



UNIVERSITATEA NAȚIONALĂ DE ȘTIINȚĂ
ȘI TEHNOLOGIE POLITEHNICA
BUCUREȘTI (UNSTPB)



Școala Doctorală de Electronică, Telecomunicații și
Tehnologia Informației

Decizie nr. 120 din 26.10.2023

REZUMAT TEZĂ DE DOCTORAT

Muhammad Amjad IQBAL

RECONSTRUCTIA IMAGINILOR SAR DE INALTA REZOLUTIE
SPARSE RECONSTRUCTION FOR HIGH-RESOLUTION
INVERSE SAR IMAGING

COMISIA DE DOCTORAT

Prof. dr. ing. Gheorghe BREZEANU UNSTPB	Peședinte
Prof. dr. ing. Andrei ANGHEL UNSTPB	PhD Conducător de Doctorat
Prof. dr. ing. Emanuel PUSCHITA Technical University of Cluj-Napoca	Referent
Dr. ing. habil. Miguel HEREDIA CONDE University of Siegen, Germany	Referent
Dr. ing. Andreas BATHELT Fraunhofer Institute (FHR), Germany	Referent
Prof. dr. ing. Mihai DATCU UNSTPB	Referent

BUCURESTI 2023

Cuprins

1	Introducere	1
1.1	Domeniul tezei de doctorat	1
1.2	Obiectivele tezei de doctorat	1
1.3	Conținutul original al tezei de doctorat	2
2	Estimarea Doppler Centroid pentru Recuperarea OSC	3
2.1	Estimarea Doppler Centroid	3
2.1.1	Estimarea Doppler a corelației	4
2.1.2	Estimarea semnului Doppler	4
2.1.3	Echilibrarea energiei pentru estimarea Doppler	4
2.1.4	Recuperarea curentului de suprafață oceanică	5
2.2	Rezultate și concluzie	5
3	De-ramp pentru estimarea OSC și rețeaua CV pentru a păstra datele SAR	7
3.1	Despre De-rampul datelor TOPS SAR	7
3.2	Rețea cu valoare complexă pentru conservarea datelor SAR TOPS	9
4	Date polarimetrice SAR pentru detectarea țintei bazate pe CFAR	12
4.1	Extractia coastei folosind imagini Doppler centroide	12
4.2	Descompunerea SA pentru detectarea navei	14
4.3	Delimitarea stratului de gheață folosind metoda CFAR	16
5	Reconstrucția imaginii SAR invers și extragerea caracteristicilor rare	18
5.1	Evaluarea imagistică ISAR	18
5.2	Estimarea proprietăților de împrăștiere a imaginilor ISAR	20
5.3	Estimarea CTF pentru Imagistica CS-ISAR	23
6	Concluzie	26
6.1	Concluzie	26
6.2	Muncă viitoare	26
6.3	Publicații	27
	Bibliografie	29

Capitolul 1

Introducere

Sistemele radar funcționează bine în detectarea în orice condiții meteorologice, fie ploioase sau înnorate, luminoase sau întunecate; prin urmare, acționează ca senzori primari. În teledetecție, radarul cu deschidere sintetică (SAR) și SAR invers sunt vitale pentru observarea Pământului și detectarea țintei. Mișcarea, care rezultă din mișcarea platformei sau a țintei, este cheia pentru imagistica radar [1, 2].

1.1 Domeniul tezei de doctorat

Radarul cu deschidere sintetică inversă (ISAR) oferă imagini ale obiectelor care sunt rotite în raport cu radarul. Este necesar un algoritm eficient de focalizare a imaginii pentru a genera imagini ISAR din ecourile datelor brute. Odată cu progresul tehnologiei radar, imagistica a devenit o funcție importantă a radarelor. Domeniul tezei de doctorat utilizează datele SAR monostatice de la Sentinel-1 pentru teledetecția oceanelor și imagistica SAR inversă prin exploatarea radarelor cu unde mmw și în bandă X. Datele polarimetrice obținute de la radar oferă o oportunitate de a extrage caracteristici, de a delimita ținte și de a reconstrui imagini folosind polarizarea adecvată în circumstanțe date. Mai mult, descompunerea polarizării îmbunătățește extragerea proprietăților și a informațiilor necesare. Datele radar pentru reconstrucția rară sunt un subiect emergent în detectarea compresivă pentru imagistica ISAR. Reconstituirea imaginii țintei direct din datele brute cu un număr limitat de eșantioane reduce supraîncărcarea sistemelor radar și îmbunătățește capacitățile radarelor de a detecta ținte cu intervale scurte de procesare coerente [3].

