



UNIVERSITATEA NAȚIONALĂ DE ȘTIINȚĂ
ȘI TEHNOLOGIE POLITEHNICA BUCUREȘTI



Școala Doctorală de Electronică, Telecomunicații
și Tehnologia Informației

Decizie Nr. 201 din 21.09.2024

REZUMAT TEZĂ DE DOCTORAT

Daniela-Iulia CALOTĂ

METODE HIBRIDE DE INTELIGENȚĂ ARTIFICIALĂ PENTRU
EXTRAGEREA INFORMAȚIILOR DIN IMAGINI SATELITARE

HYBRID METHODS OF AI FOR INFORMATION EXTRACTION FROM
SATELLITE IMAGERY

COMISIA DE DOCTORAT

Prof. Dr. Ing. Gheorghe BREZEANU Universitatea Națională de Știință și Tehnologie Politehnica București	Președinte
Prof. Dr. Habil. Ing. Mihai DATCU Universitatea Națională de Știință și Tehnologie Politehnica București	Conducător 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 Știință și Tehnologie Politehnica București	Referent

BUCUREȘTI 2024

Cuprins

1. Introducere	1
1.1 Prezentarea domeniului tezei de doctorat	1
1.2 Scopul tezei de doctorat	2
1.3 Conținutul tezei de doctorat	2
2. Noțiuni de bază și concepte în teledetecție	3
2.1 Imagistica multispectrală.....	3
2.2 Caracteristicile satelitului Sentinel-2	4
2.3 Imagistica radar cu apertură sintetică.....	4
2.4 Caracteristicile satelitului Sentinel-1	5
2.5 Soluții software	5
3. Noțiuni de bază și concepte în învățarea profundă	7
3.1 Noțiuni de bază și termeni ai rețelelor neurale.....	7
3.2 Rețele neuronale adânci și rețele neuronale convoluționale	8
4. Învățare rapidă pe imagini multispectrale.....	9
4.1 Introducere și literatură	9
4.2 Metode și seturi de date.....	9
4.3 Antrenare bazată pe histogramă	11
4.4 Antrenarea bazată pe Bag-of-Words.....	12
4.5 Antrenare cu patch-uri sub-eșantionate	12
4.6 Antrenare cu o arhitectură mai simplă.....	13
4.7 Reducerea setului de date	13
4.8 Validarea pe alte seturi de date	14
4.9 Învățare rapidă pe date multispectrale cu texturi complexe	14
5. Învățare rapidă pe imagini Radar cu Apertură Sintetică	15
5.1 Introducere și literatură	15
5.2 Metode și seturi de date.....	15
5.3 Antrenarea bazată pe histogramă a datelor Radar cu Apertură Sintetică	16
5.4 Antrenarea bazată pe BoW al imaginilor Radar cu Apertură Sintetică.....	16
5.5 Antrenare cu imagini Radar cu Apertură Sintetică sub-eșantionate	17
5.6 Antrenare pe alte seturi de date Radar cu Apertură Sintetică.....	18

5.7 Introducerea VHRUrbanSAR	18
5.7.1 Antrenarea VHRUrbanSAR pe o Rețea Neuronală Convoluțională	19
5.7.2 Ajustarea fină a VHRUrbanSAR pe OpenSARUrban.....	19
5.7.3 Învățare rapidă pe date Radar cu Apertură Sintetică cu texturi complexe.....	20
6. Practicabilitatea metodei Bag-of-Words pentru învățare rapidă	21
6.1 O comparație între învățarea profundă bazată pe Bag-of-Words și diferite abordări	21
6.2 Demonstrarea cazului de utilizare - Scenariul dezastrelor naturale	22
6.3 Scop alternativ al metodei Bag-of-Words - detectarea alunecărilor de teren.....	23
6.4 Discuție.....	23
6.5 Concluzie.....	24
7. Estimarea indicele de vegetație cu diferență normalizată din imaginile Radar cu Apertură Sintetică folosind Rețele Neuronale Adânci	25
7.1 Introducere și literatură	25
7.2 Metodologii	26
7.3 Rezultate.....	27
7.4 Concluzii	27
8. Concluzii	29
8.1 Rezultatele obținute.....	29
8.2 Contribuții originale	30
8.3. Listă de publicații originale.....	30
8.4 Perspective pentru dezvoltări ulterioare	31
Bibliografie	32

Capitolul 1

Introducere

Înțelegerea corelațiilor dintre elementele naturale este esențială în dezvoltarea sistemelor sofisticate pentru Observarea Pământului (Earth Observation - EO) și analiza acestora. Aceste sisteme sprijină dezvoltarea durabilă prin facilitarea procesului decizional în sectoare precum agricultura, știința climatului și conservarea mediului. Tehnologiile avansate de EO dezvăluie tipare care optimizează practicile de gestionare a terenurilor, îmbunătățesc randamentele culturilor și oferă avertizări timpurii pentru dezastre naturale.

Tehnologiile de teledetecție (Remote Sensing - RS), prin capturarea imaginilor de înaltă rezoluție în diferite regiuni spectrale, ajută la determinarea utilizării terenului, indicilor de vegetație și condițiilor atmosferice. Integrarea Învățării profunde (Deep Learning - DL) cu RS a revoluționat interpretarea datelor prin procesarea eficientă și precisă a seturilor mari de date. Această teză propune algoritmi și metode care accelerează procesarea datelor pe diferite senzori, abordând provocările semnificative din domeniul EO și RS.

1.1 Prezentarea domeniului tezei de doctorat

Imaginile satelitare sunt esențiale pentru aplicații precum monitorizarea mediului și gestionarea dezastrelor. Cercetătorii folosesc aceste imagini pentru a urmări modificări precum defrișarea și urbanizarea [2]. Cu toate acestea, datele RS se confruntă cu dificultăți datorate dimensionalității ridicate, variabilității cauzate de schimbările sezoniere și condițiile meteorologice, precum și diferitelor rezoluții [3]. Metodele de procesare tradiționale, bazate pe algoritmi precum detecția contururilor, întâmpină dificultăți cu tiparele complexe [6, 7]. În contrast, algoritmi DL precum Rețele neuronale adânci (Deep Neural Networks - DNNs) și Rețele neuronale convoluționale (Convolutional Neural Networks - CNNs) oferă performanțe superioare în clasificare, gestionând dimensionalitatea ridicată și variabilitatea, deși necesită resurse extinse și seturi de date etichetate [8].

DL are un impact asupra diverselor domenii, inclusiv Computer Vision (CV) și EO, multe studii subliniind beneficiile sale. De exemplu, [9-11] oferă revizuirii ale arhitecturilor DNN și aplicațiile acestora. În special, comunitatea EO avansează arhitecturi DL pentru a aborda sarcini de

clasificare, cum ar fi clasificarea utilizării terenului și a suprafeței [12-15]. Tehnicile emergente, cum ar fi rețelele neuronale convoluționale grafice, arată promisiuni în corelarea diverselor date [17]. În plus, inovații precum reducerea rețelilor și modificările CNN vizează reducerea timpului de antrenare și îmbunătățirea performanței [33-36].

1.2 Scopul tezei de doctorat

Această teză își propune să dezvolte metode pentru antrenare rapidă cu seturi de date reduse, menținând totodată performanțe comparabile cu tehnicile actuale. Cercetarea se concentrează pe soluții hibride care implică reducerea dimensionalității datelor de intrare și simplificarea arhitecturilor. Abordările cheie includ utilizarea histogramei intensității pixelilor, aplicarea modelului Bag-of-Words (BoW), sub-eșantionarea patch-urilor și simplificarea arhitecturilor. Teza abordează, de asemenea, estimarea Indicelui de Vegetație pe Diferență Normalizată (Normalized Difference Vegetation Index - NDVI) din datele obținute prin tehnologie Radar cu Apertură Sintetică (Synthetic Aperture Radar - SAR), de obicei derivat din imagini multispectrale (Multispectral - MS).

1.3 Conținutul tezei de doctorat

Teza este structurată astfel:

- Capitolul 2: Introduce conceptele de bază în teledetecție și detaliază sursele principale de date — Sentinel-1 și Sentinel-2.
- Capitolul 3: Abordează principiile fundamentale ale învățării profunde și comenzi software relevante
- Capitolul 4: Descrie metodologiile și rezultatele antrenării rapide cu date multispectrale, testând diverse seturi de date, metode și arhitecturi.
- Capitolul 5: Aplică aceleași metode de învățare rapidă la datele SAR, introducând un set de date de imagini SAR de înaltă rezoluție.
- Capitolul 6: Demonstrează practicabilitatea celor mai eficiente algoritmi de învățare rapidă, incluzând cazuri de utilizare și limitări.
- Capitolul 7: Prezintă metode pentru estimarea NDVI din seturile de date SAR.
- Capitolul 8: Conchide teza cu un rezumat al contribuțiilor și viziuni pentru cercetări viitoare.

Capitolul 2

Noțiuni de bază și concepte în teledetecție

Teledetecția este o disciplină utilizată pentru a studia, analiza și înțelege suprafața Pământului prin diverse sisteme de imagine care adună informații în diferite lungimi de undă. Aceste sisteme de imagine facilitează monitorizarea agriculturii, urbanizării, defrișării și schimbărilor climatice. Procesul de teledetecție implică mai multe componente:

1. Sursa de radiație electromagnetică: Pentru senzorii multispectrali, lumina solară servește ca sursă. Pentru imaginile radar, satelitul însuși emite radiația electromagnetică.
2. Calea radiației: Radiația interacționează cu suprafața Pământului și este apoi emisă, reflectată sau transmisă.
3. Ținta: Ținta observată poate fi un tip de acoperire a terenului, un corp de apă sau o zonă urbană.
4. Senzor: Acesta detectează și măsoară radiația. Senzorii pot fi pasivi (detectând radiația naturală) sau activi (emite și primește radiație).
5. Stația de procesare: Această stație digitalizează și procesează datele, convertind datele brute de la senzori în informații semnificative prin calibrări și corecturi. Rezultatele sunt apoi analizate pentru diverse aplicații cum ar fi clasificarea, cartografierea și detectarea schimbărilor [37].

