




National University of Science and
Technology POLITEHNICA Bucharest



Doctoral School of Electronics, Telecommunications
and Information Technology

Decision No. 117 from 26-10-2023

Ph.D. THESIS SUMMARY

Reza MOHAMMADI ASIYABI

DEEP LEARNING FOR SAR DATA IN PRESENCE
OF ADVERSARIAL SAMPLES

ÎNVĂȚAREA PROFUNDĂ PENTRU DATE SAR ÎN
PREZENȚA EȘANTINTELOR ADVERSIALE

THESIS COMMITTEE

Prof. Dr. Ing. Ioan MARGHESCU National University of Science and Technology POLITEHNICA Bucharest	President
Prof. Dr. Eng. Mihai DATCU National University of Science and Technology POLITEHNICA Bucharest	PhD Supervisor
Prof. Dr. Ing. Emanuel PUȘCHIȚĂ Technical University of Cluj-Napoca	Referee
Conf. Dr. Ing. Stefan Adrian TOMA Military Technical Academy “Ferdinand I”	Referee
Dr. Ing. Michele MARTONE Microwaves and Radar Institute, German Aerospace Center (DLR)	Referee
Prof. Dr. Ing. Andrei ANGHEL National University of Science and Technology POLITEHNICA Bucharest	Referee

BUCHAREST 2023

Abstract

În era schimbărilor fără precedent de pe Pământ, este imperios necesară o monitorizare continuă, pe termen lung și la scară globală, prin intermediul senzorilor de observare a Pământului (EO). Dintre senzorii EO, sistemele radar cu deschidere sintetică (SAR) se remarcă prin capacitatea lor de observare pe timp de zi și de noapte și prin imunitatea la condițiile atmosferice și joacă un rol esențial în asigurarea unei monitorizări neîntrerupte la nivel mondial. Cu toate acestea, datele SAR au un grad ridicat de complexitate; acestea sunt semnale multidimensionale cu valoare complexă (CV), cu proprietăți particulare induse de modul de formare coerentă a imaginii și de procesul de împrăștiere a scenei observate, precum și de efectul adversativ inerent.

Învățarea profundă a apărut ca o tehnică remarcabil de puternică, demonstrându-și eficacitatea de neegalat în abordarea provocărilor complexe, inclusiv în domeniul teledetecției. Această teză este dedicată explorării unor soluții noi bazate pe învățare profundă pentru aplicațiile SAR, luând în considerare caracteristicile unice ale datelor SAR și capacitatea rețelelor profunde de a învăța și de a modela distribuția datelor SAR, pentru a dezvălui noi perspective în acest domeniu. În acest scop, aprofundăm arhitecturile profunde CV pentru a exploata pe deplin componentele de amplitudine și fază ale datelor SAR. Cercetările prezentate în această teză pot fi clasificate în trei părți:

În prima parte, investigăm modelul generativ bayesian, Latent Dirichlet Allocation, pentru extragerea datelor EO mari de conținut semantic și generăm un set de date CV adnotate semantic din produsele modului Sentinel-1 (S1) Single Look Complex (SLC) StripMap (SM), numit S1SLC_CVDL, pentru antrenarea rețelelor profunde CV.

În continuare, a doua parte a tezei este dedicată implementării rețelelor CV și analizelor cuprinzătoare ale acestor modele, în ceea ce privește caracteristicile particulare ale datelor CV-SAR. În această parte, o gamă largă de operatori, straturi și funcții sunt convertite în domeniul complex pentru implementarea rețelei CV. Ulterior, se efectuează cercetări extinse asupra arhitecturilor CV profunde pentru diverse aplicații SAR, care evidențiază supremația modelelor CV pentru clasificarea semantică a acoperirii terenului, modelarea distribuției datelor, conservarea coerenței complexe și interpretarea și recuperarea atributelor fizice din datele SAR.

Recunoscând potențialul lor enorm, în ultima parte ne aventurăm în aplicațiile practice și mai complicate ale rețelelor CV. Utilizăm rețelele CV pentru a proiecta o nouă abordare de compresie a datelor utilizând autocodare CV, adaptată pentru comprimarea datelor SAR brute.

Capacitățile demonstrate ale arhitecturilor CV deep în această teză deschid noi perspective în domeniul arhitecturilor CV deep pentru aplicațiile SAR și deschid calea pentru dezvoltarea viitoare a rețelelor CV deep care țin cont de fizică, cu capacitate de modelare a distribuției de date pentru diverse aplicații de teledetecție.

Conținut

Abstract.....	ii
Conținut.....	iii
Chapter 1 Introducere.....	1
1.1 Prezentare generală	1
1.2 Motivația și scopul principal	1
1.3 Principalele contribuții	2
1.4 Structura tezei.....	3
Chapter 2 Context Teoretic	4
2.1 Noțiuni de bază ale radarului cu deschidere sintetică (SAR).....	4
2.2 Modelarea datelor și eșantioane adversariale.....	5
2.3 Rețele cu valoare complexă.....	6
Chapter 3 mineritul observației pământului mare pentru descoperirea informațiilor semantice și generarea setului de date S1SLC_CVDL.....	8
3.1 Prezentare generală	8
3.2 Rezultate experimentale	9
3.2.1 Scenariul 3: Analiza de adnotare bazată pe patch-uri Sentinel-1 și dezvoltarea setului de date S1SLC_CVDL	9
3.3 Concluzie.....	10
Chapter 4 Arhitecturi profunde cu valențe complexe pentru date SAR cu păstrarea coerenței și a proprietăților originale	11
4.1 Prezentare generală	11
4.2 Rezultate experimentale	12
4.2.1 Studiu de caz 1, clasificarea CV-SAR cu arhitectură end-to-end:.....	12
4.2.2 Studiu de caz 4.2.2, arhitectură end-to-end pentru CV cu atribuții integrate conștiente de fizică:	13
4.2.3 Studiu de caz 3, rețele CV vs. RV:	13
4.2.4 Studiu de caz 4, CV end-to-end vs. RV HRNet:.....	15
4.2.5 Studiu de caz 5, capacitatea de conservare a coerenței:.....	15
4.2.6 Studiu de caz 6, menținerea centroidului Doppler și a proprietăților originale ale datelor SAR:	16
4.3 Concluzie.....	17
Chapter 5 Compresia datelor SAR	18

5.1	Prezentare generală	18
5.2	Generarea datelor SAR brute cu cuantificare aproape uniformă	19
5.3	Compresia Datelor SAR brute.....	20
5.4	Concluzie.....	21
Chapter 6	Concluzie	22
6.1	Principalele Contribuții ale Tezei.....	22
6.2	Lista publicațiilor	23
6.2.1	Articole din jurnal	23
6.2.2	Lucrările conferinței.....	24
6.2.3	Seturi de date.....	24
Bibliografie	25

Chapter 1

Introducere

Modelele de învățare profundă sunt algoritmi de ultimă generație în materie de procesare a datelor pentru majoritatea aplicațiilor. Cu toate acestea, este important să se ia în considerare cu atenție mai mulți factori atunci când se aplică arhitecturi profunde pentru aplicațiile de teledetecție, în special datele SAR (Synthetic Aperture Radar) cu proprietăți specifice. Acest capitol prezintă motivația și scopul principal al tezei și rezumă principala contribuție în domeniu.

1.1 Prezentare generală

Prin captarea de date în diferite lungimi de undă, teledetecția și observarea Pământului (EO) ne permit să obținem informații valoroase despre caracteristicile Pământului și permit monitorizarea la scară globală a diferitelor fenomene. Dintre senzorii EO, capacitatea SAR de a achiziționa date aproape independent de condițiile meteorologice și în timpul zilei/noapții îl face un instrument neprețuit pentru monitorizarea diferitelor procese terestre. Cu toate acestea, datele SAR au un grad ridicat de complexitate, acestea fiind semnale multidimensionale cu valoare complexă (CV) cu proprietăți particulare și cu un efect adversativ inerent indus de modul de imagistică coerentă și de procesul de dispersie a scenei observate. Aceste particularități specifice ale datelor SAR introduc noi provocări în ceea ce privește interpretarea și extragerea de informații semnificative din punct de vedere semantic din acestea.

Mai mult decât atât, modelele de învățare profundă au demonstrat performanțe de ultimă oră și au reprezentat un progres major și un instrument extrem de puternic pentru multe sarcini diferite. [1]. Progresele imense ale modelelor de învățare profundă au permis arhitecturilor profunde să rezolve sarcini extrem de complicate și complicate și să depășească alți algoritmi de procesare a datelor și de învățare automată.

1.2 Motivația și scopul principal

Având în vedere potențialul uriaș al arhitecturilor profunde și creșterea fără precedent a disponibilității datelor EO, cercetătorii în domeniul teledetecției au aplicat modele de

învățare profundă la datele EO. Cu toate acestea, datele de teledetecție sunt diferite de imaginile naturale și ar ridica provocări specifice pentru modelele de învățare profundă. În cazul datelor SAR, una dintre principalele probleme este utilizarea rețelelor cu valoare reală (RV) pentru datele CV-SAR. Datele SAR sunt, prin natura lor, un domeniu complex, iar aplicarea modelelor RV va neglija informațiile de fază și va exploata doar componenta de amplitudine a datelor CV-SAR.

Rețelele CV sunt dezvoltate pentru a aborda această limitare a arhitecturilor profunde. În ciuda interesului sporit pentru dezvoltarea de noi rețele CV pentru interpretarea datelor SAR și a progreselor imense înregistrate de rețelele CV în ultimii ani, există încă mai mulți factori restrictivi care limitează avansarea și utilizarea pe scară largă a acestor modele. Motivația principală a acestei teze este de a aborda unele dintre principalele provocări și de a oferi soluții pentru o mai bună dezvoltare a arhitecturilor CV profunde pentru procesarea și interpretarea datelor SAR, pentru a rezolva lacunele rețelelor CV cu capacitatea de a învăța și de a modela distribuția complexă a datelor SAR în prezența unor eșantioane adverse inerente. Acest studiu are ca scop să ducă rețelele CV profunde dincolo de simpla analiză a semnalelor CV și să încorporeze proprietățile fizice ale datelor SAR în modelele CV.

