și vegetația înconjurătoare.




(b) Imagine SAR cu polarizare VV a Eyjafjallajökull (noiembrie 2022). Zonele întunecate indică fluxuri recente de lavă cu suprafețe netede, în timp ce regiunile mai luminoase reprezintă terenul vulcanic accidentat.

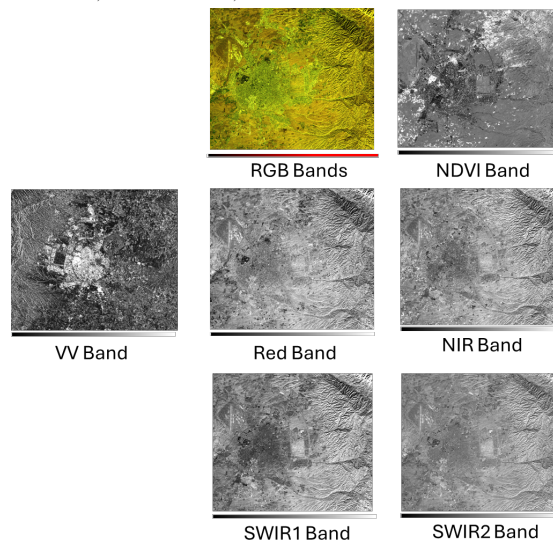
Fig. 2.3 Analiză combinată a regiunii Eyjafjallajökull folosind benzile multispectrale Sentinel-2 și datele SAR. Fuziunea seturilor de date relevă activitatea vulcanică și caracteristicile de suprafață.

2.4.4 Monitorizarea Cetății Erbil: Date SAR și Multispectrale

Cetatea Erbil, un sit arheologic major, beneficiază de date SAR și multispectrale non-invasive, facilitând detectarea și analiza structurilor îngropate.



(a) Compozit RGB multispectral al Cetății Erbil (decembrie 2021). Vegetația și structurile urbane sunt prezentate în diferite nuanțe de verde și maro.




(b) Imagine SAR cu polarizare VV a Cetății Erbil (decembrie 2021). Zonele mai luminoase indică teren accidentat și structuri subterane, în timp ce suprafețele mai netede apar mai întunecate.

Fig. 2.4 Analiză combinată multispectrală și SAR a Cetății Erbil folosind datele Sentinel-2. Fuziunea seturilor de date dezvăluie structurile subterane și caracteristicile de suprafață.


Figura 2.4 ilustrează utilizarea datelor SAR și multispectrale pentru descoperirea structurilor îngropate și analiza suprafeței Cetății Erbil, oferind informații valoroase pentru conservarea arheologică.

2.4.5 Monitorizarea Regiunii Arctice: Date SAR și Multispectrale

Regiunea Arctică, afectată de schimbările climatice, necesită monitorizare continuă. Combinarea datelor SAR și multispectrale este crucială pentru urmărirea schimbărilor în gheața marină, vegetație și dinamica ghețarilor.



(a) Compozit RGB multispectral și analiză a gheții marine și vegetației din regiunea Arctică (septembrie 2024). Sunt utilizate diverse benzi pentru evaluarea sănătății vegetației, extinderea gheții marine și caracteristicile suprafeței.



(b) Imagine SAR cu polarizare VV a regiunii Arctice (septembrie 2024). Zonele întunecate indică suprafețe de gheață mai netede, în timp ce regiunile mai luminoase dezvăluie teren glaciuar accidentat și permafrost.

Fig. 2.5 Analiză combinată a regiunii Arctice utilizând date SAR și multispectrale din septembrie 2024. Compoziția RGB relevă extinderea gheții marine și schimbările vegetației, în timp ce datele SAR evidențiază rugozitatea suprafeței, dinamica ghețarilor și caracteristicile permafrostului.

Figura 2.5 arată utilizarea datelor SAR și multispectrale pentru monitorizarea extinderii gheții marine, schimbărilor vegetației și dinamicii ghețarilor în regiunea Arctică, oferind informații despre impactul schimbărilor climatice.

2.5 Concluzie

Acest capitol a evidențiat valoarea datelor EO, îmbunătățită de rezoluțiile spațială, spectrală, temporală și radiometrică. Combinarea datelor SAR și multispectrale permite monitorizarea eficientă în condiții dificile [37].

Tehnici de IA precum CS, ML și DL sunt esențiale pentru gestionarea datelor mari și reducerea zgomotului.

Studiile de caz pe activitatea vulcanică și monitorizarea Deltei Dunării arată beneficiile EO în managementul climatului, dezastrelor și resurselor [39, 25].

Progresul EO va depinde de cadrele IA pentru valorificarea volumelor crescânde de date [13].

Chapter 3

Lanțul de Procesare al Observării Pământului

3.1 Importanța și Prezentarea Generală a Procesării Datelor în RS

Lanțul de procesare în observarea Pământului transformă datele brute în informații utilizabile, incluzând calibrare, analiză de bază și finalizare, cu software-ul SNAP ca un instrument cheie.

3.1.1 Calibrarea și Preprocesarea Datelor

Calibrarea și preprocesarea asigură acuratețea, corectând distorsiunile din datele brute. SNAP îmbunătățește fiabilitatea datelor prin calibrare precisă, esențială pentru aplicații precum monitorizarea vegetației [19].

3.1.2 Analiza de Bază

Analiza de bază extrage informații folosind uneltele SNAP. Tehnicile de extracție de caracteristici și clasificare, precum NDVI și SVM, ajută la analiza acoperirii terenului și a vegetației [33].

3.1.3 Finalizarea

Finalizarea include validarea rezultatelor, integrarea datelor și generarea de rezultate precum hărți NDVI pentru luarea deciziilor [5].

3.2 Prezentare Generală a SNAP

SNAP, dezvoltat de ESA, procesează date din surse precum misiunile Sentinel și Landsat, oferind instrumente pentru manipularea și analiza avansată a datelor [28].