2.1 Imagistica multispectrală

Imagistica multispectrală captează date în mai multe lungimi de undă, convertite în benzi spectrale. Cu senzori echipați pentru a captura date atât pasiv, cât și activ, imaginile multispectrale permit aplicații precum monitorizarea vegetației, clasificarea utilizării terenului și evaluarea calității apei [37][42]. Misiunea Sentinel-2 este un pilon al acestei tehnici, oferind date de la spectrul vizibil până la infraroșu scurt, cu o rezoluție spațială cuprinsă între 10 și 60 de metri pe 13 benzi spectrale [39].

Caracteristicile cheie ale imaginilor multispectrale includ:

- Rază spațială: cea mai mică caracteristică distinctivă, exprimată în metri.

- Rază spectrală: intervalul de lungimi de undă capturate.
- Rază temporală: frecvența capturii imaginilor pentru monitorizarea schimbărilor.
- Rază radiometrică: capacitatea de a detecta diferențe minore în nivelurile de energie.
- Corecții geometrice și atmosferice: ajustări pentru a ține cont de curbura Pământului, rotație și distorsiuni atmosferice [37].

Aspectele de interpretare includ luminozitatea, diferențierea culorilor, textura, formele, umbrele și contextul spațial. Acești factori permit o analiză și clasificare precise a utilizării terenului și caracteristicilor suprafeței [37].

2.2 Caracteristicile satelitului Sentinel-2

Sentinel-2, parte a Programului Copernicus al ESA, are două sateliți echipați cu un Imager Multispectral (MultiSpectral Imager - MSI) care capturează date de la 443 nm la 2190 nm pe 13 benzi spectrale [49]. Caracteristicile cheie ale sateliților Sentinel-2 includ:

- Tip de orbită: orbită sincronică cu soarele la o altitudine de aproximativ 786 km.
- Perioada orbitală: aproximativ 100 minute.
- Lățimea fâșiei: 290 km.

MSI al Sentinel-2 prezintă mai multe benzi cu rezoluții și aplicații variate. Banda 1, operând la o rezoluție de 60m, este utilizată pentru corecția atmosferică și analiza calității apei. Banda 2 și Banda 4, ambele la o rezoluție de 10m, sprijină monitorizarea corpurilor de apă și cartografierea urbană, respectiv. Banda 5 se concentrează pe evaluarea sănătății culturilor la o rezoluție de 20m, în timp ce Banda 8, de asemenea la 10m, este importantă pentru umiditatea solului și sănătatea vegetației. În cele din urmă, Banda 10, la o rezoluție de 60m, este utilizată pentru analizarea umidității solului și vegetației. Această diversitate permite instrumentului să sprijine eficient monitorizarea mediului, agricultura și gestionarea resurselor. Corecțiile, cum ar fi corecția atmosferică (procesorul Sen2Cor), corecțiile geometrice, produsele de reflectanță a suprafeței și mascarea norilor îmbunătățesc calitatea și acuratețea datelor [49].

2.3 Imagistica radar cu apertură sintetică

Radarul cu apertură sintetică utilizează radar cu microunde pentru a obține imagini de înaltă rezoluție, neinfluențabil de condițiile atmosferice și iluminatul zilei. Achiziția de date SAR implică transmiterea semnalelor de microunde către suprafața Pământului și primirea semnalului întors. Acest proces este ilustrat în Figura 2.7, detaliind focalizarea datelor în rație și azimut, filtrarea zgomotului, calibrarea radiometrică și ortorectificarea [51-53].

Datele SAR oferă caracteristici polarimetrice, cum ar fi polarizările VV, HH, VH și HV, oferind multiple straturi de informații despre suprafața Pământului.




Figura 2.7 Achiziția de date în tehnologia SAR.

2.4 Caracteristicile satelitului Sentinel-1

Sentinel-1, parte a Programului Copernicus al ESA, dispune de două sateliți echipați cu radar SAR care operează în banda C (5.405 GHz) și sunt capabili de diferite polarizări. Operând de la o altitudine de 686 km, sistemele SAR ale Sentinel-1 facilitează aplicații de imagistică de înaltă rezoluție, variind de la studii de urbanism până la monitorizarea maritimă. Satelitul Sentinel-1 funcționează în trei moduri, fiecare adaptat pentru aplicații diferite. Modul Interferometric Wide (IW) are o lățime a fâșiei de 250 km și o rezoluție spațială de 5m în rație și 20m în azimut, fiind ideal pentru monitorizarea terenului, detecția schimbărilor și analiza vegetației. Modul Extra Wide (EW), cu o lățime a fâșiei de 400 km și o rezoluție de 40m atât în rație, cât și în azimut, se concentrează pe aplicații maritime și monitorizarea oceanului deschis, fiind potrivit pentru observarea gheții marine și inundațiilor pe scară largă. În cele din urmă, modul Strip Map (SM) are o fâșie mai îngustă de 100 km, cu o rezoluție spațială înaltă de 5m în ambele dimensiuni, fiind eficient pentru studii de urbanism și cartografierea topografică. [54].

2.5 Soluții software

Agencia Spațială Europeană oferă instrumente software pentru procesarea datelor prin Ecosistemul de Spațiu pentru Date Copernicus (Copernicus Data Space Ecosystem - CDSE) [50]. Instrumentele esențiale includ SNAP (Sentinel Application Platform) și modulul său Python, snappy. Interfața grafică a SNAP și comunitatea online extinsă suportă diverse activități de procesare a datelor, în timp ce snappy automatizează aceste procese prin scripturi Python [55].

Capitolul 3

Noțiuni de bază și concepte în învățarea profundă

Învățarea profundă a transformat semnificativ serviciile tradiționale în domenii precum medicina, educația, agricultura și Observarea Pământului [56]. Asemenea modului în care electricitatea a revoluționat societatea, inteligența artificială (Artificial Intelligence - AI) reshapează mediile în domenii precum transportul, tehnologia și sănătatea. Dezvoltarea rapidă a AI, în special a învățării automate (Machine Learning - ML) și DL, a condus la progrese în diverse domenii.

În Observarea Pământului, tehnicile DL sunt aplicate pentru a analiza datele de teledetecție, cum ar fi imaginile multispectrale și radar, permițând dezvoltarea rapidă a aplicațiilor precum clasificarea utilizării terenului și monitorizarea schimbărilor de mediu. Numeroase biblioteci și instrumente, precum TensorFlow, Keras, dlib și OpenCV, facilitează crearea arhitecturilor DL. Programele de gestionare a pachetelor, cum ar fi Anaconda, ajută la integrarea eficientă a acestor instrumente. Având în vedere cerințele computaționale, soluțiile DL sunt optimizate pentru mașini echipate cu GPU-uri, deși soluțiile bazate pe CPU sunt mai puțin eficiente [56].

3.1 Noțiuni de bază și termeni ai rețelelor neurale

Rețelele neurale artificiale (Artificial Neural Networks - ANNs) sunt inspirate de neuronii din creier și conexiunile acestora. Aceste rețele identifică tipare și iau decizii pe baza datelor de intrare printr-un proces de antrenare. Există diverse arhitecturi de rețele neuronale, de la modele simple de regresie liniară și logistică până la structuri mai complexe [56].

- Regresia liniară: Prezice ieșiri continue printr-o funcție de ipoteză a intrărilor și greutateților. Utilizează o funcție de cost pentru a optimiza greutatețile prin metoda Gradient Descent, o strategie care minimizează iterativ diferența dintre ieșirile prezise și cele așteptate. Variantele includ Gradient Descent stocastic, care actualizează parametrii folosind subseturi aleatorii de date de antrenare [56].

- Regresia logistică: Adaugă o funcție de activare (de obicei, o sigmoidă) pentru a lua decizii binare, clasificând datele în funcție de faptul dacă funcția de ipoteză depășește un prag.
- Rețele neuronale de suprafață: Încorporează un singur strat ascuns cu diverse funcții de activare, optimizate prin tehnici precum Gradient Descent. Când sunt introduse multiple straturi ascunse, arhitectura evoluează într-o rețea neurală profundă capabilă să gestioneze sarcini de clasificare complexe [57].

3.2 Rețele neuronale adânci și rețele neuronale convoluționale

Rețelele neuronale adânci folosesc mai multe straturi ascunse pentru a detecta tipare progressively complexe în date. Primul strat poate identifica caracteristici de bază, cum ar fi marginile, în timp ce straturile ulterioare detectează structuri mai complexe, culminând cu recunoașterea obiectelor complete (de exemplu, fețe) [57].

Rețelele neuronale convoluționale extind DNN-urile prin includerea operațiunilor convoluționale, esențiale pentru sarcini precum recunoașterea imaginilor. Aceste operațiuni implică aplicarea de filtre asupra datelor de intrare pentru a detecta caracteristici specifice. Arhitectura unui CNN include, de obicei:

1. Zero Padding: Asigură că filtrul nu reduce dimensiunea de intrare.
2. Convoluție (Conv2D): Aplică un filtru pentru a detecta structuri, deplasându-se în pași (strides).
3. Funcția de activare: De obicei, o Unitate Rețea Liniară Rectificată (ReLU) pentru procesare non-liniară.
4. Max Pooling: Reduce dimensiunea datelor pentru a diminua dimensionalitatea.
5. Regularizare (Dropout): Previne supraînvățarea (overfitting) prin eliminarea neuronilor aleatori.
6. Flattening: Converteste datele matricii într-un vector.
7. Stratul dens: Strat complet conectat cu funcții de activare.
8. Stratul de ieșire: Folosește funcții de activare precum sigmoid sau SoftMax pentru sarcinile de clasificare [59].

Keras și TensorFlow sunt biblioteci populare pentru dezvoltarea CNN-urilor și altor modele DL. Ele oferă instrumente cuprinzătoare pentru a crea, antrena și implementa eficient rețele neuronale. Înțelegerea blocurilor și funcțiilor specifice din aceste biblioteci este crucială pentru implementarea soluțiilor DL eficiente.