Scopul principal al acestei teze este de a studia dezvoltarea arhitecturilor profunde CV pentru diverse aplicații SAR, de a oferi soluții pentru a aborda provocările și de a încorpora atribute de modelare a distribuției de date și de cunoaștere a fizicii în arhitecturile profunde CV pentru a le duce dincolo de simpla analiză a semnalelor CV.

1.3 Principalele contribuții

Principalele contribuții ale acestei teze sunt în direcția scopului principal de a studia capacitatea de învățare a modelelor de date a rețelelor CV pentru datele SAR în prezența unor eșantioane adversative, de a oferi soluții bazate pe arhitecturi CV profunde pentru diverse aplicații SAR și de a răspunde la întrebările de cercetare menționate mai sus. Principalele contribuții ale tezei sunt rezumate după cum urmează:

- Se studiază contextul teoretic și matematic necesar pentru implementarea rețelelor CV, inclusiv operatorii CV, straturile și algoritmi de backpropagation. Se oferă conversia operatorilor din domeniul real în domeniul complex. [2].
- Este explorat potențialul tehnicilor de minerit de date, în special al metodelor Bag of Visual Words (BOVW) și LDA, pentru extragerea de informații semnificative din punct de vedere semantic din diferite date de OT [3], [4].
- Tehnicile studiate de minerit de date sunt utilizate și un set de date la scară largă adnotate semantic din datele Sentinel-1 (S1) SLC pentru antrenarea modelelor de învățare profundă CV este dezvoltat și publicat cu acces liber pe IEEE DataPort, numit S1SLC_DL, pentru a deschide calea pentru alte activități de cercetare în domeniul rețelelor CV pentru datele SAR [5].
- Se discută capacitatea rețelelor CV de a învăța și de a modela distribuția datelor SAR în prezența eșantioanelor adverse inerente și se analizează competența diferitelor tehnici de modelare a datelor în acest scop [2], [6].

- Este evaluată capacitatea arhitecturilor de adâncime CV de a păstra coerența complexă a datelor SAR. Pentru a evalua această capacitate, se efectuează investigații cuprinzătoare, inclusiv în ceea ce privește păstrarea proprietății de subopunere a datelor SAR [2], [7].
- Se efectuează analize cuprinzătoare asupra arhitecturilor de clasificare profundă CV, precum și o comparație amănunțită între performanțele de clasificare ale acestora în raport cu rețeaua RV echivalentă și cu arhitecturile de clasificare de ultimă generație și se demonstrează superioritatea rețelelor CV în ceea ce privește acuratețea mai mare a clasificării, mai puține date de instruire și costuri de calcul mai mici [2], [8].
- Este evaluată pentru prima dată capacitatea rețelelor CV de a învăța atributele fizice și de a păstra proprietățile de bază originale ale datelor SAR. Efectul rețelelor CV asupra proprietăților centroidei Doppler a datelor SAR SLC este evaluat în ceea ce privește estimarea curentului de suprafață al oceanului. [9].
- Sunt studiate conceptele necesare pentru compresia datelor (de exemplu, teoria distorsiunilor de viteză, codificarea aritmetică și tehnicile standard de compresie) pentru compresia datelor SAR brute. În acest scop, se evaluează și se compară performanța tehnicilor bine cunoscute, tehnica de cuantificare BAQ și tehnicile JPEG2000 pentru compresia datelor SAR brute [10].
- Pentru prima dată, este dezvoltată o nouă arhitectură autocodificatoare CV pentru compresia neuronală a datelor SAR brute. Curba rată-distorsiune rezultată din schema de compresie bazată pe autocodificatorul CV dezvoltată este evaluată în comparație cu tehnicile de compresie bine cunoscute, cum ar fi BAQ și JPEG2000, pentru datele SAR brute. Performanța superioară a metodei de compresie bazată pe autocodificatorul CV a demonstrat potențialul rețelelor CV pentru învățarea și înțelegerea modelului de date SAR [6].

1.4 Structura tezei

Inclusiv capitolul introductiv, această teză conține șase capitole. Pe scurt, teza este structurată după cum urmează:

- Capitolul 2 prezintă contextul teoretic al conceptelor utilizate în această teză.
- Capitolul 3 prezintă metodele de extragere a datelor EO și setul de date CV-SAR adnotat semantic dezvoltat în acest studiu.
- Capitolul 4 este dedicat arhitecturilor profunde CV dezvoltate pentru clasificarea și reconstrucția datelor SAR. În acest capitol sunt analizate diferite proprietăți ale rețelelor CV dezvoltate.
- Capitolul 5 duce rețelele CV dezvoltate dincolo de simplul domeniu de analiză a semnalelor și utilizează arhitecturi CV profunde pentru compresia datelor SAR brute.
- Capitolul 6 concluzionează constatările și contribuțiile acestei teze, precum și oferă idei și direcții de cercetare viitoare.

Chapter 2

Context Teoretic

Acest capitol oferă o introducere la conceptele de bază studiate în această teză. Mai întâi, în secțiunea 2.1, sunt prezentate elementele fundamentale ale imagisticii datelor SAR. Ulterior, în secțiunea 2.2 se analizează conceptul de modelare a datelor pentru distribuția complexă a datelor SAR în prezența eșantioanelor adversative de inerență. Secțiunea 2.3 introduce contextul matematic pentru rețelele CV și conversia diferiților operatori, inclusiv a celor convoluționali, de tip pooling, de normalizare a loturilor, complet conectați, a diferitelor funcții de activare și pierdere și a algoritmului de backpropagation, din domeniul real în cel complex.

2.1 Noțiuni de bază ale radarului cu deschidere sintetică (SAR)

RADAR este un senzor activ care transmite unde radio (microunde) către o țintă și primește undele retrodifuzate. Radarul care privește înainte (de exemplu, radarul meteorologic) nu poate crea imagini, iar radarul de imagistică are o geometrie cu privire laterală. Un radar cu privire glisantă este de obicei transportat pe un avion sau pe un satelit pe orbită și scanează suprafața Pământului în două dimensiuni, distanță și azimut.

Rezoluția spațială este definită ca fiind separarea minimă dintre măsurători pe care senzorul este capabil să o distingă. Rezoluția spațială a imaginii create este diferită în direcțiile de distanță și azimut. Rezoluția în distanță este proporțională cu lățimea impulsurilor transmise de senzor, în timp ce rezoluția azimutală este proporțională cu lățimea amprentei pe sol a fasciculului, care la rândul ei este invers proporțională cu lungimea antenei. Prin urmare, este necesară o antenă foarte mare pentru a obține o rezoluție azimutală rezonabilă, ceea ce limitează rezoluția azimutală a sistemelor de imagistică radar cu deschidere reală [11]. SAR este un algoritm avansat de procesare a semnalelor pentru a depăși această limitare. În sistemul de formare a imaginilor SAR, mișcarea antenei de-a lungul direcției azimutale este utilizată pentru a sintetiza o antenă efectivă mai mare dintr-o secvență de achiziții realizate cu o antenă în mișcare mai scurtă, ceea ce, la rândul său, conduce la imagini cu o rezoluție azimutală mai mare [11].

Sistemele de formare a imaginilor SAR sunt capabile să achiziționeze date atât ziua, cât și noaptea și în aproape toate condițiile meteorologice. Aceste capacități fac din sistemele SAR o alegere potrivită pentru multe aplicații de supraveghere. În plus, interacțiunea semnalelor radar cu suprafața Pământului este diferită de cea a altor sisteme de detecție și, prin urmare, poate oferi informații unice și atractive.

Cu toate acestea, interpretarea imaginilor SAR nu este simplă. Observațiile SAR au un grad ridicat de complexitate, sunt semnale multidimensionale cu valoare complexă (CV) cu proprietăți particulare și cu un efect adversativ inerent indus de modul de formare a imaginii coerente și de procesul de dispersie a scenei observate. Geometria neintuitivă de privire laterală a sistemelor de imagistică SAR adaugă o dificultate suplimentară pentru interpretarea imaginilor SAR, cum ar fi efectul de prescurtare, de staționare și de umbră. [11]. În plus, semnalul retrodifuzat într-o celulă de rezoluție a imaginii SAR este suma coerentă a mai multor evenimente individuale de împrăștiere cu energie și fază diferite, ceea ce are ca rezultat un model granulat în imaginile SAR, cunoscut sub numele de efect speckle [12].

În plus, semnalul retrodifuzat din imaginile SAR conține atât componente de amplitudine, cât și de fază. Pentru a utiliza în mod eficient informațiile de fază din datele SAR, sunt necesare metode CV, cum ar fi rețelele profunde CV. Rețelele CV ar trebui să fie capabile să modeleze distribuția complexă a datelor SAR în prezența eșantioanelor adverse pentru a exploata în mod eficient relațiile inerente dintre amplitudine și fază, ceea ce duce la îmbunătățirea performanțelor în sarcini precum clasificarea și compresia datelor SAR.

2.2 Modelarea datelor și eșantioane adversariale

Obiectivul principal al acestei teze este de a oferi soluții bazate pe modele de învățare profundă CV, pentru diverse aplicații SAR, inclusiv clasificarea și compresia datelor CV SAR și de a rezolva problema lipsei de rețele CV cu capacitatea de a învăța și de a modela distribuția complicată a datelor SAR. Datele SLC și datele SAR brute au o complexitate foarte mare, iar capacitatea modelelor profunde de a învăța în mod eficient modelul complex de date este importantă pentru a obține performanțe eficiente de clasificare și compresie.

În plus, eșantioanele contradictorii reprezintă o provocare semnificativă pentru modelele de învățare profundă. De exemplu, diversele mecanisme de dispersie și, de asemenea, modelul fizic de bază, precum influența fenomenului Doppler pentru țintele în mișcare, pot cauza un efect adversarial în datele SAR [12]. Abordarea vulnerabilității modelelor de învățare profundă la eșantioanele adverse inerente ale datelor SAR este crucială pentru menținerea fiabilității și acurateții clasificării și a eficienței compresiei datelor în aplicațiile de date SAR.