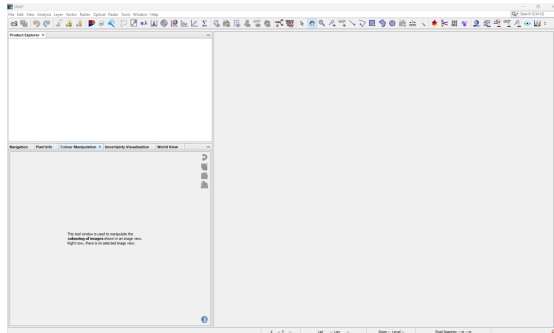


Fig. 3.1 Mediul de interfață SNAP arătând instrumente pentru manipularea datelor, manipularea culorilor și procesarea avansată în teledetecție.

3.2.1 Misiuni Suportate și Capacitatea Multi-Misiune

Capacitatea multi-misiune a SNAP permite procesarea datelor de la mai mulți senzori, precum radarul de la Sentinel-1 și datele optice de la Sentinel-2, facilitând cercetarea multi-senzorială în studiile climatice și de mediu [28].

3.2.2 Coregistrarea Datelor Sentinel-1 și Sentinel-2 Utilizând SNAP

Coregistrarea aliniaza imaginile Sentinel-1 și Sentinel-2 pentru detectarea schimbărilor, fuziunea datelor și analiza în serii temporale.

Fluxul de Procesare GRD al Sentinel-1 în SNAP

Fluxul de procesare GRD al Sentinel-1 include pași precum aplicarea unui fișier de orbită pentru a corecta traiectoria satelitului, îmbunătățind acuratețea geometrică pentru analiză.

3.2.3 Eliminarea Zgomotului Termic

Zgomotul termic, care degradează calitatea datelor, este eliminat pentru a se asigura că semnalul de retrodifuziune reprezintă cu acuratețe proprietățile suprafeței.

3.2.4 Eliminarea Zgomotului de la Margine

Zgomotul de la margine este eliminat pentru a curăța imaginile SAR și pentru a îmbunătăți utilizabilitatea.




Fig. 3.2 Aplicarea fișierului de orbită în SNAP pentru a îmbunătăți acuratețea geometrică a datelor GRD Sentinel-1.




Fig. 3.3 Eliminarea zgomotului termic aplicată pe datele Sentinel-1 folosind SNAP.

3.2.5 Calibrarea Radiometrică

Calibrarea radiometrică convertește valorile digitale în coeficienți de retrodifuziune (σ^0), asigurând comparabilitatea cantitativă a datelor.

3.2.6 Corecția de Teren

Corecția de teren folosește un DEM pentru a ajusta coordonatele pixelilor, asigurând că elementele din imaginile SAR sunt mapate corect pe pozițiile geografice.

3.2.7 Conversia Benzilor în dB

Conversia datelor SAR de la scară liniară la decibeli (dB) simplifică interpretarea și compararea între seturile de date.

3.2.8 Subsetare

Funcția de subsetare reduce volumul de date și timpul de procesare concentrându-se pe zona de interes.




Fig. 3.4 Eliminarea zgomotului de la margine din datele GRD Sentinel-1 folosind SNAP.




Fig. 3.5 Calibrarea radiometrică aplicată pe datele Sentinel-1, convertind valorile pixelilor în coeficienți de retrodifuziune (σ^0).

Fluxul de Preprocesare Sentinel-2 în SNAP

Preprocesarea Sentinel-2 include pași similari, precum subsetarea și colocarea, pentru a pregăti datele pentru analiză.

3.2.9 Subsetare

Subsetarea datelor Sentinel-2 reduce dimensiunea setului de date concentrându-se pe zona de interes.

3.2.10 Colocare

Colocarea aliniaza datele SAR Sentinel-1 și imaginile optice Sentinel-2 pentru o analiză comună.

3.3 Introducere în CS

Compressive Sensing (CS) achiziționează și reconstruiește eficient semnale prin utilizarea rarității, reducând volumul de date, păstrând totodată informațiile cruciale, fiind potrivit pentru gestionarea seturilor mari de date de la senzori SAR și hiperspectrali [11].




Fig. 3.6 Corecția de teren în SNAP folosește un DEM pentru a ajusta distorsiunile topografice din datele SAR Sentinel-1.




Fig. 3.7 Conversia valorilor de retrodifuziune de la scară liniară la decibeli (dB) în SNAP.

3.3.1 Origini și Dezvoltare

CS a fost dezvoltat la începutul anilor 2000 de către Candès, Romberg, Tao și Donoho, demonstrând că semnalele rare pot fi reconstruite cu mai puține mostre [8, 14].

3.3.2 Concepte de Bază și Fundamente Matematice

CS se bazează pe raritate și incoerență. Vectorul de măsurare y este reprezentat ca $y = \Phi x$, unde x este semnalul rar, iar Φ este matricea de măsurare. Problema reconstrucției este rezolvată folosind tehnici de optimizare, cum ar fi Basis Pursuit [9, 14].

3.4 Prezentare Generală a Tehnicilor de IA

Tehnicile de IA, în special ML și DL, au transformat RS prin simplificarea fluxurilor de lucru complexe, îmbunătățind eficiența și extrăgând informații mai profunde din datele satelitare. Aceste capacități sunt esențiale pentru aplicații în timp real, cum ar fi gestionarea dezastrelor și clasificarea utilizării terenului [5].

3.4.1 ML în RS

ML automatizează analiza datelor, cu învățarea supervizată (de exemplu, SVM, Random Forests) pentru sarcini precum clasificarea acoperirii terenului și învățarea nesupervizată (de exemplu, K-means, PCA) pentru segmentarea imaginilor și detectarea anomaliilor [23, 2].



Fig. 3.8 Subsetarea datelor GRD Sentinel-1 în SNAP.




Fig. 3.9 Subsetarea datelor Sentinel-2 în SNAP.