Capitolul 4

Învățare rapidă pe imagini multispectrale

4.1 Introducere și literatură

Rețelele neuronale adânci au avansat substanțial domeniul Viziunii Computerizate (Computer Vision), cu Rețele neuronale convoluționale, fiind prominente pentru clasificarea imaginilor [62]. Cu toate acestea, aceste rețele necesită resurse computaționale semnificative și timp pentru antrenare, o problemă amplificată atunci când se gestionează date de Observare a Pământului, care sunt considerate date mari (Big Data) [29]. În mod specific, EO implică adesea imagini multispectrale sau hiperspectrale (Hyperspectral - HS), care au mai multe canale decât imaginile RGB tipice.

Provocarea este amplificată de lipsa seturilor de date etichetate în EO. Seturi de date notabile includ BigEarthNet [84], care oferă imagini MS extinse [26]. Studiile anterioare au integrat Învățarea profundă cu EO cu diverse grade de succes. De exemplu, [63] oferă o revizuire detaliată a aplicațiilor DL în EO, în timp ce [64] și [65] introduc arhitecturi inovatoare DNN pentru sarcini specifice, cum ar fi detecția obiectelor și clasificarea imaginilor SAR.

Acest capitol își propune să examineze metodele care accelerează antrenarea CNN pe imagini MS. Deși modelele precum transferul de învățare există, ele adesea nu performează bine cu imaginile MS din cauza informațiilor spectrale suplimentare dincolo de spectrul vizibil [26]. Explorăm tehnici de reducere, inclusiv dimensiuni reduse ale setului de date și dimensiuni de intrare, pentru a facilita antrenarea mai rapidă fără a compromite semnificativ performanța.

4.2 Metode și seturi de date

Explicații detaliate și rezultate sunt prezentate în [1], [60] și [61]. Detalii despre seturile de date MS utilizate sunt rezumate grafic în Figura 4.1. Seturile de date includ BigEarthNet, EuroSAT

[66], UC-Merced [22] și RSI-CB [72], fiecare acoperind diferite geografii și clase tematice, cum ar fi vegetația și zonele urbane.

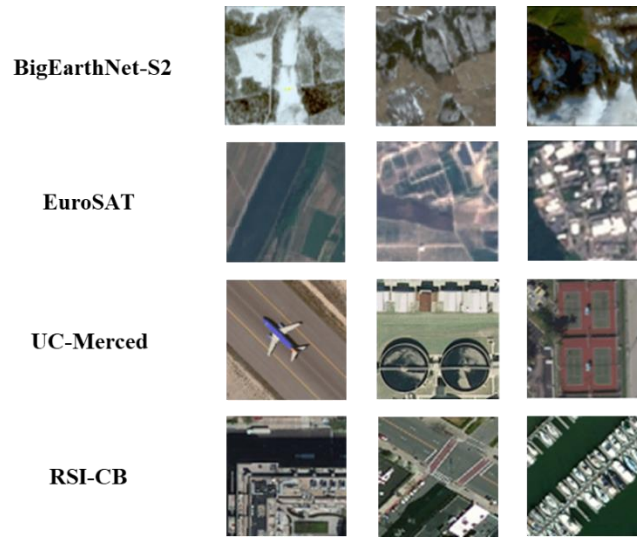


Figura 4.1 Patch-uri din seturile de date MS utilizate pe parcursul lucrării noastre, revelând complexitatea și diversitatea datelor folosite.

Pentru a demonstra antrenarea eficientă cu seturi de date reduse, am folosit diverse metode (Figura 4.2):

- Antrenare bazată pe histogramă: Convertirea patch-urilor de imagine în histogramme de intensitate a pixelilor.
- Antrenare prin Bag-of-Words: Înlocuirea patch-urilor de imagine cu reprezentări BoW.
- Antrenare pe patch-uri sub-eșantionate: Reducerea dimensiunilor imaginilor prin sub-eșantionare.

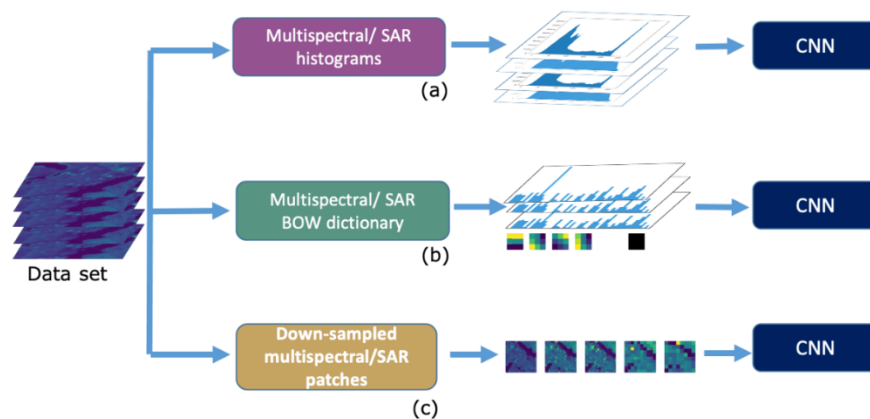


Figura 4.2 Descrierea metodologiilor avansate pentru a obține intrări optimizate pentru CNN-uri în timpul antrenării. Prima abordare va fi utilizarea histogramelor de intensitate a pixelilor, a doua va deriva Bag-of-Words din setul de date pentru a alimenta rețeaua, în timp ce a treia lucrează cu patch-uri sub-eșantionate.

Aceste abordări vizează reducerea dimensiunii setului de date, minimizarea timpului de antrenare și simplificarea arhitecturii prin reducerea parametrilor. Obiectivul general este de a valida aceste metode pe diverse seturi de date pentru a asigura generalizabilitatea.

Arhitecturile sunt reprezentate în Figura 4.3.

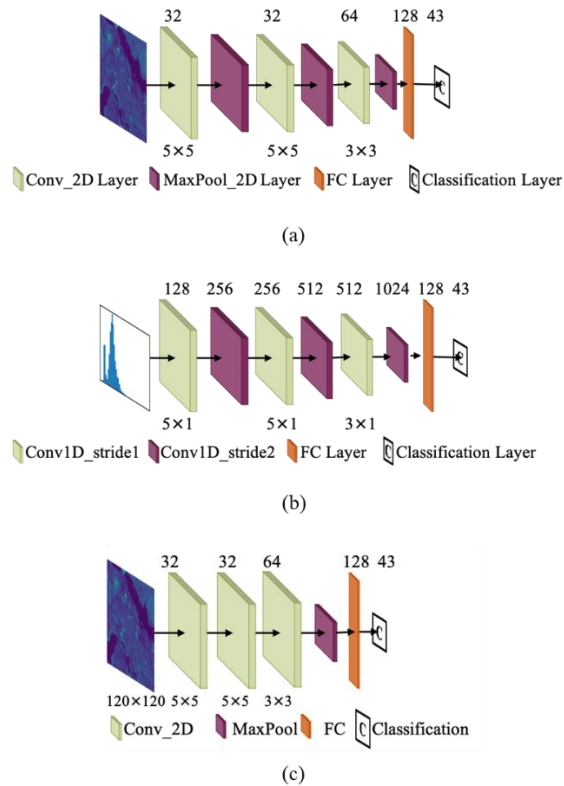


Figura 4.3 Arhitecturile CNN utilizate în lucrarea actuală. (a) *CNN_patch* – Configurare CNN pentru antrenarea patch-urilor, fie cu patch-uri originale, fie cu patch-uri sub-șantionate. (b) *CNN_1D* – Arhitectura CNN propusă pentru antrenarea bazată pe histogramă/BoW. (c) *CNN_simple* – Arhitectură CNN simplificată.

4.3 Antrenare bazată pe histogramă

Fluxul de lucru implică conversia patch-urilor de imagine în histograme cu dimensiuni diferite ale bin-urilor (32, 100, 250) și antrenarea acestor histograme folosind arhitectura CNN_1D (Figura 4.3.b). Rezultatele (Tabelul 4.3) arată că, chiar și cu histograme de 32 de bin-uri, timpii de antrenare sunt semnificativ reduși, de exemplu, de la 5040 de minute la 480 de minute pentru patch-uri cu 12 canale, cu doar o scădere marginală a metricilor de performanță. Ultimele două rânduri, marcate cu Ref. perform, sunt performanțele de referință și rezultatele fără algoritmi propuși. Acest lucru este observat pe parcursul întregii teze.

Tabelul 4.3 Rezultatele antrenării BigEarthNet-S2 cu histograme ale intensităților pixelilor pe CNN_1D.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
H-RGB-32	0.7457	0.585	0.6542	0.6106	300	0.11
H-12B-32	0.7787	0.6549	0.7102	0.6757	480	0.43
H-RGB-100	0.7652	0.6008	0.6724	0.6274	420	0.33
H-12B-100	0.7885	0.6592	0.7175	0.6812	500	1.31
H-RGB-250	0.7604	0.5875	0.6622	0.6152	690	0.84
H-12B-250	0.7712	0.6655	0.7139	0.6839	750	3.29
Ref. perform (RGB)	0.7949	0.5729	0.6656	0.6065	360	47.5
Ref. perform (12B)	0.8103	0.6621	0.7287	0.6872	5040	190

4.4 Antrenarea bazată pe Bag-of-Words

Această metodă implică generarea de BoW pentru fiecare patch de imagine și antrenarea CNN_1D cu reprezentări BoW. Evaluările cu dimensiuni ale dicționarului de 50, 100 și 250 de intrări (Tabelul 4.4) au arătat că, chiar și cu o dimensiune mai mică a dicționarului, antrenarea BoW depășește antrenarea bazată pe histogramă, în special în metricile de recuperare.