Modelele de date, cum ar fi modelele de variabile latente, reprezintă baza pentru proiectarea diferiților algoritmi de învățare automată. Scopul principal al modelelor de date este înțelegerea și reprezentarea structurilor inerente din cadrul seturilor de date. Puterea algoritmilor de învățare automată constă în capacitatea lor de a învăța modelul

de date al datelor de instruire și de a extrage structuri și modele ascunse. În plus, modelele generative puternice au demonstrat performanțe superioare în clasificarea și comprimarea datelor complexe. Numeroase studii au investigat diferite modele generative, inclusiv LDA, GAN și autocodificatoare, pentru sarcini de clasificare și compresie, și au explorat efectul eșantioanelor adverse asupra acestora.

În această secțiune, sunt discutate două tehnici bine cunoscute de modelare a datelor, modele autoregresive și modele de variabile latente, iar mai târziu, trei modele generative populare sunt analizate critic, în ceea ce privește capacitatea lor de a învăța modele complexe de date SAR, vulnerabilitatea împotriva eșantioanelor adverse și compatibilitatea cu datele CV SAR.

Alegerea între LDA, GAN și autocodare depinde de sarcina specifică, de tipul de date și de obiective. Autoencoderele au demonstrat un potențial imens pentru învățarea modelului complex de date și, în această teză, ne concentrăm pe autoencoderele pentru sarcinile de clasificare și compresie datorită caracteristicilor lor, cum ar fi capacitatea de înclinare a distribuției complexe.

2.3 Rețele cu valoare complexă

Atunci când datele CV apar în mod natural într-un sistem, cum ar fi sistemele de imagistică SAR, componentele reale și imaginare sunt corelate statistic. În timp ce se extind operatorii RV în domeniul complex, păstrarea acestei corelații între componentele reale și imaginare este necesară pentru a utiliza în mod corespunzător datele CV și pentru a extrage informațiile fizice corecte din datele SAR [13].

Toate elementele rețelei CV se află în domeniul complex. Cu toate acestea, funcția de pierdere rămâne în domeniul real pentru a preveni problemele empirice în timpul învățării [8], [14]. În această secțiune a tezei, sunt explicate explicații detaliate și ecuații cuprinzătoare ale diferiților operatori CV, inclusiv stratul convoluțional, stratul de punere în comun, stratul de normalizare a loturilor, stratul complet conectat, funcțiile de activare, funcțiile de pierdere și algoritmul de backpropagation.

De exemplu, backpropagation este o metodă bazată pe Stochastic Gradient Descent (SGD), care este utilizată pe scară largă pentru antrenarea modelelor de învățare profundă. Algoritmul de backpropagation minimizează eroarea totală (pierderea) a eșantioanelor de formare în etapa de formare a rețelei prin ajustarea parametrilor de greutate și de polarizare ai rețelei.

Conform teoremei lui Liouville în analiza complexă, o funcție holomorfă mărginită trebuie să fie constantă pe întreaga distribuție complexă [14]. Cu alte cuvinte, pierderea și funcțiile de activare ale modelului CV trebuie să fie constante sau nemărginite. Cu toate acestea, calculul Wirtinger [15] a extins derivarea complexă la funcțiile neholomorfe. Mai multe articole au utilizat calculul Wirtinger pentru a deriva algoritmul de backpropagare CV [14], [16]–[19]. O versiune simplificată a backpropagării CV bazată pe calculul Wirtinger, adaptată pentru studiul de caz al acestei teze, este prezentată mai jos.

Conform calculului Wirtinger, dacă z este o variabilă complexă, $z = x + jy \in \mathbb{C}$, $(x, y) \in \mathbb{R}^2$, derivatele parțiale ale unei funcții complexe $f(z)$ în raport cu z și \bar{z} sunt cele prezentate în (2.38):

$$\frac{\partial f}{\partial z} \triangleq \frac{1}{2} \left(\frac{\partial f}{\partial x} - j \frac{\partial f}{\partial y} \right), \quad \frac{\partial f}{\partial \bar{z}} \triangleq \frac{1}{2} \left(\frac{\partial f}{\partial x} + j \frac{\partial f}{\partial y} \right) \quad (2.38)$$

Ulterior, gradientul complex poate fi definit astfel (2.39):

$$\nabla_z f = 2 \frac{\partial f}{\partial \bar{z}} \quad (2.39)$$

În consecință, termenul de corecție pentru ponderile celui de-al l th strat $\Delta \omega_{ik}^{(l)} [t]$ poate fi calculat ca (2.40)

$$\Delta \omega_{ik}^{(l)} = \frac{\partial \mathcal{L}}{\partial \Re(\omega_{ik}^{(l)})} + j \frac{\partial \mathcal{L}}{\partial \Im(\omega_{ik}^{(l)})} \quad (2.40)$$

Pierdere \mathcal{L} nu este direct legată de ponderile $\omega_{ik}^{(l)}$ ale modelului și, prin urmare, pentru a calcula termenul de corecție pentru ponderile din fiecare strat, trebuie să se aplice regula complexă a lanțului [20], [21].

$$\begin{aligned} \Delta \omega_{ik}^{(l)} = & \left(\frac{\partial \mathcal{L}}{\partial \Re(V_i^{(l)})} \frac{\partial \Re(V_i^{(l)})}{\partial \Re(\omega_{ik}^{(l)})} + \frac{\partial \mathcal{L}}{\partial \Im(V_i^{(l)})} \frac{\partial \Im(V_i^{(l)})}{\partial \Re(\omega_{ik}^{(l)})} \right) \\ & + j \left(\frac{\partial \mathcal{L}}{\partial \Re(V_i^{(l)})} \frac{\partial \Re(V_i^{(l)})}{\partial \Im(\omega_{ik}^{(l)})} + \frac{\partial \mathcal{L}}{\partial \Im(V_i^{(l)})} \frac{\partial \Im(V_i^{(l)})}{\partial \Im(\omega_{ik}^{(l)})} \right) \end{aligned} \quad (2.41)$$

Dacă termenul complex de eroare $\delta_i^{(l)}$ este definit ca (2.42), (2.41) poate fi simplificat ca fiind (2.43)

$$\delta_i^{(l)} = - \frac{\partial \mathcal{L}}{\partial \Re(V_i^{(l)})} - j \frac{\partial \mathcal{L}}{\partial \Im(V_i^{(l)})} \quad (2.42)$$

$$\Delta \omega_{ik}^{(l)} = -\delta_i^{(l)} \overline{O_i^{(l-1)}} \quad (2.43)$$

Termenul de eroare $\delta_i^{(l)}$ trebuie calculat în fiecare strat pentru a propaga eroarea și a ajusta parametrii modelului pentru a obține ieșirile dorite. Algoritmul complex de retropropagare propagă eroarea până la parametrii (adică ponderile și polarizările) din primul strat al rețelei profunde și ajustează acești parametri în mod simultan, în conformitate cu funcția de pierdere definite.

Chapter 3

mineritul observației pământului mare pentru descoperirea informațiilor semantice și generarea setului de date S1SLC_CVDL

Progresele recente în tehnologia de teledetecție au furnizat date de OT cu rezoluție spațială (foarte) mare și cu o abundență de informații semantice latente. Acest capitol se concentrează pe metodele de descoperire a informațiilor semantice, bazate pe modele generative Bayesiene pentru extragerea datelor, cum ar fi modelele Latent Dirichlet Allocation (LDA) și Bag of Visual Words (BOVW). Sunt utilizate trei scenarii diferite pentru a evalua descoperirea de informații semantice în diverse aplicații de teledetecție, incluzând atât date optice, cât și date SAR cu diferite rezoluții spațiale. În plus, în acest capitol este dezvoltat și prezentat un set de date adnotat semantic din datele Sentinel-1 SLC pentru aplicații de învățare profundă CV, denumit set de date S1SLC_CVDL.

3.1 Prezentare generală

În acest capitol, două tehnici bine cunoscute de extragere a datelor, modelele LDA și BOVW, sunt utilizate pentru a exploata diferite date de OT și a extrage informații semantice latente din acestea. LDA este un model probabilistic generativ bayesian care a fost propus de Blei et al. [22] pentru modelarea textului. În domeniul imaginilor, LDA modelează fiecare imagine ca un amestec de subiecte latente dintr-o distribuție Dirichlet. În acest scop, LDA utilizează reprezentarea BOVW a imaginii și consideră cuvintele vizuale ca fiind reprezentante ale subiectelor pentru a reprezenta fiecare imagine cu un vector de probabilitate a subiectelor prin intermediul unei proceduri generative.

Obiectivul principal al acestui capitol este de a evalua capacitățile metodelor de analiză semantică latentă de data mining bazate pe modelele LDA și BOVW pentru

descoperirea de informații semantice latente în imaginile EO cu diferite scenarii. Prin urmare, au fost utilizate trei scenarii diferite cu trei seturi de date diferite de imagini EO pentru descoperirea de informații semantice în imaginile de teledetecție. Ca prim scenariu, BOVW și LDA bazate pe kernel sunt aplicate pe imagini EO multispectrale (3 benzi RGB) de rezoluție foarte mare (30 cm) pentru descoperirea de informații semantice și îmbunătățirea hărții GT definite de utilizator pentru a obține o hartă clasificată mai bună și mai cuprinzătoare din punct de vedere semantic. Ulterior, o procedură similară este utilizată cu imagini multispectrale cu rezoluție spațială mai grosieră (10 m) (3 benzi RGB și 1 bandă infraroșie) pentru a detecta zonele afectate de incendii de pădure. Și, în cele din urmă, în ultimul scenariu, BOVW și LDA bazate pe patch-uri sunt utilizate pe patch-uri SAR inițial adnotate pentru a detecta erorile de clasificare și erorile din rezultatele inițiale de clasificare. Metoda dezvoltată în acest scenariu este utilizată pentru a dezvolta un set de date adnotate semantic din datele Sentinel-1 SLC, denumit set de date S1SLC_CVDL.