3.4.2 DL în RS


Modelele DL, cum ar fi CNN, sunt utilizate pe scară largă pentru sarcini precum clasificarea acoperirii terenului și detectarea obiectelor în imaginile satelitare [21, 41].

3.5 Abordarea Tezei


Această teză își propune să îmbunătățească acuratețea și eficiența procesării datelor EO utilizând CS, ML și DL. Aplicate pentru sarcini în Delta Dunării, inclusiv analiza acoperirii terenului, schimbări temporale și detectarea navelor, aceste tehnici abordează medii provocatoare ale RS.

În analiza acoperirii terenului, CS reduce volumul de date, iar ML și DL permit extracția automată a caracteristicilor. Schimbările temporale sunt urmărite prin date coregistrate Sentinel-1 și Sentinel-2 cu tehnici IA, cum ar fi clustering-ul și SVM. Detectarea navelor SAR utilizează modele DL, precum YOLO, pentru o acuratețe ridicată, iar CS minimizează redundanța.

Această integrare oferă soluții scalabile și precise pentru EO, sprijinind procesarea în timp real și luarea deciziilor.



(a) Datele benzii VV Sentinel-1.



(b) Datele RGB Sentinel-2.

Fig. 3.10 Imagini colocare ale benzii VV Sentinel-1 și RGB Sentinel-2 pentru analiza multi-senzor.

Chapter 4

Capitolul Rezumat 4: Analiza Schimbărilor Temporale în Delta Dunării

4.1 Rezumat

Clasificarea imaginilor de teledetecție (RS) în zone dinamice precum Delta Dunării este o provocare datorită schimbărilor rapide ale peisajului [18]. Acest studiu utilizează date coregistrate de radar cu apertură sintetică (SAR) și multispectrale (MS), aplicând tehnici de învățare automată (ML)—t-SNE, clustering K-means [20] și clasificare SVM [27]. Rezultatele arată că banda VV a SAR oferă date detaliate pentru antrenament [34], în timp ce banda infraroșie a MS ajută la extragerea referințelor [29]. Un model SVM îmbunătățit de t-SNE a obținut o acuratețe de 91,60




Fig. 4.1 Diagrama de bloc a proiectului are trei secțiuni principale: coregistrarea datelor SAR și MS; aplicarea filtrului Gabor pe segmente; și tehnici de clustering și clasificare.

4.2 Introducere

Clasificarea imaginilor de teledetecție este esențială pentru monitorizarea mediului, mai ales în zone dinamice precum Delta Dunării, expusă riscurilor de pierdere a biodiversității [18]. Combinarea imaginilor SAR și MS prin coregistrare oferă o perspectivă completă asupra schimbărilor de mediu [34, 26].



Fig. 4.2 ROI-ul studiului este situat în Delta Dunării, la granița dintre sud-estul României și sudul Ucrainei.

Studiul aplică tehnici de învățare automată (ML)—filtre Gabor pentru extragerea caracteristicilor [22], K-means pentru clasificare nesupervizată [20] și SVM pentru clasificare supervizată [27]—pentru a monitoriza schimbările temporale din Deltă, sprijinind urmărirea eficientă a modelelor ecologice.

4.3 Metodologie

Date coregistrate SAR și MS de la Copernicus Open Access Hub, pe o perioadă de zece luni, au fost utilizate pentru a surprinde schimbările sezoniere și pe termen lung. Preprocesarea în SNAP a inclus corecția orbitei, eliminarea zgomotului, calibrarea și corecția terenului. Filtrele Gabor au fost aplicate pentru extragerea caracteristicilor, îmbunătățind reprezentarea texturii.

K-means clustering și t-SNE au grupat caracteristicile în trei categorii: corpuri de apă, teren și vegetație. t-SNE a redus datele de dimensiuni mari pentru vizualizare, iar SVM a efectuat clasificarea supervizată pentru a distinge între clase.

4.3.1 Extragerea Patch-urilor și Reprezentarea Caracteristicilor Gabor

Filtrele Gabor au fost aplicate pe segmente, generând un vector de 48 de dimensiuni pentru clasificare, utilizând diverse orientări și scale.




Fig. 4.3 Rezultatele t-SNE pe vectorii de caracteristici pentru patru benzi: RGB, Infraroșu, VV și VH. Banda VV SAR a evidențiat cea mai bună separare în trei clase.

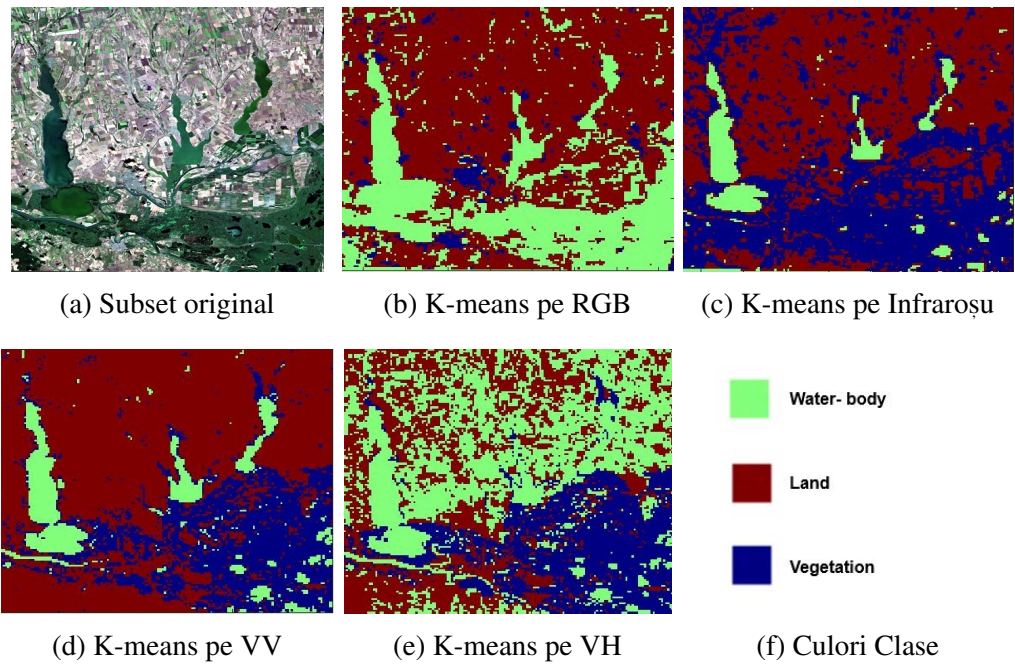


Fig. 4.4 Subsetul original (a) și rezultatele clustering-ului pe patru benzi—RGB, Infraroșu, VV și VH—după aplicarea K-means pentru trei clase: apă, teren și vegetație. Benzile Infraroșu MS și VV SAR au dat cele mai bune rezultate.