Tabelul 4.4 Rezultatele antrenării BigEarthNet-S2 cu BoW pe CNN_1D.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
BoW-50	0.8023	0.72	0.759	0.735	200	0.05
BoW-100	0.8151	0.7316	0.7706	0.7466	250	0.11
BoW-250	0.8272	0.7236	0.7711	0.7417	396	0.28
Ref. perform (RGB)	0.7949	0.5729	0.6656	0.6065	360	47.5
Ref. perform (12B)	0.8103	0.6621	0.7287	0.6872	5040	190

4.5 Antrenare cu patch-uri sub-eșantionate

Folosind arhitectura CNN_patch, patch-uri sub-eșantionate (prin factori de scalare de la 2 la 15) au fost evaluate (Figura 4.5). Antrenarea pe patch-uri sub-eșantionate a demonstrat că, deși se pierde o parte din rezoluția spațială, metricile generale de clasificare rămân stabile, confirmând utilitatea dimensiunilor reduse de intrare.

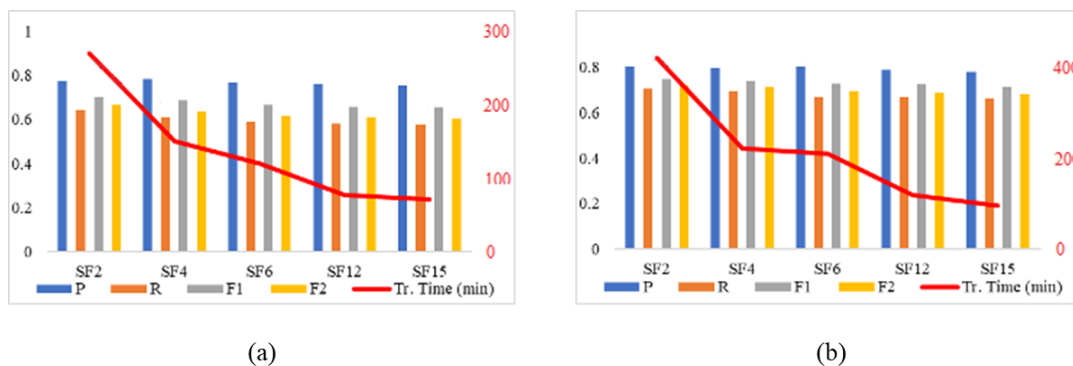


Figura 4.5 Rezultatele antrenării patch-urilor pe CNN_patch cu factori de scalare (SF) de 2, 4, 6, 12 și 15 pentru (a) patch-uri RGB și (b) patch-uri cu 12 canale. SF de 2 rezultă în patch-uri de dimensiune 60×60 , SF de 4 în dimensiune 30×30 , SF de 6 în dimensiune 20×20 , SF de 12 în dimensiune 10×10 , iar SF de 15 în dimensiune 8×8 .

4.6 Antrenare cu o arhitectură mai simplă

Arhitectura CNN simplificată (CNN_simple, Figura 4.3.c) cu mai puține straturi și sub-eșantionare drastică a fost testată. Rezultatele (Tabelul 4.5) indică o performanță comparabilă cu arhitecturile complexe, subliniind beneficiul unui număr mai mic de parametri și reducerea supraînvățării.

Tabelul 4.5 Rezultatele antrenării pe arhitectura CNN_simple.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
RGB	0.7962	0.6556	0.7185	0.6793	330	47.55
12B	0.8041	0.6725	0.7484	0.6937	5060	190
Ref. perform (RGB)	0.7949	0.5729	0.6656	0.6065	360	47.5
Ref. perform (12B)	0.8103	0.6621	0.7287	0.6872	5040	190

4.7 Reducerea setului de date

Am explorat impactul asupra performanței rezultând din reducerea dimensiunii setului de date de antrenare la 50%, 20% și 10%. Combinarea reducerii setului de date cu antrenarea bazată pe histogramă și BoW a diminuat semnificativ timpul de antrenare, menținând în același timp o performanță satisfăcătoare (Tabelul 4.6).

Tabelul 4.6 Rezultatele antrenării pe 10% din setul de date de antrenare pe BOW-100 și H-250.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
H-12B-250	0.7331	0.612	0.6671	0.6329	75	0.335
BoW-100	0.7861	0.7123	0.7474	0.7259	25	0.02
Ref. perform (RGB)	0.7949	0.5729	0.6656	0.6065	360	47.5
Ref. perform (12B)	0.8103	0.6621	0.7287	0.6872	5040	190

4.8 Validarea pe alte seturi de date

Pentru a valida generalizabilitatea rețelelor antrenate cu BoW, am ajustat fin CNN_1D antrenat pe BigEarthNet-BoW pe seturile de date EuroSAT și UC-Merced (Figura 4.9). Ambele seturi de date au demonstrat metrice de performanță îmbunătățite cu BoW față de reprezentările tradiționale de intrare, stabilind viabilitatea BoW pentru diverse seturi de date.




Figura 4.9 Rezultatele ajustării fine a CNN_1D antrenat cu BoW din BigEarthNet-S2 pe UC-Merced și EuroSAT.

4.9 Învățare rapidă pe date multispectrale cu texturi complexe

În cele din urmă, am testat metoda pe RSI-CB, un set de date cu texturi complicate și rezoluție spațială ridicată. Rezultatele (Tabelul 4.7) au confirmat că BoW permite învățarea eficientă chiar și cu texturi complexe de înaltă rezoluție, reducând în continuare timpul de antrenare și dimensiunea setului de date.

Tabelul 4.7 Rezultatele antrenării RSI-CB BoW pe CNN_1D.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
RSI-CB BoW	0.9783	0.9773	0.9778	0.9775	16	0.03
Ref. perform	0.8301	0.7644	0.7953	0.7764	110	4.46

Capitolul 5

Învățare rapidă pe imagini Radar cu Apertură Sintetică

5.1 Introducere și literatură

Radarul cu apertură sintetică este esențial în teledeteție, oferind date de înaltă rezoluție indiferent de condițiile atmosferice sau de lumina naturală. Totuși, imaginile SAR prezintă provocări unice, inclusiv zgomot și texturi complexe. Metodologiile de învățare profundă utilizate pentru a aborda aceste provocări implică adesea învățarea prin transfer, optimizarea hardware-ului, tăierea modelului, cuantificarea și ajustările ratei de învățare adaptive.

Strategiile arhitecturale cheie, cum ar fi rețelele neuronale convoluționale și modelele bazate pe atenție (cum ar fi transformerile), au arătat eficacitate [78]. Augmentarea datelor rămâne crucială din cauza rarității seturilor mari și diverse de date SAR, îmbunătățind performanța modelului prin mărirea artificială a seturilor de date de antrenare [80]. Scopul este de a optimiza antrenarea imaginilor SAR pentru diverse aplicații, inclusiv scenarii în timp real.

5.2 Metode și seturi de date

Explicații detaliate și rezultate sunt prezentate în [1], [60], [61] și [73]. Capitolul evaluează aplicabilitatea metodelor precum histogramme, Bag-of-Words și sub-eșantionarea pe imaginile SAR folosind seturi de date precum OpenSARUrban [27], BigEarthNet-S1 [84] și VHRUrbanSAR (Figura 5.1). Fiecare set de date acoperă diverse regiuni globale și domenii tematice, de la clase urbane până la vegetație.

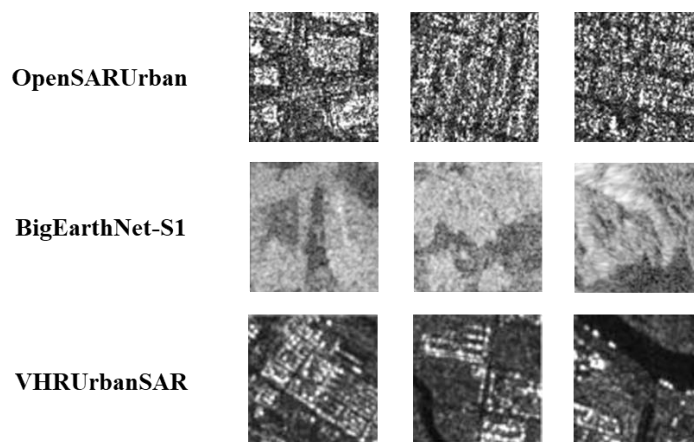


Figura 5.1 Patch-uri din seturile de date SAR utilizate pe parcursul lucrării noastre, revelând complexitatea și diversitatea datelor folosite.

5.3 Antrenarea bazată pe histogramă a datelor Radar cu Apertură Sintetică

Antrenare utilizând histograme ale intensității pixelilor cu bin-uri de dimensiune 250 a fost realizată cu arhitectura CNN_1D și o arhitectură personalizată VGG-19 (VGG19_red). Rezultatele (Tabelul 5.3) indică o performanță păstrată în întreaga arhitectură, cu o supraînvățare mai puțin observată în CNN_1D comparativ cu antrenarea cu patch-uri.

Tabelul 5.3 Rezultatele antrenării CNN_1D și VGG19_red cu histograme din OpenSARUrban.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
CNN 1D	0.6532	0.4782	0.5522	0.5053	50	0.31
VGG19 red	0.691	0.5257	0.5971	0.5521	72	0.31
Ref. perform (CNN patch)	0.5497	0.5124	0.5304	0.5195	15	1.22
Ref. perform (VGG 19)	0.6213	0.6132	0.6172	0.6148	90	1.22

5.4 Antrenarea bazată pe BoW al imaginilor Radar cu Apertură Sintetică

Metoda BoW, cu dimensiuni ale dicționarului de 50, 100 și 250, a fost aplicată atât pe CNN_1D, cât și pe VGG19_red. Timpii de antrenare au fost accelerați cu o pierdere minimă a performanței (Tabelul 5.4). Tehnici precum augmentarea datelor, ponderarea claselor și învățarea prin transfer au fost testate pentru a îmbunătăți rezultatele. Augmentarea datelor a îmbunătățit semnificativ metricile de performanță cu aproximativ 10%.