3.2 Rezultate experimentale

Este prezentat un rezumat al celui de-al treilea scenariu și al setului de S1SLC_CVDL.

3.2.1 Scenariul 3: Analiza de adnotare bazată pe patch-uri Sentinel-1 și dezvoltarea setului de date S1SLC_CVDL

Lipsa setului de date de teledetecție adnotate și dificultatea de a crea un set de date EO adnotate la scară largă și de înaltă calitate reprezintă un factor important și restrictiv în dezvoltarea diferiților algoritmi de învățare automată. Numeroase seturi de date cu caracteristici diverse au fost dezvoltate în literatura de teledetecție pentru diferite aplicații, însă nu există un set de date CV-SAR de înaltă calitate la scară largă. Pentru a aborda această problemă, tehnica de extragere a datelor bazată pe LDA este utilizată în cel de-al treilea scenariu din acest capitol pentru a dezvolta un set de date adnotat semantic din produsele Sentinel-1 SLC modul SM pentru rețelele CV Deep Learning (S1SLC_CVDL).

Au fost selectate trei scene Sentinel-1 deasupra orașelor Chicago și Houston din SUA și Sao Paulo din Brazilia, pentru a include diverse zone urbane, precum și vegetație și corpuri de apă. Scenele SAR menționate mai sus sunt împărțite în 289 760 de patch-uri care nu se suprapun, de 100×100 pixeli. Deoarece adnotările semantice ale petelor SAR nu sunt disponibile, 1274 de pete sunt adnotate manual, utilizând inspecția vizuală prin intermediul Google Earth Pro, în 7 clase semantice, inclusiv Agricultură (AG), Pădure (FR), Zone urbane de mare densitate (HD), Clădiri înalte (HR), Zone urbane de mică densitate (LD), Regiuni industriale (IR) și Regiuni acvatice (WR).

Ulterior, clasificatorul SVM, cu nucleu de intersecție a histogramei, este utilizat pentru a clasifica patch-urile SAR în cele șapte clase semantice, utilizând caracteristicile Gabor. Mai multe erori evidente de clasificare sunt vizibile în patch-urile clasificate. În etapa următoare, analiza semantică bazată pe BOVW și LDA este

utilizată pentru a identifica și elimina erorile de clasificare și pentru a îmbunătăți adnotarea petelor.

Ca urmare a analizei semantice, numărul de patch-uri este redus, iar dimensiunea setului de date este redusă cu aproximativ 5%. Cu toate acestea, această procedură îmbunătățește setul de date în ceea ce privește mai puține patch-uri clasificate incorect, precum și mai puține patch-uri mixte, care constau în mai multe clase semantice. Acuratețea generală este îmbunătățită cu aproximativ 2%, iar rata medie de falsuri pozitive este, de asemenea, redusă cu aproximativ 2% pentru fiecare clasă, după analiza semantică. Setul de date adnotat S1SLC_CVDL dezvoltat este disponibil la IEEE DataPort (<http://ieee-dataport.org/11016>) în scopuri de cercetare [5].

3.3 Concluzie

Tehnicile de descoperire a informațiilor semantice bazate pe data mining, LDA și BOVW, sunt utilizate în acest studiu cu diferite seturi de date de teledetecție pentru a extrage informațiile semantice latente din imaginile EO pentru diverse aplicații..

Utilizarea reprezentării BOVW pe bază de kernel și a modelului tematic LDA ne-a permis să corectăm și să îmbunătățim harta GT definită de utilizator și să identificăm clasele semantice neglijate în imaginile aeriene USGS de foarte înaltă rezoluție (0,3 m) cu benzi optice RGB. Harta GT corectată a avut ca rezultat o hartă clasificată mai semnificativă din punct de vedere semantic și mai cuprinzătoare, precum și mai puține erori de clasificare greșită.

În plus, benzile spectrale RGB și NIR ale imaginilor optice Sentinel-2 cu o rezoluție spațială mai grosieră (10 m) sunt utilizate pentru a detecta zonele afectate de incendii, la câteva zile și la câteva luni după incident. Rezultatele au demonstrat capacitatea metodei de descoperire semantică de a detecta diverse fenomene (de exemplu, zona afectată de incendii de pădure) în imaginile optice EO. În plus, acest scenariu a demonstrat capacitatea analizei semantice de data mining de a detecta benzile spectrale relevante cu date mai informative pentru aplicația țintă.

În plus, tehnica de minerit de date bazată pe BOVW și LDA este utilizată pentru a dezvolta un set de date adnotate semantic din datele Sentinel-1 SLC pentru modelul de învățare profundă cu valori complexe (set de date S1SCL_CVDL). În acest scop, trei scene din imaginile SAR Sentinel-1 cu modul de imagistică SM sunt împărțite în patch-uri de 100×100 pixeli și câteva patch-uri sunt adnotate manual în 7 clase semantice prin inspecție vizuală și imagini Google Earth. Caracteristicile de textură Gabor și binecunoscutul clasificator SVM sunt utilizate pentru adnotarea inițială a petelor. Ulterior, metoda de descoperire a informațiilor semantice prin minerit de date este utilizată pentru a curăța setul de date adnotate și pentru a elimina peticele clasificate greșit, precum și pentru a elimina peticele cu etichete semantice ambigue sau multiple.

Experimentele efectuate în acest capitol au demonstrat capacitățile imense ale tehnicilor de extragere semantică a datelor pentru diverse contexte de teledetecție. Cu toate acestea, sunt necesare mai multe inspecții pentru a evalua competența metodelor de analiză semantică în studiile viitoare.

Chapter 4

Arhitecturi profunde cu valențe complexe pentru date SAR cu păstrarea coerenței și a proprietăților originale

În acest capitol, se studiază performanța arhitecturilor profunde CV pentru diferite aplicații SAR. Pentru reconstrucția și clasificarea datelor CV-SAR sunt dezvoltate trei arhitecturi CV diferite, inclusiv o rețea profundă CV end-to-end cu două capete de ieșire pentru clasificare și reconstrucție, un autocodificator convoluțional CV (CV Convolutional Autoencoder - CAE) și o rețea neuronală convoluțională CV (CV Convolutional Neural Network - CNN). Sunt efectuate mai multe experimente pentru a examina și a prezenta potențialul rețelelor CV pentru diferite aplicații SAR.

4.1 Prezentare generală

În ciuda interesului și a evoluțiilor recente în ceea ce privește modelele de adâncime CV pentru procesarea datelor SAR, există mai mulți factori restrictivi care au limitat avansarea pe scară largă a acestor modele. În acest capitol, operatorii CV, definiți în capitolul 2, sunt utilizați pentru a implementa arhitecturi CV profunde și sunt efectuate mai multe analize pentru a investiga performanța și potențialul arhitecturilor CV pentru diferite aplicații SAR și pentru a aborda unele dintre limitări. Se proiectează și se implementează o arhitectură end-to-end cu capete de clasificare și reconstrucție, precum și două arhitecturi mai specifice pentru clasificarea și reconstrucția specifică a datelor SAR. Arhitecturile CV profunde sunt utilizate pentru a explora performanța și capacitatea rețelelor CV pentru diferite aplicații SAR, în 6 studii de caz.

Setul de date S1SLC_CVDL, dezvoltat și prezentat în capitolul 3, este utilizat în acest capitol pentru antrenarea și testarea rețelelor CV. În plus, o imagine PolSAR, achiziționată de sistemul AirSAR al NASA/JPL deasupra unei zone agricole din Flevoland, Țările de Jos, cu o dimensiune de 750×1024 , este utilizată pentru a evalua performanța de clasificare a modelelor CV pentru datele PolSAR. În plus, o scenă

Sentinel-1 achiziționată în modul interferometric cu bătaie largă (IW) deasupra plajei Mamaia, pe coasta românească a Mării Negre, este utilizată pentru a explora capacitatea rețelelor CV de a păstra proprietățile originale ale datelor SAR.

4.2 Rezultate experimentale

În această secțiune, arhitecturile CV dezvoltate sunt utilizate în diferite studii de caz pentru a investiga diverse aspecte ale arhitecturilor CV profunde pentru aplicații SAR.

4.2.1 Studiu de caz 1, clasificarea CV-SAR cu arhitectură end-to-end:

În acest studiu de caz, arhitectura end-to-end este folosită pentru a clasifica datele CV-SAR din setul de date S1SLC_CVDL. Graficele colorate în portocaliu din Figura 4.5 demonstrează acuratețile de clasificare generale și pe clase obținute de la modelul CV end-to-end propus în acest studiu de caz. Rețeaua profundă CV end-to-end a obținut o acuratețe generală de clasificare de aproximativ 90,7%. Cele mai scăzute acurateți sunt obținute în cazul claselor construite, unde clasa LD este clasificată cu doar 43,85% precizie. Cu toate acestea, în scenariul cu trei clase, clasele construite sunt separate cu o precizie ridicată, iar cea mai importantă confuzie apare între diferitele tipuri de clase semantice construite. Motivul principal pentru acuratețea foarte scăzută de clasificare a clasei LD este confuzia dintre această clasă și celelalte clase construite, în special câmpurile industriale. Celelalte trei clase construite, HD, HR și IR, sunt clasificate cu acuratețe aproape similară, în jur de 78%.

În concluzie, în ciuda confuziei dintre diferitele clase construite, rețeaua profundă CV end-to-end propusă a clasificat cu succes setul de date S1SLC_CVDL dificil cu o acuratețe rezonabilă și a utilizat informațiile de amplitudine și fază ale imaginilor CV-SAR.




Figure 4.5 Acuratețea de clasificare pentru cele șapte adnotări semantice în diferite studii de caz.