1.2 Obiectivele tezei de doctorat

Prelucrarea semnalului și a imaginii datelor SAR și ISAR este punctul central al acestei teze. Sunt abordate mai multe probleme, inclusiv estimarea parametrilor de circulație oceanică pe baza centroidului Doppler, conservarea datelor SAR prin rețele CV, de-

limitarea liniilor de coastă și a liniei de gheață prin metode CFAR, detectarea țintei corporative sau non-corporate prin imagistică și detectarea compresivă pentru ISAR de înaltă rezoluție imagistica. Lucrările viitoare sunt de a adapta calculul paralel nou dezvoltat pentru interferometria de-a lungul căii pentru a avansa sistemele SAR bistatice pentru estimarea curentului oceanic. De asemenea, imagistica de înaltă rezoluție a țintelor necesare în mișcare neconstrânsă cu mai puține mostre de date va reduce timpul de scanare a sistemelor SAR și ISAR.

1.3 Conținutul original al tezei de doctorat

Lucrarea deosebit de distinctă prezentată în această teză este clasificată în trei secțiuni.

Prima parte este un studiu privind estimarea centroidului Doppler pentru regăsirea curentului OSC folosind atât datele Strip-map, cât și TOPS SAR [4]. Avansarea calculului paralel oferă oportunitatea de a reduce constrângerile de memorie pentru estimările Doppler de suprafață mare a oceanului. Am dezvoltat de-rampul datelor TOPS similar cu metodele SOA, care este ușor de utilizat și ușor de adaptat [5]. De asemenea, păstrăm proprietățile Doppler ale datelor SAR utilizând o arhitectură CV nouă. Rezultatele experimentale și analitice demonstrează caracterul practic al metodologiei modificate și propuse pentru teledetecția oceanelor.

A doua parte este un studiu al detectării țintei SAR prin utilizarea algoritmului de detectare CFAR. O nouă metodă de extracție a liniei de coastă bazată pe centroid Doppler este propusă cu conceptul de linie de coastă statică pavează zero Doppler [6]. În plus, metoda de descompunere a sub-apertura (SA) este utilizată pentru a genera SA multiple, care sunt apoi mediate pentru a îmbunătăți TCR, în timp ce matricea de corelație cu dublu pol este propusă pentru detectarea navei folosind abordarea CFAR. Extinderea acestei strategii la extracția stratului de gheață a oferit rezultate excelente în extracția stratului de gheață cu ajutorul CFAR. Metoda este evaluată experimental și cantitativ pentru acordul general între detectarea țintă și non-țintă.

A treia și ultima secțiune a studiului a acoperit detectarea compresivă, extracția caracteristicilor rare și imagistica ISAR pentru detectarea țintei. Cu utilizarea imaginilor îmbunătățite cu numărul de undă ISAR ($\omega - k$), imaginile pot fi focalizate cu o rezoluție adecvată și cu cheltuieli de calcul minime. Apoi, prin utilizarea imaginilor ISAR și a descompunerii dual-pol $H - \alpha$, caracteristicile rare ale țintelor arborelui sunt recuperate. În cele din urmă, am reușit să reconstruim imagini ISAR folosind doar o cantitate limitată de eșantioane de date datorită estimărilor grosiere până la fine, care ne-au apropiat foarte mult de imagistica țintă în timp real.

Capitolul 2

Estimarea Doppler Centroid pentru Recuperarea OSC

Estimarea exactă a f_{DC} a datelor primite este crucială în procesarea SAR. Estimările slabe introduc niveluri de zgomot și ambiguitate în imaginea procesată, ducând adesea la un impact semnificativ asupra clarității imaginii. Estimarea precisă a f_{DC} este o provocare, deoarece măsurătorile se bazează exclusiv pe geometrie, iar datele primite pot conține anomalii locale care împiedică procesul de estimare. O estimare necorespunzătoare f_{DC} poate duce la pierderea SNR, o ambiguitate sporită a azimutului și pierderea unor informații specifice, cum ar fi curentul de suprafață și viteza vântului.