Tabelul 5.4 Rezultatele antrenării diferitelor arhitecturi pe BoW al datelor SAR.

No. dict. BoW entries	P	R	F1	F2	Timp [min]	Dm [GB]
ARHITECTURĂ: CNN_1D						
50	0.6345	0.4883	0.5519	0.5119	33	0.003
100	0.6121	0.4709	0.5323	0.4937	36	0.006
250	0.6233	0.4476	0.521	0.4743	40	0.016
Ref. perform (CNN patch)	0.5497	0.5124	0.5304	0.5195	15	1.22
ARHITECTURĂ: VGG19_RED						
50	0.7317	0.5075	0.5993	0.5406	43	0.003
100	0.7221	0.4881	0.5825	0.5219	47	0.006
250	0.705	0.5138	0.5944	0.5433	55	0.016
Ref. perform (VGG 19)	0.6213	0.6132	0.6172	0.6148	90	1.22

5.5 Antrenare cu imagini Radar cu Apertură Sintetică sub-șantionate

Folosind imagini sub-șantionate (reducând 100x100 pixeli la dimensiuni de până la 10x10), antrenarea a fost efectuată pe CNN_patch și VGG19 (Tabelul 5.5). Performanța a scăzut odată cu creșterea factorilor de sub-șantionare, dar rezultate acceptabile au fost menținute cu sub-șantionare de 50%.

Tabelul 5.5 Rezultatele antrenării datelor SAR la diferiți factori de sub-șantionare.

SF	P	R	F1	F2	Timp [min]	Dm [GB]
ARHITECTURĂ: CNN_patch						
2	0.7436	0.4307	0.5455	0.4703	40	0.003
4	0.7078	0.2483	0.3677	0.2854	33	0.006
5	0.6603	0.2338	0.3453	0.2685	25	0.016
10	0.4681	0.1205	0.1916	0.1415	20	
Ref. perform (CNN patch)	0.5497	0.5124	0.5304	0.5195	15	1.22
ARHITECTURĂ: VGG19						
2	0.7312	0.4441	0.5526	0.482	50	0.003
Ref. perform (VGG 19)	0.6213	0.6132	0.6172	0.6148	90	1.22

5.6 Antrenare pe alte seturi de date Radar cu Apertură Sintetică

Metodele au fost extinse la BigEarthNet-S1, demonstrând că BoW poate fi eficient chiar și pe seturi de date care conțin predominant clase de vegetație (Tabelul 5.6). În ciuda zgomotului de tip speckle, CNN-ul a clasificat cu succes intrările BoW, comparabil cu antrenarea pe patch-uri.

Tabelul 5.6 Rezultatele antrenării BigEarthNet-S1 BoW pe CNN_1D.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
BigEarthNet-S1	0.7522	0.6013	0.6706	0.632	403	0.28
Ref. perform	0.7449	0.5204	0.6111	0.553	618	63.3

5.7 Introducerea VHRUrbanSAR

VHRUrbanSAR este un set de date nou care conține imagini SAR de înaltă rezoluție, fiind deosebit de valoros datorită diversității sale în scene urbane și disponibilității în multiple tipuri de date (Figura 5.3, Tabelul 5.7). Setul de date a fost utilizat pentru a ajusta modelele pre-antrenate și pentru a studia învățarea rapidă.




Figura 5.3 Exemple de patch-uri din fiecare clasă: (a) Aeroport; (b) Zonă rezidențială densă; (c) Zonă rezidențială generală; (d) Clădiri înalte; (e) Autostrăzi; (f) Zone industriale; (g) Zone cu case mobile; (h) Zgarie-nori; (i) Vegetație urbană; (j) Vile.

Tabelul 5.7 Distribuția claselor în VHRUrbanSAR.

<i>Class index</i>	<i>Class name</i>	<i>No. of patches per class</i>
1	Airports	232
2	Dense residential area	3116
3	General residential area	314
4	High buildings	2378
5	Highways	862
6	Industrial areas	294
7	Mobile homes	8
8	Skyscrapers	1993
9	Urban vegetation	756
10	Villas	81
Total		8234

5.7.1 Antrenarea VHRUrbanSAR pe o Rețea Neuronală Convoluțională

Rețelele antrenate pe VHRUrbanSAR utilizând arhitectura CNN_patch cu diferite tipuri de date au arătat că tipul de date uint16 a avut performanțe mai bune decât altele, posibil datorită detaliilor reduse ale imaginii care ajută generalizarea. Precizia maximă este de 73,66%.

5.7.2 Ajustarea fină a VHRUrbanSAR pe OpenSARUrban

Învățarea prin transfer a fost aplicată prin ajustarea fină a modelului VHRUrbanSAR pe patch-urile din OpenSARUrban. Rezultatele (Tabelul 5.9) au evidențiat că anumite clase, cum ar fi vegetația urbană și zgârie-norii, au beneficiat semnificativ de pe urma procesului de ajustare fină.

Tabelul 5.9 Performanța imaginilor selectate în VHRUrbanSAR după Învățarea prin Transfer.

<i>Class</i>	<i>A</i>	<i>P</i>	<i>F1</i>
<i>Airports</i>	0.45	0.42	0.4
<i>Dense residential area</i>	0.56	0.53	0.49
<i>General residential area</i>	0.57	0.59	0.55
<i>High buildings</i>	0.23	0.25	0.2
<i>Highways</i>	0.35	0.37	0.32
<i>Industrial areas</i>	0.3	0.29	0.25
<i>Skyscrapers</i>	0.81	0.79	0.75
<i>Urban vegetation</i>	0.85	0.8	0.75

5.7.3 Învățare rapidă pe date Radar cu Apertură Sintetică cu texturi complexe

În cele din urmă, metodele BoW au fost testate pe date SAR de înaltă rezoluție din VHRUrbanSAR. Rezultatele (Tabelul 5.10) au confirmat capacitatea CNN-ului de a învăța din reprezentările BoW, oferind o performanță robustă în ciuda prezenței zgomotului de tip speckle.

Tabelul 5.10 Rezultatele antrenării VHRUrbanSAR BoW pe CNN_1D.

Set date	P	R	F1	F2	Timp [min]	Dm [GB]
VHRUrbanSAR BoW	0.7658	0.7259	0.7436	0.7325	15	0.008
Ref. perform	0.7063	0.7366	0.7211	0.7303	17	0.32

Acest capitol demonstrează că metodele de învățare rapidă propuse, aplicate anterior imaginilor multispectrale, sunt la fel de eficiente pentru imaginile SAR. Abordările au demonstrat câștiguri constante de performanță și eficiență în antrenare pe diverse seturi de date SAR, consolidând astfel potențialul lor pentru aplicații mai ample în teledetecție.

Capitolul 6

Practicabilitatea metodei Bag-of-Words pentru învățare rapidă

6.1 O comparație între învățarea profundă bazată pe Bag-of-Words și diferite abordări

Explicații detaliate și rezultate sunt prezentate în [1]. Acest capitol evaluează funcționalitatea și practicabilitatea metodei Bag-of-Words combinată cu Rețele Neuronale Adânci. Demonstrăm superioritatea învățării profunde bazate pe BoW în diverse scenarii comparativ cu metodele tradiționale și de vârf.

Constatări cheie:

- BoW combinat cu DNN depășește BoW cu Mașini cu Vector de Sprijin (SVM).
- BoW și DNN depășesc rețelele de vârf și metodele bazate pe profilul caracteristicilor.
- Timpul de antrenare și eficiența computațională a BoW sunt superioare abordărilor bazate pe tăiere.

Tabelul 6.1 Comparația între clasificarea BoW cu DNN și clasificarea BoW cu SVM.

Met. de clasificare	P	R	F1	F2
BIGEARTHNET-S2 (BOW)				
DNN	0.8272	0.7236	0.7711	0.7417
SVM	0.6752	0.6031	0.6312	0.6163
RSI-CB (BOW)				
DNN	0.9783	0.9773	0.9778	0.9775
SVM	0.9163	0.8981	0.9071	0.9017
OPENSARURBAN (BOW)				
DNN	0.705	0.5138	0.5944	0.5433
SVM	0.5102	0.4176	0.4593	0.4333
VHRURBANSAR (BOW)				
DNN	0.7658	0.7259	0.7436	0.7325
SVM	0.6162	0.5542	0.5836	0.5656

Tabelul 6.1 arată că metoda noastră depășește SVM în precizie și recuperare pentru seturi de date precum BigEarthNet-S2, RSI-CB, OpenSARUrban și VHRUrbanSAR. Comparația cu EfficientNet și MobileNet a evidențiat, de asemenea, că BoW cu DNN oferă metrici de performanță mai bune și timpi de antrenare reduși.

6.2 Demonstrarea cazului de utilizare - Scenariul dezastrelor naturale

Pentru a susține și mai departe practicabilitatea metodei BoW, am aplicat-o pe un set de date dedicat dezastrelor naturale, incluzând imagini SAR și multispectrale din evenimente precum inundații și uragane. Setul de date a inclus 1135 de patch-uri MS și 875 de patch-uri SAR, împărțite în proporție de 80% pentru antrenare și 20% pentru testare (Figura 6.1).




Figura 6.1 Exemple din setul de date dedicat dezastrelor naturale.

Rezultate:

- BoW cu DNN-uri și arhitecturi VGG-19 a arătat metrici de precizie și recuperare satisfăcătoare atât pentru imaginile SAR, cât și pentru cele MS (Tabelul 6.2).
- Învățarea prin transfer din BigEarthNet-S1 a îmbunătățit clasificarea scenelor de dezastre SAR.

Tabelul 6.2 Rezultatele antrenării pe noua bază de date despre dezastre cu metoda propusă: precizie (P), recuperare (R), scor F1 (F1) și scor F2 (F2), timp de antrenare în minute.