4.3.2 Clustering prin K-means

Figura 4.3 arată vizualizarea t-SNE a vectorilor de caracteristici din benzile SAR și MS, cu banda VV SAR excelând în categorisirea celor trei clase. Figura 4.4 ilustrează clustering-ul K-means, distingând apa, terenul și vegetația.

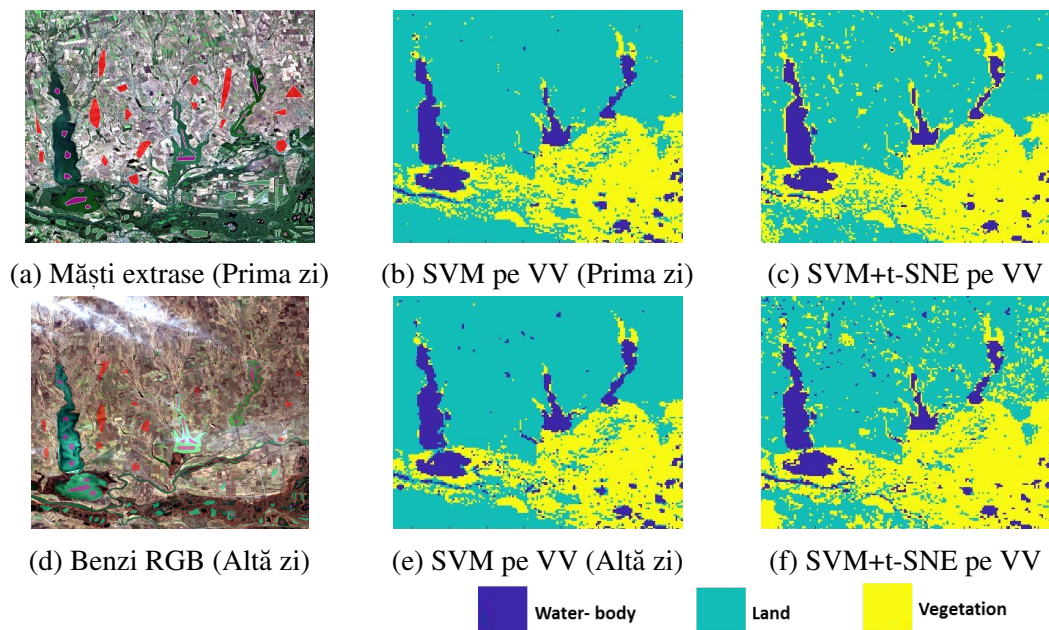


Fig. 4.5 Clasificarea SVM pe banda SAR VV, comparând rezultatele în două zile diferite. SVM+t-SNE demonstrează o acuratețe îmbunătățită a clasificării.

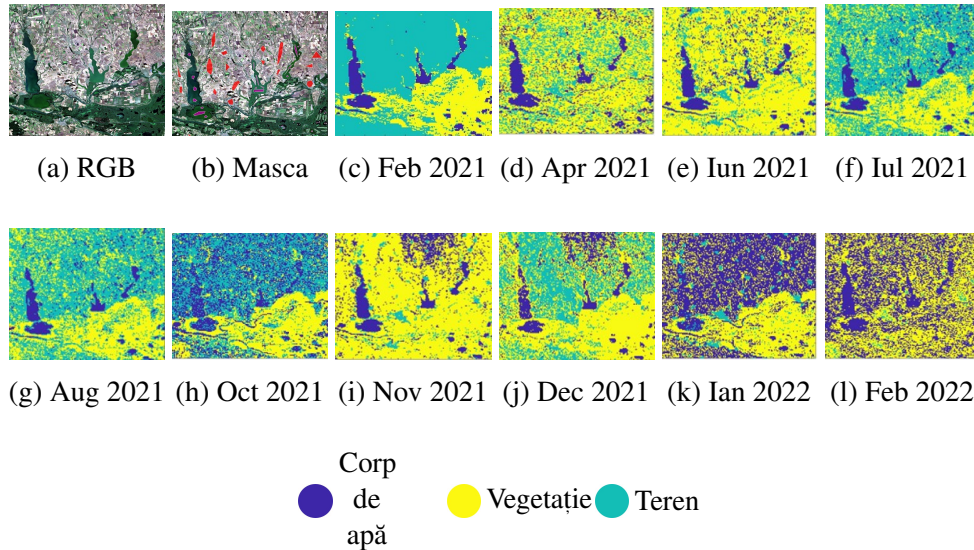


Fig. 4.6 O colecție de imagini RGB, măști și hărți de caracteristici pe parcursul mai multor luni, din februarie 2021 până în februarie 2022.




Fig. 4.7 Acuratețea Clasificării




Fig. 4.8 Mediile NDVI

4.3.3 Clasificare Supervizată prin SVM

SVM a clasificat caracteristicile benzii VV SAR. Figura 4.5 arată o acuratețe crescută cu t-SNE înainte de antrenament.

4.4 Rezultate pe Date în Serii Temporale

SVM a clasificat constant terenul, vegetația și apa pe zece date. Figura 4.6 prezintă distribuția în timp a acoperirii terenului.