2.1 Estimarea Doppler Centroid

Contribuția principală în acest capitol este utilizarea unei ferestre glisante 2D și a unui filtru de convoluție pentru estimarea f_{DC} pe baza algoritmilor predominanți ai CDE, SDE și EB. Mișcarea relativă a radarului sau a scenei dinamice sub observație prezintă o deplasare Doppler, dată ca:

$$f_D = -\frac{k_{\text{Rad}}V}{\pi} \quad (2.1)$$

unde k_{Rad} este numărul de undă radar și V este viteza liniei de vedere a țintei. Centroidul Doppler f_{DC} poate fi estimat din datele procesate SAR. Dacă zona sub observație este staționară, deplasarea Doppler anormală va fi zero. Algoritmii predominanți pentru a estima f_{DC} fie prin găsirea centroidului spectrului de putere al semnalului în direcția azimutală, adică EB [7]; sau prin faza funcției de auto-corelare, adică CDE [8]; sau corelarea părților reale și imaginare ale datelor SAR complexe numai prin semn, cunoscută sub denumirea de Estimare Doppler semnelui (SDE).

2.1.1 Estimarea Doppler a corelației

Metoda de estimare Doppler a corelației (CDE) implică o corelație încrucișată a imaginii SLC ‘ S ’ cu versiunea sa deplasată ‘ S^* ’ în direcția azimutală ‘ $\Delta\eta$ ’. [4]. Folosind fereastra glisantă ‘ W ’ de dimensiunea $N \times N$ a calculat local corelația în direcția azimutului și a efectuat o operație de mediere în direcția intervalului, Faza ‘ ϕ ’ a termenului de corelație $C(\eta, \tau) = S \cdot S^*$ este estimată ca:

$$\phi(\eta, \tau) = \arg \{ \langle S(\eta, \tau) S^*(\Delta\eta, \tau) \rangle \} \quad (2.2)$$

Pe baza frecvența de repetare a impulsurilor (PRF) și a funcției de corelare a fazelor, f_{DC} se calculează după cum urmează:

$$f_{DC}(\eta, \tau) = -\frac{\text{PRF}}{2\pi} \phi(\eta, \tau) \quad (2.3)$$

2.1.2 Estimarea semnului Doppler

Tehnica de estimare a semnului Doppler utilizează corelația. Principiul de bază al acestei abordări se învârtă în jurul valorificării „legii arcsinului” inerente unui proces gaussian.

$$Y = \sin \left(\frac{\pi}{2} R[II, IQ, QI, QQ] \right) \quad (2.4)$$

unde R conține corelația fiecărei părți reale (I) și imaginare (Q), funcția semn a semnalului $Z(t)$ este dată ca:

$$Z(t) = \begin{cases} 1, & \text{for } Y(t) \geq 0 \\ -1, & \text{for } Y(t) < 0 \end{cases} \quad (2.5)$$

deoarece $Z(t)$ ia doar valoarea +1 și -1, de aceea este numit semnul $Y(t)$. Pentru a estima Doppler, obțineți mai întâi corelații cu 4 semne, inclusiv II, IQ, QI , and QQ , apoi obțineți coeficienții de corelație corespunzători și coeficienții de corelație complexi, dați ca:

$$R(k) = \frac{1}{2}(\rho_{II} + \rho_{QQ}) + j\frac{1}{2}(\rho_{IQ} - \rho_{QI}) \quad (2.6)$$

în cele din urmă, convertiți argumentul $R(k)$ în f_{DC} după cum este prezentat mai jos:

$$f_{DC}^{SDE} = \frac{\text{PRF}}{2\pi\Delta\delta} \times (\arg\{R(k)\}) \quad (2.7)$$

2.1.3 Echilibrarea energiei pentru estimarea Doppler

Pasul-1 Pentru a estima f_{DC} utilizând echilibrarea energiei metoda, la început, calculați spectrul de putere medie $S(n)$ în direcția azimutală.