4.2.2 Studiu de caz 4.2.2, arhitectură end-to-end pentru CV cu atribuții integrate conștiente de fizică:

În acest studiu de caz, sunt extrase trei imagini de subapertură suprapuse (20%) din fiecare canal de polarizare al petelor CV-SAR ale setului de date S1SLC_CVDL (adică șase imagini CV de subapertură pentru fiecare pată). Transformata Fourier poate fi folosită pentru a obține imaginile de subapertură din datele SAR prelucrate. Trebuie menționat că imaginile de subapertură obținute sunt, de asemenea, în domeniul complex. În timpul utilizării decompunerii subaperturii pe azimut, trebuie să se țină cont că imaginile de subapertură vor avea o rezoluție proporțional mai mică, deoarece utilizăm doar o parte din lățimea de bandă a sistemului disponibil [23]. În plus, Zero Doppler pentru țintele în mișcare, inclusiv trenuri sau mașini, ar putea fi în poziții diferite, ceea ce crește posibilitatea detectării defocalizate și a ratării [23].

Imaginile subaperturii CV (șase canale, trei din fiecare canal de polarizare), împreună cu imaginile CV-SAR (două canale), sunt introduse în modelul CV propus end-to-end, iar rezultatele clasificării sunt prezentate în diagramele colorate cu albastru din Figura 4.5. Precizia generală a crescut cu aproximativ 3% în comparație cu studiul de caz anterior și a atins 93,72%. Cea mai evidentă îmbunătățire se observă în clasa semantică LD. Clasa LD este clasificată cu o precizie de peste 80%, ceea ce este aproape de două ori mai mare decât precizia de clasificare a acestei clase în studiul de caz anterior. Cu toate acestea, confuzia dintre diferitele clase semantice construite rămâne în continuare o provocare. Cea mai problemă confuzie în acest studiu de caz este între clasele semantice HD și HR.

În concluzie, adăugarea imaginilor subaperturii azimutale CV a permis arhitecturii CV propuse de la capăt la capăt să clasifice mai bine diferitele clase semantice construite. Atributul conștient de fizică al modelului adânc a îmbunătățit semnificativ rezultatele clasificării, în special în zonele construite. După cum este arătat în Capitolul 3, setul de date S1SLC_CVDL este foarte dificil și conține ținte foarte similare, în special în clasele construite. Cu toate acestea, modelul CV propus de la capăt la capăt reușește să clasifice setul de date dificil și să exploateze informațiile valoroase din amplitudinea și faza componentelor imaginilor CV-SAR, precum și proprietățile fizice din imaginile subaperturii azimutale CV.

4.2.3 Studiu de caz 3, rețele CV vs. RV:

Pentru a evalua efectul rețelelor CV asupra rezultatelor de clasificare, se compară două arhitecturi în formatele RV și CV, și anume arhitectura end-to-end pentru setul de date S1SLC_CVDL și arhitectura CNN pentru clasificarea datelor PolSAR.

Arhitectura End-to-end:

În primul experiment, a fost proiectată o rețea neuronală profundă echivalentă RV end-to-end. Similar cu studiul de caz anterior, în acest studiu de caz sunt folosite 8 canale

de intrare. Amplitudinea SAR și imaginile de subapertură folosite în rețeaua RV și rezultatele clasificării sunt prezentate cu diagrame colorate în tonuri de gri în Figura 4.5. Rețeaua echivalentă RV cu imagini RV-SAR și RV-subapertură a obținut o precizie globală de clasificare de 79,01%.

Rețeaua CV end-to-end a obținut o precizie mai mare în clasificare pentru toate clasele atunci când au fost folosite aceleași imagini de intrare (imagini SAR și imagini de subapertură azimutală). Performanța mai bună a rețelei CV demonstrează superioritatea acestei rețele. Modelul CV este capabil să valorifice mai multe informații valoroase și distinctive din componentele de amplitudine și fază ale datelor SAR.

În concluzie, rețeaua CV deep end-to-end a obținut o precizie generală de clasificare cu aproximativ 14% mai mare cu aceleași date de intrare. Doar în clasa LD, rețeaua RV a obținut o precizie de clasificare ușor mai mare. Cu toate acestea, rata foarte mare de rezultate false pozitive în această clasă în modelul RV explică precizia mai mare și demonstrează performanța slabă a rețelei RV, în ciuda preciziei mai mari pentru această clasă.

Arhitectura CNN:

În al doilea experiment al acestui studiu de caz, arhitecturile CNN CV și RV sunt folosite pentru a clasifica datele PolSAR. Cele trei elemente RV și cele trei elemente CV ale triunghiului superior al matricei de covarianță sunt folosite ca caracteristici de intrare ale modelelor. Pentru a păstra echivalența între rețele, aceeași arhitectură este utilizată pentru CV-CNN și RV-CNN.

Se compară performanța CV-CNN și RV-CNN în ceea ce privește convergența modelului cu diferite dimensiuni ale setului de antrenare, precizia clasificării și eficiența computațională a modelelor.

Pentru a compara rata de convergență a modelelor, dimensiunea setului de antrenament este modificată între 5% și 50% din dimensiunea setului de date (GT), iar modelele sunt antrenate cu 100 de epoci. Precizia testului modelului CV cu doar 5% din dimensiunea setului de antrenament ajunge la aproximativ 92% și 94% după 50 și, respectiv, 100 de epoci. Cu toate acestea, modelul RV a avut nevoie de cel puțin 30% din dimensiunea setului de antrenament pentru o performanță similară. CV-CNN are o precizie de testare remarcabilă de peste 98% cu o dimensiune a setului de antrenament de 50%.

În ceea ce privește acuratețea clasificării, cu o dimensiune a setului de antrenament de 10%, modelele CV-CNN și RV-CNN au obținut o Acuratețe Generală (OA) mai mare de 95%, respectiv 90% pentru setul de testare. Doar în două clase, Pădure și Sol gol, modelul RV a obținut acuratețe mai mare la clasificare, cu toate acestea, acuratețea CV-CNN este semnificativ mai mare în celelalte 13 clase semantice.

În ciuda performanței superioare, CV-CNN are de două ori mai mulți parametri antrenabili decât RV-CNN, respectiv 39.034 și 19.517 de parametri, ceea ce duce la un timp de antrenare mult mai mare pentru modelul CV. Cu toate acestea, modelul CV atinge un OA mai mare cu mai puține epoci de antrenament. De exemplu, pentru un OA țintă de peste 90%, modelul CV are nevoie de 17 epoci și 173,32 de secunde de

antrenament, în timp ce modelul RV are nevoie de 39 de epoci și 192,26 de secunde de antrenament.

În concluzie, utilizarea componentei de fază în arhitecturile CV profunde poate îmbunătăți rezultatele de clasificare și va necesita un set de antrenament mai mic și mai puține epoci și timp de antrenament.

4.2.4 Studiu de caz 4, CV end-to-end vs. RV HRNet:

Arhitecturile utilizate în acest capitol sunt rețele convoluționale simple și de bază, și ele pot fi îmbunătățite pentru a obține rezultate mai bune. În literatură au fost propuse numeroase arhitecturi diferite pentru a îmbunătăți performanța rețelelor adânci, inclusiv High-Resolution Network (HRNet). În acest studiu de caz, rețeaua CV end-to-end cu aceeași arhitectură este comparată cu RV HRNet. Asemănător studiului de caz anterior, sunt folosite 8 canale de intrare, constând din două canale de polarizație SAR și șase imagini subapertură (adică în domeniul complex pentru rețeaua CV și în domeniul real pentru RV HRNet).

HRNet a obținut o precizie globală de 90,97%, ceea ce este aproape cu 3% mai mică decât rețeaua CV. Rețeaua CV a obținut o precizie mai mare în clasificarea tuturor claselor, cu excepția clasei IR. Cu toate acestea, rata de fals pozitiv pentru această clasă este foarte mare, în mare parte ca rezultat al confuziei între această clasă și clasele HD și LD. Cu toate acestea, HRNet RV a obținut o performanță semnificativ mai bună decât rețeaua RV cu arhitectura end-to-end. Intrarea pentru ambele rețele este aceeași (8 canale RV), dar HRNet a obținut o precizie globală cu aproape 12% mai mare.

Rezultatele acestui studiu de caz au demonstrat că HRNet are o arhitectură mai bună decât rețeaua end-to-end, dar operatorii CV au obținut o acuratețe mai mare în clasificare chiar și cu o arhitectură mai puțin adâncă și mai slabă. De asemenea, trebuie menționat că HRNet are mai mulți parametri ajustabili decât rețeaua CV (HRNet are 21.301.884 de parametri, în timp ce rețeaua CV are 18.466.186 de parametri).

4.2.5 Studiu de caz 5, capacitatea de conservare a coerenței:

În imagistica SAR, coeficientul de corelație complex (Coerența) conține informații importante despre sistemul SAR și proprietățile fizice ale obiectului [24]. Ca rezultat, coerența datelor CV-SAR trebuie să fie păstrată în lanțul de procesare, iar o rețea CV completă cu o caracteristică de păstrare a coerenței este necesară. Procesarea separată a componentelor de amplitudine și fază (sau a părților reale și imaginare) ale datelor CV-SAR va întrerupe coerența datelor CV-SAR. Cu toate că rețelele CV pot fi benefice pentru a păstra această coerență și a exploata informațiile de fază [14], capacitatea de păstrare a coerenței a rețelelor CV dezvoltate ar trebui evaluată și monitorizată pentru a asigura păstrarea coerenței. În acest studiu de caz, două rețele CV sunt folosite pentru a evalua capacitatea de păstrare a coerenței a rețelelor CV, respectiv o rețea CV end-to-end profundă și un model CV CAE.

Arhitectura CV end-to-end:

Rețeaua CV end-to-end este folosită cu cele 8 canale de intrare CV, care constau din două imagini CV-SAR și șase imagini CV subapertură. În primul pas, corelația dintre imaginea CV-SAR reconstruită de CV-CAE și imaginea de intrare este evaluată. Coerența medie între intrare și patch-urile CV-SAR reconstruite este de 0,9415. Coerența ridicată demonstrează păstrarea coeficientului de corelație complex al patch-urilor CV-SAR în modelul CV adânc.