4.5 Concluzie

Combinarea datelor SAR și MS cu ML permite monitorizare precisă în Delta Dunării. t-SNE integrat cu SVM îmbunătățește acuratețea. Lucrările viitoare vor extinde clasificarea și metodele de învățare profundă.

Chapter 5

Module Semantice Orientate pe Obiective pentru Detectarea Navelor SAR

Abstract

Acest capitol introduce o metodologie nouă pentru detectarea navelor SAR, combinând rețele neuronale convoluționale (CNN) [21, 41] și Transformatoare Vizuale (ViT) [15] cu un mecanism de control. Validată inițial pe setul de date MNIST [12] și apoi pe datele de detectare a navelor SAR (PSeg-SSDD) [42], metodologia demonstrează robustețe și versatilitate. Un model YOLOv5s modificat [38] oferă un echilibru între acuratețe și eficiența computațională, demonstrând aplicabilitatea sa practică în supravegherea maritimă.

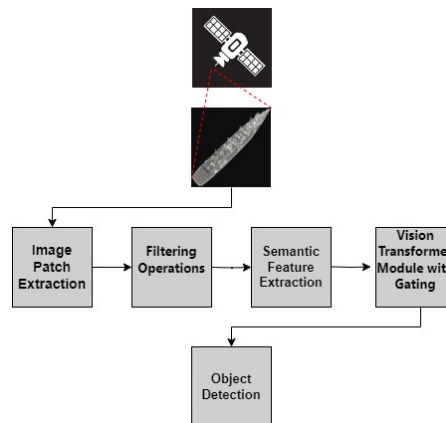


Fig. 5.1 Reprezentare schematică a metodologiei propuse

5.1 Introducere

Tehnologia radar cu apertură sintetică (SAR) revoluționează supravegherea maritimă prin detectarea navelor în orice condiții meteorologice, zi sau noapte [41]. Spre deosebire de senzorii optici, SAR se bazează pe semnale de microunde, permițând detectarea prin nori și întuneric [34]. Această capacitate susține gestionarea traficului maritim, protecția frontierelor și conservarea mediului. În ciuda avantajelor sale, detectarea navelor bazată pe SAR întâmpină provocări datorită zgomotului și mediilor complexe [10]. Figura 5.1 ilustrează metodologia propusă, arătând integrarea rețelelor neuronale convoluționale (CNN) [21] și a Transformatoarelor Vizuale (ViT) [15] pentru sarcini de detectare a navelor, îmbunătățind percepția caracteristicilor printr-un mecanism de control.




Fig. 5.2 Procesul de extracție și fuziune a caracteristicilor pe imagini din setul de date MNIST și date de detectare a navelor SAR, demonstrând adaptabilitatea modelelor CNN și ViT pe diverse domenii.

5.2 Metodologie

Abordarea integrează CNN și ViT, combinate cu un mecanism de control și optimizate în cadrul YOLOv5s. Figura 5.2 ilustrează procesul de extracție a caracteristicilor pe seturile de date MNIST și SAR, evidențiind fiecare pas de transformare, de la extracția patch-urilor la ieșirea ViT cu control, care adaptează modelul pentru condiții maritime variate.

5.2.1 Preprocesarea Datelor


Setul de date PSeg-SSDD a fost prelucrat pentru a îmbunătăți calitatea imaginii. Aceasta a inclus reducerea zgomotului folosind filtre FMK și Lee, îmbunătățirea conturilor și normalizarea pentru a optimiza datele SAR pentru modelele DL. Setul de date a fost împărțit în antrenare, validare și testare, asigurând o evaluare cuprinzătoare.

5.2.2 Structura Modelului YOLOv5s


YOLOv5s este structurat cu trei componente principale: Backbone, Neck și Head, fiecare optimizată pentru detectarea eficientă a obiectelor. Modelul modificat integrează EfficientConvModule și blocuri SE, așa cum se arată în Figura 6.2, pentru a îmbunătăți acuratețea și eficiența detectării.

5.3 Rezultate Experimentale


Abordarea a fost validată pe seturile de date MNIST și detectare nave SAR, obținând o precizie medie (mAP) de 96% la un prag IoU de 0.5 pe datele SAR. Figura 6.3 arată performanța pe diferiți parametri de evaluare, cu precizie și recall ridicate și constante.



(a) Batch de Antrenament 0



(b) Etichetă Batch Validare 0



(c) Predicție Batch Validare 0

Fig. 5.3 Etapele de antrenare și validare pentru detectarea navelor SAR utilizând YOLOv5s pe setul de date PSeg-SSDD.




Fig. 5.4 Rezultate pe diferiți parametri și metrice.

5.4 Concluzie

Acest capitol prezintă o metodologie eficientă de detectare a navelor SAR, integrând CNN, ViT și îmbunătățiri în arhitectura YOLOv5s. Cercetările viitoare vor extinde aplicațiile la monitorizarea mediului și alte sarcini de teledetectie.

Chapter 6

Învățare Compresivă SAR

Abstract

Învățarea Compresivă (CL) pentru SAR reduce cerințele de date, sporind eficiența și reducând cerințele computaționale. Prima metodă combină procesarea semnalului cu Compressive Sensing (CS) pentru a atinge o acuratețe de 80

nvățare Compresivă (CL), Radar cu Apertură Sintetică (SAR), Reducerea Datelor, Procesare Comună a Semnalului, Cadru CS, Clasificator SVM, Matrice de Senzori Binară.

6.1 Introducere

CL valorifică raritatea semnalului pentru a reconstrui datele din măsurători mai puține [6]. În imagistica SAR, combinarea imagisticii rare cu ML permite sarcini precum recunoașterea și clasificarea [41]. Studiile anterioare au folosit algoritmi CS precum MRKCS și ITR pentru a îmbunătăți compresia datelor SAR [4]. Senzorii SAR, folosind semnale de microunde, sunt critici în teledetecție (RS) pentru imagistica continuă [30]. Metodele CS reduc cerințele de date, scăzând nevoile de stocare și transmitere RS [9]. Integrarea CL cu SAR îmbunătățește sarcinile precum clasificarea, avansând cercetarea în reprezentarea rară [11].