Pasul-2 Pentru a realiza funcția de referință $R(f)$ și a asigura că EB este atins, suma

circulară cumulativă se aplică, astfel încât energia spectrului să fie egală pe ambele părți:

$$R(f) = \begin{cases} -1, & \text{pentru } 0 \leq f \leq \frac{\text{PRF}}{2}, \\ +1, & \text{pentru } -\frac{\text{PRF}}{2} \leq f \leq 0, \\ 0, & \text{dacă nu.} \end{cases} \quad (2.8)$$

Pasul-3 Deoarece $R(f)$ este în formă continuă, corelația circulară poate fi determinată după cum urmează:

$$C(n) = \text{IFFT}\{\text{FFT}(S(n)) \times \text{conj}(R(n))\} \quad (2.9)$$

Pasul-4 În cele din urmă, prin informațiile de corelație circulară, f_{DC} este estimat ca:

$$f_{\text{DC}}^{\text{EB}} = \frac{N_{\text{DC}}}{N} \times \text{PRF} \quad (2.10)$$

unde N_{DC} este punctul de trecere zero al circularei corelație, în timp ce N aparține lungimii datelor de azimut.

2.1.4 Recuperarea curentului de suprafață oceanică

Curentul de suprafață oceanică (OSC) este derivat din f_{DC} , unghiul de incident θ și numărul de undă k_r , dat de [9]:

$$U_D = -\frac{\pi f_{\text{DC}}(\eta, \tau)}{k_r \sin \theta} \quad (2.11)$$

în timp ce valoarea calculată a k_r este $113,28 \text{ m}^{-1}$ pentru Sentinel-1.

2.2 Rezultate și concluzie

Au fost efectuate experimente pentru a evalua tehnicile CDE, SDE și EB, pentru a compara performanța acestora și, ulterior, pentru a deriva curenții de suprafață oceanică pe baza istoriei estimate f_{DC} . Datele SAR Sentinel-1 cu modul SM și polarizare VH au fost utilizate pentru această sarcină. O fereastră glisantă 2D de 64×64 pixeli este utilizată pentru a estima f_{DC} cu ajutorul unui filtru de convoluție 2D. Rezultatele sunt limitate la intervalul de bandă de bază primitivă ($\pm \text{PRF}/2$). Valorile pozitive indică faptul că Doppler-ul se deplasează spre platformă. f_{DC} de nave în mișcare în scena SAR dată modifică omogenitatea Doppler datorită echilibrării spectrului, deoarece valorile împrăștiate în spate ale țintelor punctuale (cum ar fi navele) sunt mai mari în comparație cu pixelii apei oceanului. Curenții de suprafață oceanici sunt preluați din istoricul f_{DC} și din gama unghiurilor de incidente. Curentul fluctuează până la 3 m/sec, în funcție de natura Doppler. Totuși, semnele (+ și -) depind de informațiile f_{DC} . Valorile curente sunt




Figura 2.1 Semnătura centroidului Doppler pentru o scenă SAR dată, obținută prin metodele CDE, EB și SDE.




Figura 2.2 Curentul de suprafață oceanic extras pe baza Doppler Centroid estimat de CDE, EB, SDE.

modificate în metoda EB datorită prezenței unor ținte evidente în mișcare în scena SAR, așa cum se poate observa în Fig. 2.2(b). Pe baza experimentelor date, este important de remarcat faptul că, în timp ce atât CDE, cât și SDE funcționează bine pentru scene distribuite și neomogene, metoda EB demonstrează performanțe favorabile în primul rând în scene omogene.

Sunt implementate trei tehnici SOA pentru a estima f_{DC} pentru a extrage curentul de suprafață oceanic și pentru a le compara numeric performanța. Metodele CDE și SDE realizează un f_{DC} stabil în intervalul de bandă de bază primitivă ($\pm PRF/2$). Diferența dintre toate metodele este dramatică dintr-un motiv: metoda EB domină f_{DC} datorită prezenței țintelor punctuale în scenă. Se ajunge la concluzia că, pentru scenele SAR distribuite și neomogene, atât CDE, cât și SDE funcționează foarte bine, iar metoda EB funcționează frumos fie pentru ținte punctuale, fie pentru scene omogene. Estimarea scade atunci când omogenitatea este distrusă într-o scenă cu ținte punctuale proeminente.