Arhitectură	P	R	F1	F2	Timp [min]
SAR Scenes					
CNN 1D	0.5981	0.5342	0.5643	0.558	10
VGG19	0.6625	0.6101	0.6352	0.63	17
MS Scenes					
CNN 1D	0.691	0.6243	0.656	0.6494	13
VGG19	0.7432	0.6955	0.7186	0.7138	20

Acest caz ilustrează utilitatea metodei BoW în aplicații de cartografiere rapidă, sugerând că poate fi extinsă la alte dezastre naturale și geografii.

6.3 Scop alternativ al metodei Bag-of-Words - detectarea alunecărilor de teren

Am explorat BoW pentru sarcini de detecție, în special detectarea alunecărilor de teren în imagini multispectrale folosind Landslide4sense. Algoritmul a obținut o precizie de 0,56 și o recuperare de 0,45, indicând limitări în sarcinile de detectare din cauza variabilității mari a datelor și a distribuției disproporționate a claselor (Figura 6.4). Mai jos, putem vedea imaginea RGB a alunecării de teren, ieșirea dorită și ieșirea algoritmului.



Figura 6.4 Rezultatele algoritmului pe un eșantion.

6.4 Discuție

Progresele rapide în integrarea datelor de Teledetecție (RS) cu învățarea profundă se confruntă cu provocări legate de complexitatea datelor și cerințele de resurse. Metodele noastre bazate pe BoW urmăresc să echilibreze eficiența antrenării cu performanța, demonstrând rezultate eficiente atât pe date multispectrale, cât și pe date SAR.

Avantajele metodelor bazate pe BoW:

- Reducerea semnificativă a timpului de antrenare al rețelei.
- Eficiente pentru seturi de date de antrenare mici, îmbunătățind fezabilitatea aplicațiilor din domeniul RS.
- Acuratețea clasificării îmbunătățită prin reducerea dimensionalității intrărilor.

Recomandări: Metodele acestea pot fi integrate în cadre precum Deep SAR-Net și optimizate pentru aplicații în timp real. Lucrările viitoare ar trebui să se concentreze pe abordări robuste de învățare prin transfer care să cuprindă date multispectrale și SAR, ajutând la sarcini de regresie și derivând parametri specifici precum NDVI din seturi de date SAR.

6.5 Concluzie

Acest capitol subliniază importanța metodelor de reducere a intrărilor, cum ar fi histogramele și BoW, pentru antrenarea eficientă a datelor EO. Metodele au demonstrat:

- Diminuarea dimensiunii setului de date fără degradarea performanței.
- Păstrarea informațiilor spațiale și spectrale.
- Aplicații practice în scenarii în timp real și reducerea costurilor.

Rezumatul eforturilor computaționale (Tabelul 6.3):

- Generarea eficientă de histograme și BoW pe diverse seturi de date.
- Techniques de paralelizare pentru seturi de date mari, precum BigEarthNet.

Direcții viitoare:

- Extinderea metodelor BoW pentru a include învățarea prin transfer între multiple senzori.
- Generarea de seturi de date mari și diverse din diferite senzori pentru aplicații cuprinzătoare EO.

Tabelul 6.3 Eforturi computaționale pentru generarea histogramelor și BoW pentru fiecare set de date.

Set date	Efort histograme [min]	Efort BoW [min]
BigEarthNet-S2	300	600
OpenSARUrban	10	20
EuroSAT	20	30
UC-Merced	5	7
RCI-CB	15	25
BigEarthNet-S1	180	300
VHRUrbanSAR	5	5

Această cercetare subliniază potențialul metodologiilor simplificate și de învățare rapidă de a depăși provocările în procesarea datelor de teledeteție, deschizând drumul pentru aplicații de învățare profundă mai eficiente și scalabile în Observația Pământului.

Capitolul 7

Estimarea indicele de vegetație cu diferență normalizată din imaginile Radar cu Apertură Sintetică folosind Rețele Neuronale Adânci

7.1 Introducere și literatură

Indicele de Vegetație cu Diferență Normalizată este esențial pentru monitorizarea vegetației, dar este afectat de condițiile atmosferice atunci când este derivat din imagini multispectrale. Datele provenite din radar cu apertură sintetică, neafectate de aceste condiții, oferă o alternativă. Acest capitol prezintă o metodă bazată pe învățare profundă pentru estimarea NDVI din datele SAR, utilizând rețele neuronale convoluționale în acest scop.

Condițiile atmosferice afectează utilitatea imaginilor MS. Metodele existente de detecție a norilor, cum ar fi cele din [91], [92], și algoritmi de îndepărtare a norilor [93], [94], [95], încearcă să atenueze aceste efecte, dar conduc în continuare la pierderi inerente de date. Studiile recente, cum ar fi cele din [96], ilustrează că norii de tip Cirrus distorsionează semnificativ calculele NDVI. Metodele de estimare pe serie temporală [97] oferă soluții parțiale, dar păstrează unele limitări.

Câteva studii au evidențiat potențialul datelor SAR în estimarea indicilor de vegetație. De exemplu, [98] a descris corelația dintre caracteristicile SAR și NDVI pe câmpurile de porumb, iar [90] a explorat utilizarea datelor SAR pentru a compensa datele lipsă în imaginile MS acoperite de nori. Acest capitol folosește datele SAR combinate cu caracteristici suplimentare utilizând CNN-uri pentru a prezice NDVI, simplificând procesul și îmbunătățind eficiența.

7.2 Metodologii

Explicații detaliate și rezultate sunt prezentate în [89]. Am folosit setul de date BigEarthNet [26], [84], care include patch-uri corespunzătoare de la Sentinel-1 (SAR) și Sentinel-2 (MS). Pentru această sarcină, au fost selectate patch-uri legate de vegetație, excluzând 17 etichete irelevante, rezultând 328.586 patch-uri. Algoritmul este ilustrat în Figura 7.1.

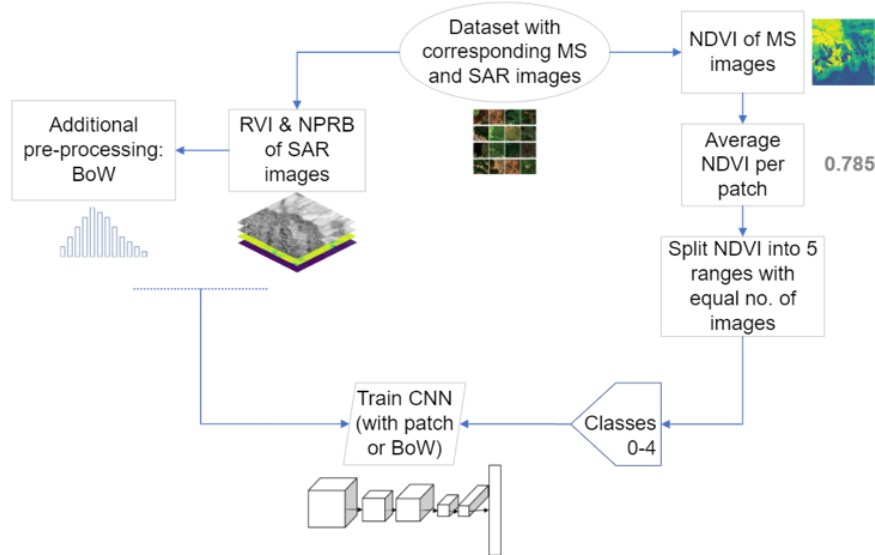


Figura 7.1 Metodologia propusă pentru estimarea NDVI din imaginile SAR.

NDVI a fost calculat folosind Ecuația 7.1, unde NIR este banda 8, iar RED este banda 4 a Sentinel-2 [100].

Ecuația 7.1 Formula pentru calcularea NDVI.

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Patch-urile SAR originale au fost augmentate cu indicele de vegetație radar (Radar Vegetation Index - RVI) și Procedura de Rație Normalizată între Benzi (Normalized Ratio Procedure between Bands - NPRB) pentru a îmbunătăți reprezentarea caracteristicilor (Ecuațiile 7.2 a și b).

Ecuația 7.2 Ecuațiile utilizate împreună cu NDVI pentru a îmbunătăți rezultatele estimării NDVI din imaginile SAR.

$$RVI = \frac{4 \cdot \sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{HV}^0} \quad NPRB = \frac{\sigma_{HV}^0 - \sigma_{HH}^0}{\sigma_{HH}^0 + \sigma_{HV}^0}$$

Au fost utilizate două arhitecturi CNN: o CNN cu 3 straturi și VGG-19 [103]. Estimarea NDVI a fost transformată într-o sarcină de clasificare, împărțind intervalele NDVI în cinci intervale (Tabelul 7.1).

Tabelul 7.1 Distribuția valorilor NDVI și a numărului de patch-uri în cele 5 clase NDVI.

Clasă NDVI	Interv. NDVI	Nr. Patch-uri
1	-0.192 → 0.368	65708
2	0.368 → 0.5325	70054
3	0.5325 → 0.7047	64978
4	0.7047 → 0.7769	63900
5	0.7769 → 0.9291	63953

7.3 Rezultate

Arhitecturile CNN cu trei straturi și VGG-19 au fost antrenate pe patch-uri SAR, obținând valori de precizie de 0,6528 și, respectiv, 0,7018. În ciuda timpilor de antrenare mai lungi, VGG-19 a arătat o performanță îmbunătățită (Tabelul 7.2).

Tabelul 7.2 Rezultatele antrenării imaginilor SAR pentru estimarea NDVI.

Arhitectură	Precizie	Recall	F1	F2
3-layered CNN	0.6528	0.6012	0.6259	0.6208
VGG-19	0.7018	0.6615	0.6811	0.6771

Folosind BoW pentru reducerea dimensionării, timpul de antrenare pentru VGG-19 a scăzut semnificativ, menținând în același timp precizia. Timpii de antrenare pentru CNN-ul cu 3 straturi și VGG-19 au fost reduși la 400 de minute și au oferit în continuare rezultate comparabile.

Figura 7.2 ilustrează patch-uri clasificate corect și incorect, evidențiind că modelele structurate în datele SAR facilitează clasificarea precisă.