Eficiența CL în SAR este demonstrată prin antrenarea comună a matricelor de senzori și clasificatorilor, ceea ce sporește acuratețea clasificării [24]. Experimentele cu matrici fixe și antrenabile confirmă potențialul CL de a optimiza procesarea datelor SAR [14].

6.2 Metodologie

Acest studiu propune comprimarea datelor SAR prin transformări liniare și clasificarea acestora fără reconstrucție. Figura 6.1 ilustrează cadrul cu trei scenarii: (I) matrice de senzori fixă cu clasificator, (II) matrice de senzori fixă cu decodor și (III) matrice de senzori antrenabilă cu antrenare comună a clasificatorului și decodorului.

6.2.1 Compresie și Construcția Matricei de Senzori

Compresia a fost realizată prin reducerea măsurătorilor folosind o matrice aleatoare, notată cu A , aleasă din distribuții Binare, Gaussiene sau Uniforme.

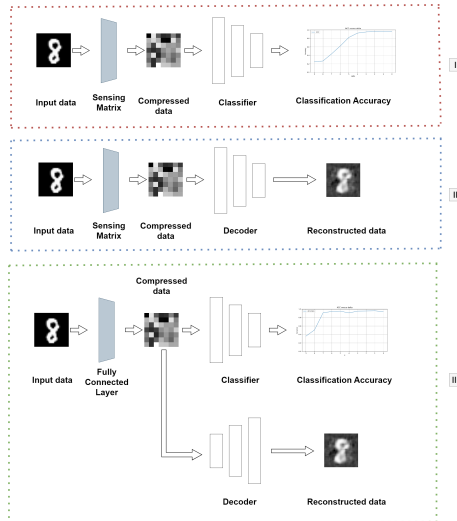


Fig. 6.1 Diagrama bloc a metodei propuse.

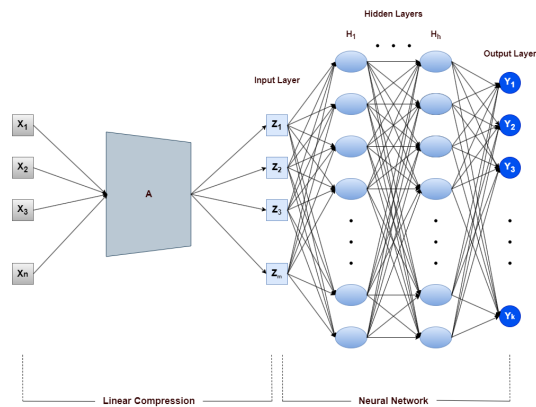


Fig. 6.2 Diagrama bloc a metodei propuse include trei scenarii diferite: (I) matrice de senzori fixă plus clasificator, (II) matrice de senzori fixă plus decodor și (III) matrice de senzori antrenabilă cu antrenare comună a ambelor clasificator și decodor.




Fig. 6.3 Comparația coerenței pentru trei distribuții distincte: Uniformă, Gaussiană și Binare, pentru valori variate ale lui δ .

6.2.2 Clasificare și Matrice Antrenabilă

Clasificatorii folosiți includ MLP, RF și SVM, selectați în funcție de caracteristicile setului de date. În plus, a fost integrată o matrice de senzori antrenabilă, permițând optimizarea prin antrenare comună. Această metodă a reținut mai multe date esențiale în măsurători comprimate, sporind acuratețea clasificării.

6.3 Experimente

6.3.1 Seturi de Date și Antrenare

Experimentele au folosit seturile de date MNIST și MSTAR, folosind un model MLP antrenat în Pytorch.




Fig. 6.4 Date originale, date comprimate și date reconstruite.

6.4 Rezultate

6.4.1 Performanța Clasificării și Reconstrucției

Nivelurile mai ridicate de compresie au redus acuratețea clasificării, așa cum se arată în Figura 6.6. Rezultatele reconstrucției din Figura 6.4 confirmă că datele comprimate rețin informații esențiale chiar și la compresii mari, fiind potrivite pentru aplicații cu stocare limitată.

6.4.2 Antrenare Comună

Antrenarea comună a depășit configurările cu matrice fixă, în special pe seturile de date MNIST și MSTAR, așa cum se arată în Figura 6.7. Această abordare permite adaptarea matricei de senzori, optimizând clasificarea și reconstrucția împreună.

6.5 Concluzie

CL sporește eficiența datelor SAR, reducând semnificativ cerințele de date, menținând în același timp performanța clasificării. Studiul a demonstrat impactul antrenării comune asupra acurateței, promovând CL ca o soluție viabilă pentru aplicații RS și SAR cu constrângeri de date. Cercetările viitoare ar trebui să optimizeze și mai mult CL pentru seturi de date SAR mai largi.