Mai mult, rețeaua profundă CV dezvoltată ar trebui să învețe modelul de date CV într-un mod în care diferitele deschideri în imaginea CV-SAR reconstruită să reprezinte în continuare unghiurile diferite ale antenei. Pentru a evalua modelul CV dezvoltat end-to-end pentru învățarea și păstrarea modelului de date CV, descompunerea subaperturii este, de asemenea, aplicată la petele CV-SAR reconstruite. Coerența medie de 0,9214 între imaginile subaperturii demonstrează capacitatea rețelei CV dezvoltate de a învăța și păstra modelul de date.

Arhitectura CV CAE:

În plus, arhitectura CV CAE este utilizată în acest studiu de caz pentru a evalua conservarea coerenței complexe în reconstrucția imaginilor CV-SAR. În acest scop, se introduc în rețeaua CV CAE aceleași 8 canale de intrare CV ca în cazul arhitecturilor end-to-end, iar coerența dintre imaginile de intrare și patch-urile SAR reconstruite, precum și imaginile de subapertură din patch-urile SAR originale și cele reconstruite sunt evaluate. Valoarea mare a coerenței demonstrează capacitatea modelului CV CAE de a învăța modelul datelor și de a conserva coerența complexă.

4.2.6 Studiu de caz 6, menținerea centroidului Doppler și a proprietăților originale ale datelor SAR:

Imaginile SAR transmit caracteristicile fizice și informațiile despre ținta observată, iar dacă modelul de date fizice și proprietățile de bază ale datelor SAR originale sunt menținute în lanțul de procesare, parametrii fizici ai țintei observate pot fi obținuți cu precizie din datele SAR. De exemplu, informațiile de fază din imaginile SAR SLC pot fi utilizate pentru a obține informații fizice despre Curentul Suprafeței Oceanului (OSC) din datele EO. Rețelele CV adânci, datorită capacității lor de a procesa informațiile de fază și, de asemenea, a capacității lor, așa cum s-a arătat în studiul de caz anterior, de a învăța și de a păstra modelul de date și coerența complexă a datelor CV-SAR, sunt algoritmi potriviți în acest scop. Cu toate acestea, capacitatea rețelelor CV de a menține proprietățile de bază ale imaginii SAR originale, în acest caz, centrul Doppler, ar trebui evaluată.

În acest scop, rețeaua end-to-end CV este utilizată, fără a ține cont de capul de ieșire pentru clasificare. Ulterior, parametrii de circulație oceanică au fost estimați din datele SAR înainte și după reconstrucție folosind autoencoder-ul CV, iar rezultatele au

fost comparate. În acest studiu de caz, au fost folosite datele din modul Sentinel-1 IW, dobândite de-a lungul plajei Mamaia de pe coasta românească a Mării Negre.

Metoda Estimării Doppler a Correlației (CDE) [25] și Viteza Radială la Suprafață (RSV) [26] sunt folosite pentru a extrage informații Doppler și pentru a estima CPO (Câmpul de Viteză la Suprafață Oceanic) din acestea. Autoencoderul CV este antrenat o dată cu datele S1SLC_CVDL (modul SM, polarizare HH-HV) și o dată suplimentar cu datele din acest studiu de caz (modul IW, polarizare VV-VH). Rezultatele obținute de aceste două rețele sunt notate cu "R" și "RT", respectiv. Pentru a evalua impactul rețelei CV asupra estimării parametrilor suprafeței oceanice, CPO este estimat din datele SAR originale înainte de rețeaua CV, notate cu "O", și de asemenea, cu rețelele "R" și "RT".

Comparând f_{DC} și OSC estimate din rețeaua "R" cu datele SAR originale, se observă o diferență semnificativă în estimarea parametrului de circulație oceanică. Datele CV-SAR reconstruite, în ciuda unui model OSC similar, tind să estimeze valori mai mici pentru curent și Doppler mai slab. Cu toate acestea, atunci când autoencoderul CV este reantrenat folosind datele IW, f_{DC} și OSC estimate prezintă o asemănare foarte mare cu rezultatele din datele SAR originale. Asemănarea ridicată între estimarea parametrului de circulație oceanică în datele SAR originale și cele reconstruite demonstrează că autoencoderul CV a păstrat modelul datelor SAR chiar și fără reantrenare (experimentul notat cu R). În mod evident, reantrenarea rețelei cu un tip similar de date (canalele de polarizare IW și VV-VH) a îmbunătățit semnificativ performanța autoencoderului CV.

Când comparăm $OSC^{(O)}$ cu $OSC^{(R)}$, obținem RMSE de 0,26, o corelație de 0,85 și MAE de 0,14. Cu toate acestea, atunci când comparăm $OSC^{(O)}$ și $OSC^{(RT)}$, există o bună concordanță, cu un RMSE mai mic de 0,11, o corelație spațială puternică de 0,97 și o MAE neglijabilă de 0,05, lucru care este evident și din înclinarea liniei de regresie pentru ambele comparații.

În concluzie, potențialul imens al arhitecturilor CV profunde pentru recuperarea și predicția parametrilor fizici, datorită capacității lor de a păstra proprietățile originale ale datelor SAR, este demonstrat în acest studiu de caz.

4.3 Concluzie

În acest capitol, rețelele profunde de învățare a computerelor (CV) sunt folosite pentru reconstrucția și clasificarea datelor CV-SAR, abordând o serie de deficiențe ale modelelor CV anterioare pentru prelucrarea datelor SAR. Trei arhitecturi CV profunde, inclusiv o arhitectură profundă end-to-end cu două capete pentru clasificare și reconstrucție, o rețea neurală convoluțională (CNN) și modele de codificare automată (CAE), sunt proiectate și implementate în diferite studii de caz pentru a evalua diverse aspecte ale eficienței rețelelor CV în aplicațiile SAR. Sunt definite șase studii de caz diferite, iar eficiența rețelelor CV în aceste studii de caz este evaluată. Concluziile acestui capitol demonstrează potențialul imens al rețelelor CV în diverse aplicații SAR și dezvăluie noi perspective în acest domeniu pentru studiile viitoare.

Chapter 5

Compresia datelor SAR

Îmbunătățirile capacităților avansate ale sistemului SAR implică, de asemenea, o creștere semnificativă a ratelor de achiziție a datelor SAR, astfel încât metodele de compresie eficiente și eficace devin necesare. Compresia datelor brute SAR joacă un rol crucial în abordarea provocărilor puse de limitele de transfer și de memorie la bordul sateliților SAR și afectează direct calitatea imaginii SAR generate. Tehnicile de compresie neurală folosind modele adânci au atras multe interes pentru sarcinile de compresie a imaginilor naturale și au demonstrat rezultate promițătoare. Privind potențialul imens al rețelelor CV pentru aplicațiile SAR, în acest capitol, ne vom adânci într-o aplicație mai practică a rețelelor CV prin utilizarea lor pentru compresia neurală a datelor brute SAR.

5.1 Prezentare generală

Caracteristicile și particularitățile particulare ale datelor SAR, cum ar fi natura CV, gama dinamică mare, efectul de speckle inherent și corelația spațială, impun dezvoltarea de metode noi de compresie pentru datele SAR brute, având în vedere caracteristicile sale unice. Aceste caracteristici fac ca tehnicile convenționale de compresie a imaginilor să nu fie foarte convenabile.

Tehnicile de învățare profundă au obținut rezultate remarcabile în multe domenii diferite și atrag treptat interesul pentru compresia datelor vizuale. În acest context, autoencoderile sunt larg utilizate pentru compresia imaginilor cu pierdere, în mare parte bazată pe cuantificare și reducerea ratei de biți a datelor imaginii, inclusiv imaginile SAR detectate [27]–[29]. Având în vedere potențialul uriaș și competența ridicată a arhitecturii profunde CV pentru diverse aplicații SAR, explorate în capitolul anterior, în acest capitol, se examinează compresia datelor SAR brute CV. Din cauza indisponibilității datelor SAR brute Sentinel-1 necomprimate, se propune o metodă nouă pentru adăugarea de zgomot de cuantificare uniformă aleatorie la datele brute comprimate FDBAQ pentru a genera date SAR brute necomprimate cu cuantificare aproape uniformă. Mai târziu, este dezvoltat un sistem de compresie bazat pe autoencoder CV pentru compresia datelor SAR neurale. Rețeaua dezvoltată este

evaluată pentru compresia datelor SAR brute cu cuantificare uniformă, iar rezultatele sunt comparate cu metodele de compresie bine cunoscute, BAQ și JPEG2000.

5.2 Generarea datelor SAR brute cu cuantificare aproape uniformă

Ca urmare a indisponibilității datelor brute Sentinel-1 neprocesate, am generat date brute cu cuantizare quasi-uniformă adăugând zgomot de cuantizare la datele SAR brute comprimate FDBAQ. Astfel, am obține eşantioanele originale pe numărul corect de biți. Experimentul a fost efectuat pe cele trei scene Sentinel-1, obținute deasupra orașelor Chicago, Houston și Sao Paulo (adică aceleași scene ca setul de date S1SLC_CVDL).

Procedura definită duce la date cu 256 de nivele de cuantizare. Figura 5.7 ilustrează pașii de cuantizare ai datelor decodeate înainte (albastru) și după (roșu) adăugarea zgomotului uniform, notați axa orizontală (0-255 pentru graficul roșu).




Figure 5.7 Pași de cuantizare în datele decodează, înainte (albastru) și după (roșu) adăugarea zgomotului uniform. Observați axa orizontală (0-255 pentru graficul roșu).

Pentru a evalua metodologia propusă și modul în care afectează metodele de comprimare, algoritmul de comprimare JPEG2000 cu diferite rate de comprimare este aplicat datelor înainte și după adăugarea zgomotului de cuantificare. Este important de menționat că algoritmul JPEG2000 poate fi aplicat doar datelor RV (Real Virtual). Ca rezultat, JPEG2000 este aplicat separat componentelor reale și imaginare ale datelor brute decodeate. Ulterior, datele decomprimate sunt procesate pentru a obține imagini SLC și pentru a calcula Raportul Semnal-Zgomot de Cuantificare (SQNR).