7.4 Concluzii

Acest capitol a propus o metodă robustă pentru estimarea NDVI din imaginile SAR folosind CNN-uri și augmentând datele SAR cu RVI și NRPB. Prin transformarea estimării NDVI într-o sarcină de clasificare și utilizarea BoW, am obținut rezultate eficiente și precise.

Pentru a spori robustetea, studiile viitoare ar trebui să se concentreze pe optimizarea ratelor de învățare, creșterea dimensiunii eșantioanelor și ajustarea hiperparametrilor. Această muncă stabilește baza pentru estimarea rapidă a NDVI în condiții atmosferice în care datele MS pot fi nesigure, contribuind semnificativ la monitorizarea vegetației și gestionarea mediului.

Prin adoptarea acestor metodologii, comunitatea de Teledetecție (RS) poate accelera procesele de estimare a NDVI, făcând analiza vegetației mai accesibilă și mai precisă în condiții atmosferice dificile.

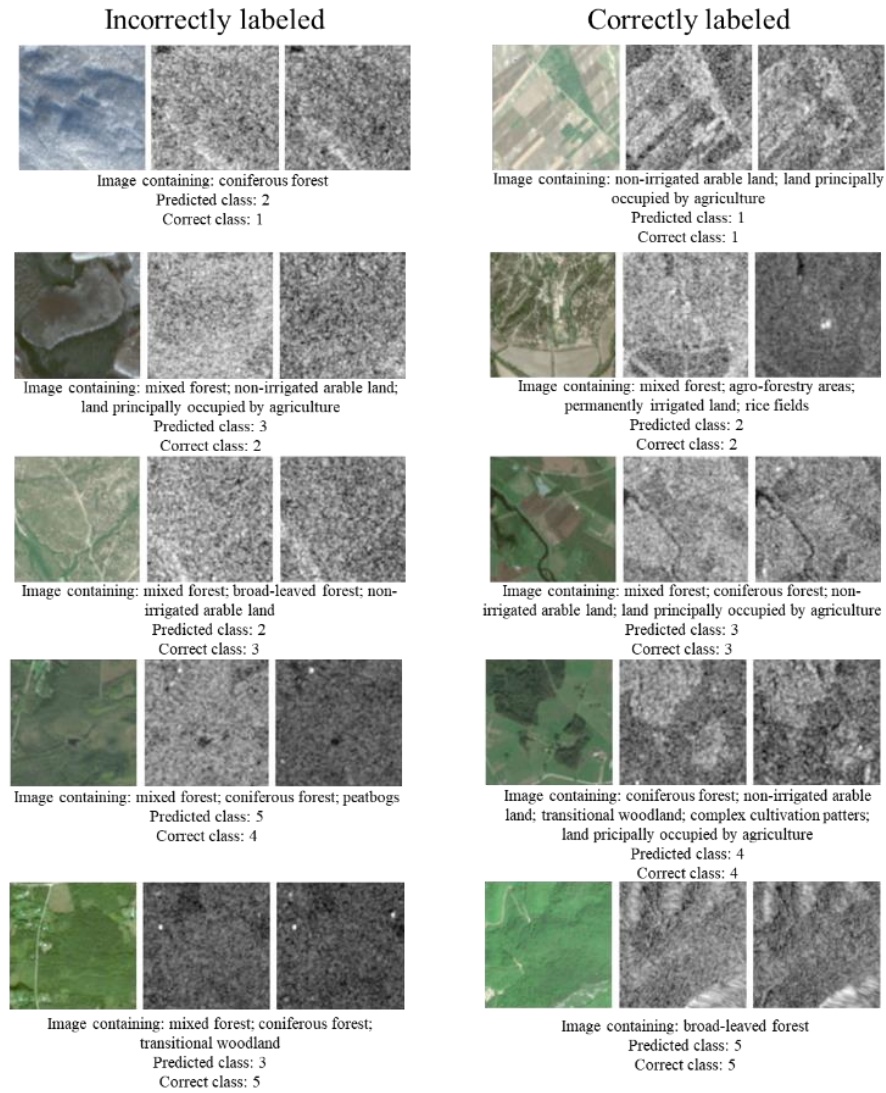


Figura 7.2 Exemple de patch-uri corect clasificate (dreapta) în opoziție cu cele clasificate greșit (stânga).

Capitolul 8

Concluzii

Focusul principal al acestei teze a fost pe dezvoltarea și aplicarea metodologiilor pentru învățare rapidă în contextul datelor de Observație a Pământului (EO). Având în vedere natura extrem de intensivă în resurse a procesării datelor EO, soluțiile propuse urmăresc optimizarea eficienței, menținând în același timp acuratețea. Acest capitol rezumă rezultatele obținute, contribuțiile originale și perspectivele pentru dezvoltări ulterioare.

8.1 Rezultatele obținute

Algoritmii de învățare rapidă dezvoltați și aplicați în această teză includ:

- Folosirea histogramelor în loc de patch-uri pentru antrenarea rețelelor neuronale convoluționale.
- Folosirea Bag-of-Words în loc de patch-uri pentru antrenarea CNN-urilor.
- Subeșantionarea imaginilor înainte de antrenare.
- Antrenare pe arhitecturi mai simple cu sub-eșantionare integrată.
- Antrenare cu seturi de date reduse.

Constatări cheie:

- Metodologia Bag-of-Words: Printre algoritmi, antrenarea rețelelor cu BoW s-a dovedit a fi cea mai eficientă. BoW transformă un patch multicanal într-un singur vector, permițând antrenarea eficientă a rețelei fără pierderi semnificative de informație. Această metodă facilitează învățarea prin transfer simplă între diferite tipuri de date (de exemplu, imagini SAR și multispectrale).
- Subeșantionare: Deși sub-eșantionarea a fost eficientă în mod artificial, implicațiile pentru caracteristicile sensorului au fost de asemenea explorate. A fost creat un nou set de date compus din imagini SAR de foarte înaltă rezoluție, validat cu procesarea BoW pentru a-i întări eficacitatea.
- Estimarea NDVI: Estimarea Indicele de Vegetație cu Diferență Normalizată din datele SAR a fost îmbunătățită prin incorporarea de benzi suplimentare (Indicele de Vegetație Radar (RVI) și

Procedura de Rație Normalizată între Benzi (NRPB)) în imaginile SAR. Aceasta a facilitat estimarea precisă a NDVI în ciuda absenței datelor multispectrale din cauza condițiilor meteorologice nefavorabile sau a lipsei luminii naturale.

- Limitări: În ciuda eficienței BoW pentru sarcinile de clasificare, aplicarea sa în detecție rămâne limitată. Acest lucru a fost evidențiat în exercițiile de detecție a alunecărilor de teren, indicând necesitatea unor algoritmi specifici pentru segmentare în astfel de sarcini.

8.2 Contribuții originale

Iată o listă a principalelor contribuții originale:

- Dezvoltarea unei metode de învățare rapidă și simple cu Bag-of-Words și învățare profundă, adecvată atât pentru date multispectrale, cât și pentru SAR;
- Dezvoltarea unui set de date SAR de foarte înaltă rezoluție;
- Dezvoltarea unui set de date cu date multispectrale și SAR care conțin dezastre naturale;
- Dezvoltarea unui algoritm pentru estimarea NDVI din date SAR.

8.3. Listă de publicații originale

Reviste:

- I. Calota, D. Faur, and M. Datcu, "Dimensionality Reduction of Deep Learning for Earth Observation: Smaller, Faster, Simpler," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 16, pp. 4484-4498, 2023.

Conferințe:

- I. Calota, D. Faur, and M. Datcu, "DNN-Based Semantic Extraction: Fast Learning from Multispectral Signatures," in IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium, 2020.
- I. Calota, D. Faur, and M. Datcu, "Low Resolution for DNN in SAR," in RadarConf 2020, 2020.
- I. Calota, D. Faur, and M. Datcu, "Bag-of-Words for Transfer Learning," 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, Brussels, Belgium, 2021, pp. 808-811.

- I. Calota, D. Faur, and M. Datcu, "Estimating NDVI from SAR Images Using DNN," in IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium, 2022.
- I. Calota, D. Faur, and M. Datcu, "DNN for EO: Fast Training With Reduced Datasets," ESA EO Φ -Week 2020, e-Poster, EO Applications, paper 200, ESA.

8.4 Perspective pentru dezvoltări ulterioare

Deși o mare parte din această muncă s-a concentrat pe învățarea rapidă și BoW, direcțiile de cercetare viitoare includ:

- AI generativă pentru Observația Pământului: Explorarea potențialului AI generative în EO, care ar putea revoluționa sinteza și analiza datelor în acest domeniu specializat.
- Extinderea seturilor de date: Contribuția la crearea de noi seturi de date care să cuprindă imagini cu diferite rezoluții. Deși este comun în viziunea computerizată, astfel de seturi de date sunt dificile de obținut în teledetecție și au un potențial semnificativ pentru avansări ulterioare.

Inovațiile prezentate în această teză oferă contribuții valoroase comunității EO, în special în îmbunătățirea eficienței și practicabilității aplicațiilor învățării profunde în medii cu resurse limitate.