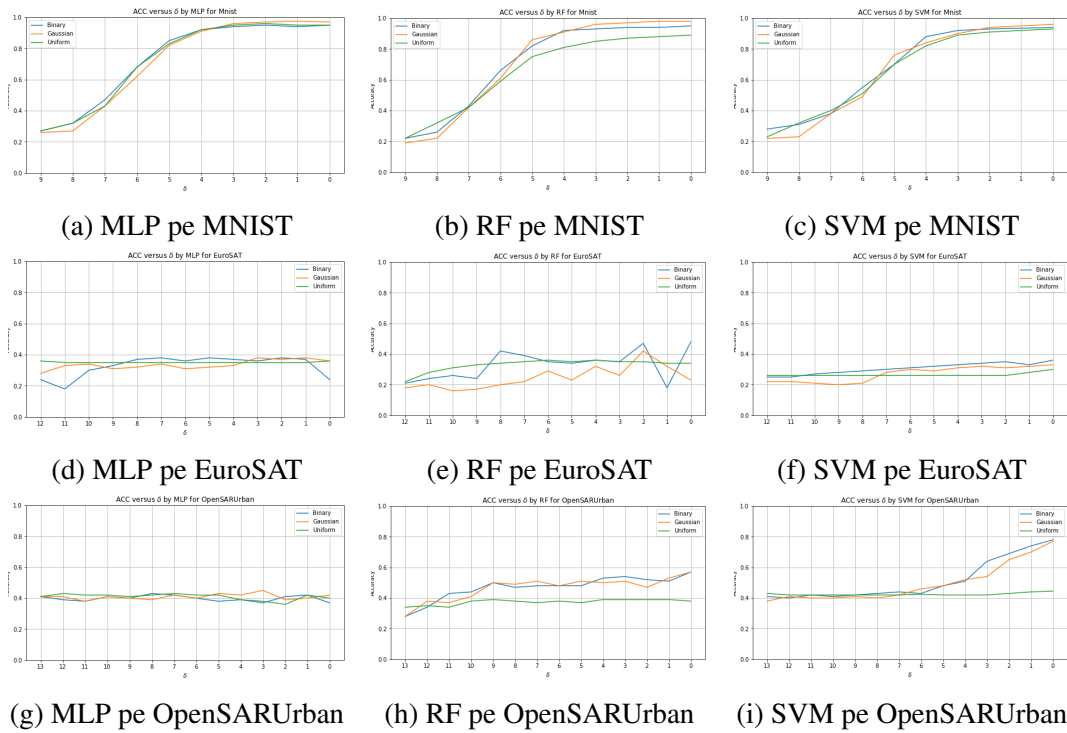


Fig. 6.5 Grafice de acuratețe în funcție de δ pentru diferiți clasificatori și tipuri de matrice de senzori pe cele trei seturi de date, inclusiv MNIST, EuroSAT și OpenSARUrban.




Fig. 6.6 Curba acurateții clasificării versus diferite valori δ pentru setul de date MNIST.




Fig. 6.7 Curbele de acuratețe a clasificării versus diferite valori δ pentru antrenare comună și o matrice de senzori fixă cu distribuții diferite.

Chapter 7

Concluzii

Această teză îmbunătățește procesarea datelor SAR și fuziunea multispectrală pentru aplicațiile de observare a Pământului (EO) utilizând compressive sensing (CS) și AI/ML. Contribuțiile principale includ:

- Un cadru CS care reduce achiziția de date pentru monitorizarea SAR în timp real.
- Tehnici AI/ML (CNN, SVM, t-SNE) pentru extragerea și clasificarea caracteristicilor.
- Co-registrarea SAR-MS validată în Delta Dunării.
- Analiza în serii temporale pentru monitorizarea vegetației și utilizării terenului.

7.1 Contribuții Principale

Această lucrare îmbunătățește procesarea datelor EO prin:

- Dezvoltarea unui cadru CS eficient pentru SAR.
- Avansarea analizei SAR-MS cu AI/ML pentru clasificare.
- Propunerea unei metode validate de co-registrare SAR-MS.
- Extinderea analizei pe serii temporale pentru monitorizarea pe termen lung.

7.2 Publicații

7.2.1 Articole în Jurnale

- Keymasi, M., et al., "**Compressive SAR Learning**," *Sensors*, Număr Special pe "Inovații în Fotogrammetrie și Teledetecție," 2024.

7.2.2 Lucrări la Conferințe

- Keymasi, M., et al., "**Classification of Danube Delta Boundaries by Using Machine Learning Algorithms on Co-registered Sentinel-1 and Sentinel-2 Data**," *Advanced Topics in Optoelectronics, Microelectronics, and Nanotechnologies XI*, 2023.
- Keymasi, M., et al., "**An Efficient Compressive Learning Method on Earth Observation Data**," *IGARSS 2023*, IEEE, 2023.
- Keymasi, M., și Datcu, M., "**Analyzing Temporal Changes in the Danube Delta: A Time Series Study with Co-registered Sentinel-1 and Sentinel-2 Data**," *ATOMS 2024 Conference*.
- Keymasi, M., et al., "**Goal-Oriented Semantic Modules for SAR Ship Detection**," *CoSeRa 2024 Conference*.
- Keymasi, M., et al., "**Hybrid GAN and Fourier Transformation for SAR Ocean Pattern Image Augmentation**," *IEEE MetroSea 2024*.

7.3 Lucrări Viitoare

Direcțiile viitoare includ:

- **Rezistență la Zgomot:** Dezvoltarea de algoritmi CS robuști.
- **Procesare în Timp Real:** Valorificarea calculului în cloud/edge.
- **Calcul Cuantic și AI:** Utilizarea calculului cuantic pentru analiză SAR mai rapidă.
- **Aplicații Extinse pe Serii Temporale:** Aplicare în studii urbane și climatice.
- **Fuziune de Date Îmbunătățită:** Integrarea datelor de la senzori precum LiDAR.

Aceste direcții vizează avansarea procesării SAR și a aplicațiilor de EO.

References

- [1] Baraniuk, R. G. (2007). Compressive sensing [lecture notes]. *IEEE Signal Processing Magazine*, 24(4):118–121.
- [2] Belgiu, M. and Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114:24–31.
- [3] Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1):2–16.
- [4] Calderbank, R., Jafarpour, S., and Schapire, R. (2009). Compressed learning: Universal sparse dimensionality reduction and learning in the measurement domain. *Preprint*.
- [5] Campbell, J. B. and Wynne, R. H. (2011). *Introduction to Remote Sensing*. Guilford Press, New York, 5th edition.
- [6] Candes, E. (2006). Compressive sampling. 3:1433–1452.
- [7] Candes, E. and Tao, T. (2005). Decoding by linear programming. *IEEE Transactions on Information Theory*, 51(12):4203–4215.
- [8] Candès, E. J., Romberg, J. K., and Tao, T. (2006). Stable signal recovery from incomplete and inaccurate measurements. *Communications on Pure and Applied Mathematics*, 59(8):1207–1223.
- [9] Candès, E. J. and Tao, T. (2006). Near-optimal signal recovery from random projections: Universal encoding strategies? *IEEE Transactions on Information Theory*, 52(12):5406–5425.
- [10] Cetin, M. and Karl, W. C. (2014). Sparsity-driven synthetic aperture radar imaging: Reconstruction, robustness, and model uncertainty. *IEEE Signal Processing Magazine*, 31(4):27–40.
- [11] Davenport, M. A., Wakin, M. B., Duarte, M. F., and Baraniuk, R. G. (2010). Introduction to compressive sensing. *IEEE Signal Processing Magazine*, 25(2):21–30.
- [12] Deng, L. (2012). The mnist database of handwritten digit images for machine learning research [best of the web]. *IEEE Signal Processing Magazine*, 29(6):141–142.
- [13] Doe, J. and Smith, J. (2021). Future directions in earth observation technology. *International Journal of Remote Sensing*.
- [14] Donoho, D. L. (2006). Compressed sensing. *IEEE Transactions on Information Theory*, 52(4):1289–1306.