Rezultatele demonstrează că zgomotul de cuantificare adăugat nu a distorsionat datele și imaginile SLC obținute după adăugarea zgomotului de cuantificare au o calitate înaltă. Mai mult, adăugarea zgomotului de cuantificare nu a perturbat performanța metodei de compresie JPEG2000. Aceste rezultate arată eficacitatea metodei de a avea eşantioanele de date brute la numărul corect de biți și de a nu afecta performanța metodei de compresie.

5.3 Compresia Datelor SAR brute

O rețea profundă CV, bazată pe arhitecturile autoencoder, este folosită pentru comprimarea neurală a datelor SAR brute. Arhitectura modelului propus constă în trei părți principale: encoderul, modelul entropic și decoderul. Figura 5.3 arată arhitectura rețelei de compresie bazată pe autoencoderul propus. În această figură, sub fiecare strat de convoluție sau deconvoluție, o casetă arată "numărul de filtre" \times "înălțimea kernelului" \times "lățimea kernelului" | "dimensiunea pasului". În aceste casete, săgețile în jos indică subeșantionarea în straturile de convoluție, iar săgețile în sus indică supraproșirea în straturile deconvoluție. Mai mult, toate straturile de convoluție din encoder au zero padding de 2, iar toate straturile de deconvoluție din decoder au zero padding de 2 și out_padding de 1.

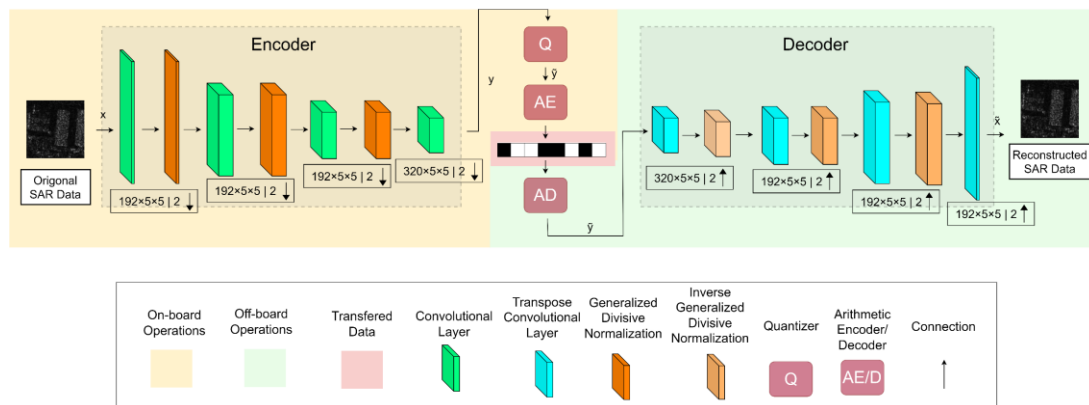


Figure 5.3 Arhitectura modelului de compresie propus bazat pe autoencoder. În această figură, sub fiecare strat de convoluție sau transpose convoluție, o casetă arată "numărul de filtre" \times "înălțimea kernelului" \times "lățimea kernelului" | "dimensiunea pasului". În aceste casete, săgețile îndreptate în jos arată reducerea dimensiunii în straturile de convoluție, iar săgețile îndreptate în sus arată mărirea dimensiunii în straturile de transpose convoluție. Mai mult, toate straturile de convoluție din encoder au un padding de zero de 2, iar toate straturile de transpose convoluție din decoder au un padding de zero de 2 și un out_padding de 1.

Metoda prezentată în secțiunea 5.2 este folosită pentru prelucrarea datelor SAR brute și aplicarea metodelor de compresie. Metodele de compresie BAQ, JPEG2000 și bazate pe autoencodere CV sunt aplicate datelor brute. Trebuie să se menționeze că JPEG2000 este aplicat separat componentelor reale și imaginare ale datelor SAR brute CV. Datele compresate/decompresate sunt prelucrate pentru a obține imaginile SAR SLC, iar metricile de evaluare sunt măsurate între imaginile SAR SLC înainte și după compresie.

Trei măsuri diferite, incluzând SQNR, eroarea de fază și coerența complexă, sunt măsurate între imaginile SLC rezultate înainte și după compresia/decompresia datelor brute cu ajutorul metodelor de compresie bazate pe BAQ, JPEG2000 și autoencoderul CV. Figura 5.12 prezintă comparația SQNR.




Figure 5.12 Analiză comparativă a autoencoderului CV, BAQ și compresiei JPEG2000 cu metrica SQNR. Semnul × portocaliu arată comportamentul neașteptat al BAQ cu 3 bpp, așa cum a fost explicat mai sus.

Rezultatele obținute demonstrează performanța superioară a schemei de compresie bazată pe autoencoderul CV pentru datele brute SAR în comparație cu BAQ și JPEG2000. Autoencoderul CV a obținut un SQNR cu aproximativ 4-6 dB mai mare decât BAQ și cu aproximativ 1-2 dB mai mare decât JPEG2000. Performanța superioară a autoencoderului CV este evidentă și în metricile erorii de fază și coerenței.

5.4 Concluzie

Problema compresiei datelor brute SAR (Synthetic Aperture Radar) este explorată în acest capitol. Metodele de compresie a datelor neurale, bazate pe arhitecturi profunde, sunt extinse la domeniul complex, iar un schema de compresie bazată pe un autoencoder CV (Computer Vision) este proiectată. Mai mult, metodele BAQ (Block Adaptive Quantization) și JPEG2000 sunt folosite pentru compresia datelor SAR. În concluzie, descoperirile acestui capitol demonstrează competența și potențialul arhitecturilor CV profunde pentru compresia datelor brute SAR. Arhitecturile CV sunt competente în gestionarea datelor brute SAR cu caracteristici peculiare. Aceste descoperiri deschid noi perspective și deschid calea pentru avansuri ulterioare ale arhitecturilor CV în studiile viitoare pentru diverse aplicații SAR și misiuni avansate viitoare ale sateliților SAR.

Chapter 6

Concluzie

Scopul principal al acestei teze este de a oferi soluții bazate pe învățare profundă CV pentru date SAR complexe, cu capacitatea de a învăța distribuția SAR în prezența unor eșantioane adverse, de a investiga caracteristicile rețelelor CV pentru coerența complexă și conservarea modelului de date și de a încorpora în modele atributele care țin cont de fizică. În acest scop, în această teză, explorăm arhitecturile profunde CV, implementarea lor și provocările privind utilizarea acestor rețele pentru aplicațiile SAR.

6.1 Principalele Contribuții ale Tezei

Pentru a pune totul la un loc, principalele contribuții ale acestei teze în domeniu pot fi rezumate după cum urmează:

- - Datorită modelului complex de distribuție a SAR, rețelele CV ar trebui să fie capabile să învețe distribuția datelor SAR în prezența eșantioanelor adverse inerente. Această capacitate a rețelelor CV este discutată și se analizează competența diferitelor tehnici de modelare a datelor în acest scop.
- Rețelele CV și operatorii esențiali pentru implementarea lor sunt examinați în detaliu, oferind o explicație cuprinzătoare a diferiților operatori și straturi din arhitecturile CV profunde.
- Ineritul de date EO mare cu conținut semantic folosind modelul generativ Bayesian, Alocația Dirichlet Latentă, este explorat pentru diverse aplicații de teledetecție.
- Tehnica de minerit de date bazată pe LDA este folosită pentru a genera setul de date S1SLC_CVDL, primul set de date semnificativ adnotat semantic la scară mare din datele Sentinel-1 (S1) SLC, destinat antrenării modelelor de Învățare Profundă pentru Vizualizare Computerizată (CVDL).
- Se efectuează analize cuprinzătoare asupra rețelelor CV și se examinează competența lor pentru aplicațiile de date SAR în diferite aspecte.:
 - Performanța de clasificare a rețelei CV este comparată cu arhitectura echivalentă RV, precum și cu o arhitectură de clasificare de ultimă

- generație, HRNet. Aceste comparații arată că rețeaua CV obține o precizie mai mare în clasificare cu mai puține exemple de antrenament și arhitecturi mai superficiale (adică cu cost computațional mai mic).
- Atributele fizice din datele SAR sunt încorporate în modelele CV și ilustrează fezabilitatea arhitecturilor CV conștiente de fizică.
 - Pentru prima dată, este examinată capacitatea rețelelor CV de a învăța distribuția datelor de modelare a datelor SAR în prezența unor eșantioane adversative inerente și de a păstra coerența complexă a datelor SAR.
 - Pentru prima dată, rețelele CV sunt explorează pentru a învăța modelul de date fizice al datelor SAR și pentru a păstra informațiile referitoare la centroidul Doppler și proprietățile originale ale datelor SAR. Această capacitate a arhitecturilor CV este examinată în ceea ce privește estimarea curentului de suprafață oceanic și demonstrează potențialul acestor rețele pentru interpretarea informațiilor fizice ale datelor SAR.
 - Se studiază conceptele necesare pentru compresia datelor SAR brute (de exemplu, teoria ratei-deformație, codificarea aritmetică și tehnicile standard de compresie). Se explorează fezabilitatea algoritmului bine-cunoscut JPEG2000 pentru compresia datelor SAR brute și se demonstrează o performanță superioară în comparație cu tehnica BAQ.
 - În cele din urmă, pentru prima dată, conceptul de compresie a datelor neurale este evaluat pentru compresia datelor SAR brute. Datele SAR brute au caracteristici peculiare și modelul de compresie ar trebui să le poată păstra pentru focalizare și obținerea imaginii SAR. Este proiectat și implementat un schemă de compresie bazată pe autoencoder CV în acest scop și s-a demonstrat potențialul remarcabil al rețelelor CV în acest sens.