Bibliografie

- [1] I. Calota, D. Faur and M. Datcu, "Dimensionality Reduction of Deep Learning for Earth Observation: Smaller, Faster, Simpler," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 16, pp. 4484-4498, 2023.
- [2] J. D. Moore, "Applications of satellite imagery, visualizations and remote sensing in environmental science: an Earth systems science approach," in *IGARSS '96. 1996 International Geoscience and Remote Sensing Symposium*, Lincoln, NE, USA, 1996.
- [3] S. Q. H. I. e. al., "High Dimensional Satellite Imagery Processing: Challenges and Opportunities," *IEEE Trans. Geosci. Remote Sens.*, vol. 59, no. 12, pp. 10293-10307, 2021.
- [6] J. H. R. e. al., "A Survey of Image Processing Techniques for Feature Extraction,," *IEEE Trans. Image Process.*, vol. 28, pp. 1234-1247, 2019.
- [7] M. A. Rahman and N. C. S. Wong, "Comparative Study on Conventional Image Processing Techniques vs. Machine Learning for Object Recognition," *IEEE Access*, vol. 7, pp. 105978-105989, 2019.
- [8] Y. L. e. al., "Deep Learning in Image Processing: A Comprehensive Survey,," *IEEE Trans. Cybern.*, vol. 50, pp. 337-348, 2020.
- [9] A. Shrestha and A. Mahmood, "Review of Deep Learning Algorithms and Architectures," *IEEE Access*, vol. 7, pp. 53040-53065, 2019.
- [10] N. Aloysius and M. Geetha, "A review on deep convolutional neural networks," in *2017 International Conference on Communication and Signal Processing (ICCSP)*, 2017.
- [11] A. Ajit, K. Acharya and A. Samanta, "A Review of Convolutional Neural Networks," in *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*, 2020.
- [12] G. Cheng, X. Xie, J. Han, L. Guo and G.-S. Xia, "Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13, pp. 3735-3756, 2020.
- [13] A. Alem and S. Kumar, "Deep Learning Methods for Land Cover and Land Use Classification in Remote Sensing: A Review," in *2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, 2020.

- [14] S. Li, W. Song, L. Fang, Y. Chen, P. Ghamisi and J. A. Benediktsson, "Deep Learning for Hyperspectral Image Classification: An Overview," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 9, pp. 6690-6709, 2019.
- [15] L. Zhang, L. Zhang and B. Du, "Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art," *IEEE Geoscience and Remote Sensing Magazine*, vol. 4, no. 2, pp. 22-40, 2016.
- [17] Y. Li, H. Zhang, X. Xue, Y. Jiang and Q. Shen, "Deep learning for remote sensing image classification: A survey," *WIREs Data Mining Knowl Discov*, vol. 8, no. 6, p. 264, 2018.
- [22] Y. Yang and S. Newsam, "Bag-of-Visual-Words and Spatial Extensions for Land-Use Classification," in *Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems*, New York, NY, USA, 2010.
- [27] J. Zhao, Z. Zhang, W. Yao, M. Datcu, H. Xiong and W. Yu, "OpenSARUrban: A Sentinel-1 SAR Image Dataset for Urban Interpretation," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13, pp. 187-203, 2020.
- [33] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," *arXiv.1704.04861*, 2017.
- [34] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *arXiv.1905.11946*, 2020.
- [35] M. Lin, R. Ji, Y. Zhang, B. Zhang, Y. Wu and Y. Tian, "Channel Pruning via Automatic Structure Search," *arXiv.2001.08565*, 2020.
- [36] J. Su, Y. Chen, T. Cai, T. Wu, R. Gao, L. Wang and J. D. Lee, "Sanity-Checking Pruning Methods: Random Tickets can Win the Jackpot," *arXiv.2009.11094*, 2020.
- [37] J. R. Jensen, *Remote Sensing of the Environment: An Earth Resource Perspective*, Upper Saddle River, NJ: Pearson Prentice Hall, 2007.
- [39] ESA, "Sentinel-2 Mission: Objectives," [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>. [Accessed September 2024].
- [42] J. B. Campbell and R. H. Wynne, *Introduction to Remote Sensing*, NY: Guilford Press, 2011.
- [49] [Online]. Available: <https://sentiwiki.copernicus.eu/web/sentinel-2>. [Accessed September 2024].
- [50] [Online]. Available: <https://dataspace.copernicus.eu/>. [Accessed September 2024].
- [51] M. S. Schmitt and T. H. H. T. d. Jong, *Fundamentals of Synthetic Aperture Radar Imaging*, Academic Press, 2018.
- [52] R. J. McLachlan and C. D. H. H. Murphy, *Synthetic Aperture Radar: System Design and Applications*, Wiley-Blackwell, 2017.

- [53] I. C. T. Lee, *Synthetic Aperture Radar Processing: Algorithms and Applications*, Cambridge University Press, 2019.
- [54] [Online]. Available: <https://sentiwiki.copernicus.eu/web/sentinel-1>.
- [55] [Online]. Available: <https://step.esa.int/main/toolboxes/snap/>.
- [56] I. Goodfellow, Y. Bengio and A. Courville, *Deep Learning*, Cambridge, MA, USA: MIT Press, 2016.
- [57] "Neural Networks and Deep Learning," [Online]. Available: <https://www.coursera.org/learn/neural-networks-deep-learning?specialization=deep-learning>. [Accessed November 2019].
- [59] "The Sequential Model," [Online]. Available: https://keras.io/guides/sequential_model/. [Accessed September 2024].
- [60] I. Calota, D. Faur and M. Datcu, "Bag-of-Words for Transfer Learning," in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021.
- [61] I. Calota, D. Faur and M. Datcu, "DNN-Based Semantic Extraction: Fast Learning from Multispectral Signatures," in *IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium*, 2020.
- [62] A. Krizhevsky, I. Sutskever and G. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Neural Information Processing Systems*, 2012.
- [63] X. Zhu, D. Tuia, L. Mou, G. Xia, L. Zhang, F. Xu and F. Fraundorfer, "Deep Learning in Remote Sensing: A Review," *IEEE Geoscience and Remote Sensing Magazine (GRSM)*, 2017.
- [64] S. J. e. al., "An Optimized Deep Neural Network Detecting Small and Narrow Rectangular Objects in Google Earth Images," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13, pp. 1068-1081, 2020.
- [65] J. Geng, H. Wang, J. Fan and X. Ma, "Deep Supervised and Contractive Neural Network for SAR Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, pp. 2442-2459, 2017.
- [66] P. Helber, B. Bischke, A. Dengel and D. Borth, "Introducing Eurosat: A Novel Dataset and Deep Learning Benchmark for Land Use and Land Cover Classification," in *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 2018.
- [67] J. You, X. Li, M. Low, D. Lobell and S. Ermon, "Deep Gaussian Process for Crop Yield Prediction Based on Remote Sensing Data," in *AAAI Conference on Artificial Intelligence*, 2017.
- [68] S. Cui, G. Schwarz and M. Datcu, "Remote Sensing Image Classification: No Features, No Clustering," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 11, pp. 5158-5170, 2015.

- [69] H. Kato and T. Harada, "Image Reconstruction from Bag-of-Visual-Words," *arXiv.1505.05190*, 2015.
- [72] H. Li, X. Dou, C. Tao, Z. Hou, J. Chen, J. Peng, M. Deng and L. Zhao, "RSI-CB: A Large Scale Remote Sensing Image Classification Benchmark via Crowdsorce Data," *arXiv.1705.10450*, 2020.
- [73] I. Calota, D. Faur and M. Datcu, "Low Resolution for DNN in SAR," in *RadarConf 2020*, 2020.
- [78] A. S. B. Z. e. al., "Deep Learning for SAR Image Classification: A Review," *IEEE Trans. Geosci. Remote Sens.*, vol. 59, p. 9472–9485, 2021.
- [80] G. L. e. al., "Data Augmentation Methods for Deep Learning in Remote Sensing Applications: A Review,," *IEEE Trans. Geosci. Remote Sens.*, vol. 58, pp. 1489-1509, 2020.
- [84] G. Sumbul, A. Wall, T. Kreuziger, F. Marcelino, H. Costa, P. Benevides, M. Caetano, B. Demir and V. Markl, "BigEarthNet-MM: A Large-Scale, Multimodal, Multilabel Benchmark Archive for Remote Sensing Image Classification and Retrieval [Software and Data Sets]," *IEEE Geoscience and Remote Sensing Magazine*, vol. 9, pp. 174-180, 9 2021.
- [89] I. Calota, D. Faur and M. Datcu, "Estimating NDVI from SAR Images Using DNN," in *IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium*, 2022.
- [90] A. Mazza, M. Gargiulo, G. Scarpa and R. Gaetano, "Estimating the NDVI from SAR by Convolutional Neural Networks," in *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 2018.
- [91] B. Zhong, W. Chen, S. Wu, L. Hu, X. Luo and Q. Liu, "A Cloud Detection Method Based on Relationship Between Objects of Cloud and Cloud-Shadow for Chinese Moderate to High Resolution Satellite Imagery," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*10, vol. 10, no. 11, pp. 4898-4908, 2017.
- [92] L. Gómez-Chova, G. Mateo-García, J. Muñoz-Marí and G. Camps-Valls, "Cloud detection machine learning algorithms for PROBA-V," in *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2017.
- [93] B. Zhou and Y. Wang, "A Thin-Cloud Removal Approach Combining the Cirrus Band and RTM-Based Algorithm for Landsat-8 OLI Data," in *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 2019.
- [94] Y. Gao, Y. Wang and H. Lv, "Extendibility of a Thin-Cloud Removal Algorithm to Hi-Resolution Visible Bands of Sentinel-2 Data," in *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 2018.

- [95] K. Lee and J. Sim, "Cloud Removal of Satellite Images Using Convolutional Neural Network With Reliable Cloudy Image Synthesis Model," in *2019 IEEE International Conference on Image Processing (ICIP)*, 2019.
- [96] K. Rajitha, M. M. P. Mohan and M. R. R. Varma, "Effect of cirrus cloud on normalized difference Vegetation Index (NDVI) and Aerosol Free Vegetation Index (AFRI): A study based on LANDSAT 8 images," in *2015 Eighth International Conference on Advances in Pattern Recognition (ICAPR)*, 2015.
- [97] X. Ling and R. Cao, "A New Spatiotemporal Data Fusion Method to Reconstruct High-Quality Landsat Ndvi Time-Series Data," in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021.
- [98] J. Alvarez-Mozos, J. Villanueva, M. Arias and M. Gonzalez-Audicana, "Correlation Between NDVI and Sentinel-1 Derived Features for Maize," in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021.
- [100] "Level 2A algorithm for Sentinel 2," [Online]. Available: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-2-msi/level-2a/algorithm>. [Accessed January 2022].
- [103] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *CoRR*, 2015.