- [15] Dosovitskiy, A., Beyer, L., Kolesnikov, A., et al. (2021). An image is worth 16x16 words: Transformers for image recognition at scale. In *International Conference on Learning Representations*.
- [16] Drusch, M., Del Bello, U., Carlier, S., et al. (2012). Sentinel-2: Esa’s optical high-resolution mission for gmes operational services. *Remote Sensing of Environment*, 120:25–36.
- [17] (ESA), E. S. A. (2020). Synthetic aperture radar: Remote sensing applications. *ESA Publications*. Accessed on 2023-10-15.
- [18] Finkl, C. and Makowski, C. (2022). Identification of domain complexes in the danube delta coastal belt using the biophysical cross-shore classification system (bccs), based on interpretation of satellite imagery. *Journal of Coastal Research*, 38(1):1–18.
- [19] Jensen, J. R. (2007). *Remote Sensing of the Environment: An Earth Resource Perspective*. Pearson, Upper Saddle River, NJ, 2nd edition.
- [20] Lloyd, S. (1982). Least squares quantization in pcm. *IEEE Transactions on Information Theory*, 28(2):129–137.
- [21] Maggiori, E. et al. (2017). Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2):645–657.
- [22] Manjunath, B. and Ma, W. (1996). Texture features for browsing and retrieval of image data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(8):837–842.
- [23] Melgani, F. and Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8):1778–1790.
- [24] Mousavi, A., Patel, V. M., and Baraniuk, R. G. (2015). Deep learning for compressive sensing. *IEEE Transactions on Signal Processing*, 63(22):6001–6014.
- [25] Niculescu, S., B. J. and Lardeux, C. (2020). Synergy of high-resolution radar and optical images for mapping wetland macrophytes on the danube delta. In *Remote Sensing Symposium*, volume 12, page 2188.
- [26] Niculescu, S., Boissonnat, J., Lardeux, C., Roberts, D., Hanganu, J., et al. (2020). Synergy of high-resolution radar and optical images satellite for identification and mapping of wetland macrophytes on the danube delta. *Remote Sensing*, 12(14):2188.
- [27] Pal, M. and Mather, P. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5):1007–1011.
- [28] Patrick Helber, Benjamin Bischke, A. D. and Borth, D. (2019). *EuroSAT: A novel dataset and deep learning benchmark for land use and land cover classification*, volume 12. IEEE.
- [29] Richards, J. A. (2013). Remote sensing digital image analysis.
- [30] Schmitt, M. et al. (2016). Data fusion and integration for multitemporal and multimodal remote sensing: A review of concepts and methods. *Proceedings of the IEEE*, 104(9):1615–1627.

- [31] Schmitt, M. and Zhu, X. (2016). Data fusion and remote sensing: An ever-growing relationship. *IEEE Geoscience and Remote Sensing Magazine*, 4(4):6–23.
- [32] Singh, A. (1989). Digital change detection techniques using remotely sensed data. *International Journal of Remote Sensing*, 10(6):989–1003.
- [33] Thomas Lillesand, R. W. K. and Chipman, J. (2015). Remote sensing and image interpretation.
- [34] Torres, R., Snoeij, P., Geudtner, D., et al. (2012). Gmes sentinel-1 mission. *Remote Sensing of Environment*, 120:9–24.
- [35] Tucker, C. J. (1986). Satellite remote sensing of vegetation. In *Annual Review of Ecology and Systematics*, pages 379–393.
- [36] Veci, L. (2016). Sentinel-1 toolbox sar processing algorithms. Technical report.
- [37] Wang, L. and Yao, M. (2022). Sar and multispectral data integration. *Journal of Applied Remote Sensing*.
- [38] Wang, S., Gao, S., Zhou, L., Liu, R., Zhang, H., Liu, J., Jia, Y., and Qian, J. (2022). Yolo-sd: Small ship detection in sar images by multi-scale convolution and feature transformer module. *Remote Sensing*, 14(20):5268.
- [39] Xie, F., L. B. and Liu, Y. (2022). Research on the coordinate attention mechanism fuse in a yolov5 deep learning detector for the sar ship detection task. *Sensors*, 22(3370):1–15.
- [40] Ye, Y., Yang, C., Zhu, B., Zhou, L., He, Y., and Jia, H. (2021). Improving co-registration for sentinel-1 sar and sentinel-2 optical images. *Remote Sensing*, 13(5):928.
- [41] Zhang, J., Shi, G., Liu, B., Yang, Y., and Xing, X. (2019). Sar ship detection using deep learning: A review. *IEEE Geoscience and Remote Sensing Letters*, 16(8):1200–1204.
- [42] Zhang, T., Zhang, X., Li, J., Xu, X., Wang, B., Zhan, X., Xu, Y., Ke, X., Zeng, T., Su, H., et al. (2021). Sar ship detection dataset (ssdd): Official release and comprehensive data analysis. *Remote Sensing*, 13(18):3690.
- [43] Zhu, X. X. et al. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4):8–36.