6.2 Lista publicațiilor

6.2.1 Articole din jurnal

1. R. M. Asiyabi and M. Datcu, “Earth Observation Semantic Data Mining: Latent Dirichlet Allocation-based Approach,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, J-STARS*, vol. 15, pp. 2607-2620, 2022, doi: 10.1109/JSTARS.2022.3159277.
2. R. M. Asiyabi, M. Datcu, A. Anghel, and H. Nies, “Complex-Valued End-to-end Deep Network with Coherency Preservation for Complex-Valued SAR Data Reconstruction and Classification,” *IEEE Transactions on Geoscience and Remote Sensing, TGRS*, vol. 61, pp. 1-17, 2023, Art no. 5206417, doi: 10.1109/TGRS.2023.3267185.

3. R. M. Asiyabi, M. Datcu, and A. Anghel, "Complex-valued autoencoder-based compression scheme for SAR raw data," To be Submitted, 2023.

6.2.2 Lucrările conferinței

1. R. M. Asiyabi and M. Datcu, "Earth Observation Image Semantics: Latent Dirichlet Allocation Based Information Discovery," in IGARSS 2021 - IEEE International Geoscience and Remote Sensing Symposium, Brussels, Belgium, 2021, pp. 2620-2623, doi: 10.1109/IGARSS47720.2021.9553122.
2. R. M. Asiyabi, M. Datcu, H. Nies and A. Anghel, "Complex-Valued Vs. Real-Valued Convolutional Neural Network for PolSAR Data Classification," in IGARSS 2022 - IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia, 2022, pp. 421-424, doi: 10.1109/IGARSS46834.2022.9884081.
3. R. M. Asiyabi, M. Datcu, A. Anghel and H. Nies, "Complex-Valued Autoencoders with Coherence Preservation for SAR," in EUSAR 2022; 14th European Conference on Synthetic Aperture Radar, Leipzig, Germany, 2022, pp. 1-6.
4. R. M. Asiyabi, A. Anghel, P. Rizzoli, M. Martone, and M. Datcu, "Complex-Valued Autoencoder for Multi-Polarization SLC SAR Data Compression with Side Information," in IGARSS 2023 - IEEE International Geoscience and Remote Sensing Symposium, Pasadena, United States, 2023, pp. 1787–1790.
5. M. A. Iqbal, R. M. Asiyabi, O. Ghozatlou, M. Datcu, and A. Anghel, "Towards Complex-Valued Deep Architectures with Data Model Preservation for Sea Surface Current Estimation from SAR Data," in CBMI 2023 - 20th International Conference on Content-based Multimedia Indexing, Orleans, France, 2023.
6. R. M. Asiyabi, A. Anghel, A. Focsa, M. Datcu, M. Martone, P. Rizzoli, and E. Imbembo, "On the use of JPEG2000 for SAR raw data compression," Submitted to the European Conference on Synthetic Aperture Radar, EUSAR, 2024.

6.2.3 Seturi de date

1. R. M. Asiyabi, M. Datcu, A. Anghel, H. Nies, April 8, 2023, "S1SLC_CVDL: A Complex-Valued Annotated Single Look Complex Sentinel-1 SAR dataset for Complex-Valued Deep Networks", IEEE DataPort, doi: <https://dx.doi.org/10.21227/nm4g-yd98>.

Bibliografie

- [1] X. X. Zhu *et al.*, “Deep learning in remote sensing: A comprehensive review and list of resources,” *IEEE Geosci. Remote Sens. Mag.*, vol. 5, no. 4, pp. 8–36, 2017.
- [2] R. Mohammadi Asiyabi, M. Datcu, A. Anghel, and H. Nies, “Complex-Valued End-to-end Deep Network with Coherency Preservation for Complex-Valued SAR Data Reconstruction and Classification,” *IEEE Trans. Geosci. Remote Sens.*, 2023.
- [3] R. Mohammadi Asiyabi and M. Datcu, “Earth Observation Semantic Data Mining: Latent Dirichlet Allocation-based Approach,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 15, pp. 2607--2620, 2022.
- [4] R. Mohammadi Asiyabi and M. Datcu, “Earth Observation Image Semantics: Latent Dirichlet Allocation Based Information Discovery,” in *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, IEEE, 2021, pp. 2620–2623.
- [5] R. Mohammadi Asiyabi, M. Datcu, A. Anghel, and H. Nies, “S1SLC_CVDL: A Complex-Valued Annotated Single Look Complex Sentinel-1 SAR dataset for Complex-Valued Deep Networks,” *IEEE Dataport*, 2023, doi: <https://dx.doi.org/10.21227/nm4g-yd98>.
- [6] R. Mohammadi Asiyabi, M. Datcu, and A. Anghel, “Complex-valued autoencoder-based compression scheme for SAR raw data,” *Ready to Submit*, 2023.
- [7] R. Mohammadi Asiyabi, M. Datcu, A. Anghel, and H. Nies, “Complex-Valued Autoencoders with Coherence Preservation for SAR,” in *EuSAR 2022*, 2022, pp. 1–6.
- [8] R. Mohammadi Asiyabi, M. Datcu, H. Nies, and A. Anghel, “Complex-Valued Vs. Real-Valued Convolutional Neural Network for Polsar Data Classification,” in *IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2022, pp. 421–424.
- [9] M. A. Iqbal, R. Mohammadi Asiyabi, O. Ghozatlou, M. Datcu, and A. Anghel, “Towards Complex-Valued Deep Architectures with Data Model Preservation for Sea Surface Current Estimation from SAR Data,” in *CBMI 2023 - 20th International Conference on Content-based Multimedia Indexing*, Orleans, 2023.
- [10] R. Mohammadi Asiyabi *et al.*, “On the use of JPEG2000 for SAR raw data compression,” *Proc. Eur. Conf. Synth. Aperture Radar, EUSAR*, 2024.
- [11] F. Meyer, “Spaceborne Synthetic Aperture Radar: Principles, data access, and basic processing techniques,” *Synth. Aperture Radar Handb. Compr. Methodol. For. Monit. Biomass Estim.*, pp. 21–64, 2019.
- [12] M. Datcu, Z. Huang, A. Anghel, J. Zhao, and R. Cacoveanu, “Explainable, Physics-Aware, Trustworthy Artificial Intelligence: A paradigm shift for synthetic aperture radar,” *IEEE Geosci. Remote Sens. Mag.*, vol. 11, no. 1, pp. 8–25, 2023.
- [13] A. Hirose and S. Yoshida, “Comparison of complex-and real-valued feedforward neural networks in their generalization ability,” in *International Conference on Neural Information Processing*, Springer, 2011, pp. 526–531.

- [14] J. A. Barrachina, C. Ren, C. Morisseau, G. Vieillard, and J. P. Ovarlez, “Complex-valued vs. Real-valued neural networks for classification perspectives: An example on non-circular data,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 2021-June, pp. 2990–2994, 2021, doi: 10.1109/ICASSP39728.2021.9413814.
- [15] W. Wirtinger, “Zur formalen theorie der funktionen von mehr komplexen veränderlichen,” *Math. Ann.*, vol. 97, no. 1, pp. 357–375, 1927.
- [16] Z. Zhang, H. Wang, F. Xu, and Y.-Q. Jin, “Complex-valued convolutional neural network and its application in polarimetric SAR image classification,” *IEEE Trans. Geosci. Remote Sens.*, vol. 55, no. 12, pp. 7177–7188, 2017.
- [17] H. Mu, Y. Zhang, Y. Jiang, and C. Ding, “CV-GMTINet: GMTI Using a Deep Complex-Valued Convolutional Neural Network for Multichannel SAR-GMTI System,” *IEEE Trans. Geosci. Remote Sens.*, vol. 60, pp. 1–15, 2021.
- [18] J. Zhang and Y. Wu, “A new method for automatic sleep stage classification,” *IEEE Trans. Biomed. Circuits Syst.*, vol. 11, no. 5, pp. 1097–1110, 2017.
- [19] J. Liu, M. Xing, H. Yu, and G. Sun, “EFTL: Complex convolutional networks with electromagnetic feature transfer learning for sar target recognition,” *IEEE Trans. Geosci. Remote Sens.*, vol. 60, pp. 1–11, 2021.
- [20] R. Hänsch and O. Hellwich, “Classification of polarimetric SAR data by complex valued neural networks,” in *ISPRS workshop high-resolution earth imaging for geospatial information*, 2009, pp. 4–7.
- [21] P. J. Schreier and L. L. Scharf, *Statistical signal processing of complex-valued data: the theory of improper and noncircular signals*. Cambridge university press, 2010.
- [22] D. M. Blei, A. Y. Ng, and M. I. Jordan, “Latent dirichlet allocation,” *J. Mach. Learn. Res.*, vol. 3, no. Jan, pp. 993–1022, 2003.
- [23] A. Marino, M. J. Sanjuan-Ferrer, I. Hajnsek, and K. Ouchi, “Ship detection with spectral analysis of synthetic aperture radar: A comparison of new and well-known algorithms,” *Remote Sens.*, vol. 7, no. 5, pp. 5416–5439, 2015.
- [24] C. López-Martínez and E. Pottier, “Coherence estimation in synthetic aperture radar data based on speckle noise modeling,” *Appl. Opt.*, vol. 46, no. 4, pp. 544–558, 2007.
- [25] M. A. Iqbal, A. Anghel, and M. Datcu, “Coastline extraction from sar data using doppler centroid images,” *IEEE Geosci. Remote Sens. Lett.*, vol. 19, pp. 1–5, 2022.
- [26] M. A. Iqbal, A. Anghel, and M. Datcu, “On the de-ramping of SLC-IW Tops SAR data and ocean circulation parameters estimation,” in *IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2022, pp. 6817–6820.
- [27] Q. Xu *et al.*, “Synthetic aperture radar image compression based on a variational autoencoder,” *IEEE Geosci. Remote Sens. Lett.*, vol. 19, pp. 1–5, 2021.
- [28] J. Ballé, D. Minnen, S. Singh, S. J. Hwang, and N. Johnston, “Variational image compression with a scale hyperprior,” *arXiv Prepr. arXiv1802.01436*, 2018.
- [29] C. Fu, B. Du, and L. Zhang, “SAR Image Compression Based on Multi-Resblock and Global Context,” *IEEE Geosci. Remote Sens. Lett.*, vol. 20, pp. 1–5, 2023.