Capitolul 3

De-ramp pentru estimarea OSC și rețeaua CV pentru a păstra datele SAR

Caracteristicile spectrale ale unei benzi interferometrice complexe cu aspect unic (SLC-IW) și ale observării terenului prin scanare progresivă (TOPS) sunt semnificativ diferite de cele ale unei hărți cu bandă (SM). În modul TOPS, informațiile de fază sunt păstrate și, fără derampare, apar rampe pentru componentele extrase din informațiile de azimut, și anume centroidul Doppler (f_{DC}). Prin urmare, este necesară o soluție pentru a depăși această problemă în timp ce se exploatează datele TOPS SAR. Pentru a elimina termenul de fază, este generat un semnal de ciripit în scopul derampării. Se discută apoi metoda de derampare, propunând o utilizare eficientă a instrumentului SNAP pentru atingerea acestui obiectiv.

3.1 Despre De-rampul datelor TOPS SAR

Pentru a extrage termenul de fază păstrat, este esențial să mutați componenta spectrală a SLC-IW în banda de bază. Termenul de fază trebuie înmulțit în domeniul timpului cu semnalul SLC S_{SLC} . Termenul de fază pentru derampare este definit ca:

$$\phi(\eta, \tau) = \exp\{(-j\pi k_t(\tau))(\eta - \eta_{ref}(\tau))^2\} \quad (3.1)$$

unde, timpul de referință $\eta_{ref}(\tau)$ și rata centroidului Doppler $k_t(\tau)$ sunt funcție de eșantioanele din interval. După evaluarea parametrilor necesari, de-ramparea pentru a anula deriva pătratică poate fi realizată prin simpla înmulțire a termenului de fază cu semnalul SLC.

$$S_d(\eta, \tau) = S_{SLC} \times \phi(\eta, \tau) \quad (3.2)$$

Rampele de la datele TOPS sunt eliminate folosind un semnal ciripit, rezultând în achiziția datelor în bandă de bază, așa cum este prezentat în Fig. 3.1 (a). Alternativ, de-ramparea poate fi realizată în instrumentul SNAP utilizând operatorul Sentinel-1 TOPS

[5]. Metodologia completă pas cu pas este prezentată în Fig. 3.1 (b). Deoarece TOPS constă din mai multe benzi, mai întâi împărțiți banda necesară și aplicați operatorul “deramp-demod”. Pentru a compensa distanța nulă azimutală (pentru a evita rampele reziduale) dintre fiecare explozie, operatorul „deburst” ajută foarte mult la realizarea unei scene rafinate și la eliminarea dungilor care împiedică extragerea caracteristicilor. Deoarece accentul principal este doar pe estimarea parametrilor Doppler oceanic, instrumentul SNAP ajută la mascarea suprafeței de uscat, sporind astfel acuratețea estimărilor noastre. Mască terestre-ocean se aplică pentru a evita efectul Doppler cauzat de obiectele dinamice prezente pe uscat.

Parametrii de circulație oceanică din acest capitol sunt extrași din date SAR complexe care sunt bazate pe date, în timp ce parametrii din benchmark/referință sunt prevăzuți din informațiile despre produse oceanice (OCN) și se bazează pe polinoamele date în metadata. Centroidul Doppler f_{DC} și estimarea OSC sunt date în capitolul-2. Astfel, OSC este utilizat pentru a regăsi înălțimea semnificativă a undei (SWH) în domeniul imaginii pe baza relației empirice dată ca:

$$\mathbf{H}_S = 4\sqrt{\frac{1}{T} \sum_{i=1}^T (U_D^{(i)})^2} \quad (3.3)$$

unde, \mathbf{H}_S este un parametru important pentru ingineria litoralului. SWH este înălțimea medie a undei într-o anumită perioadă de timp T , care este intervalul de timp azimut al datelor sub observație.

De-rampul se face până acum pentru a elimina deviația pătratică a termenului de fază prin semnalul ciripit sau folosind instrumentul SNAP. Când termenul de fază $\phi(\eta, \tau)$ este înmulțit cu semnalul SLC original S_{SLC} , datele se mută în domeniul de bandă de bază, așa cum se arată în partea de jos a Fig. 3.1. Parametrii de circulație oceanică includ OSC și, SWH. OSC este evaluat folosind f_{DC} estimat prin metoda CDE, care se potrivește

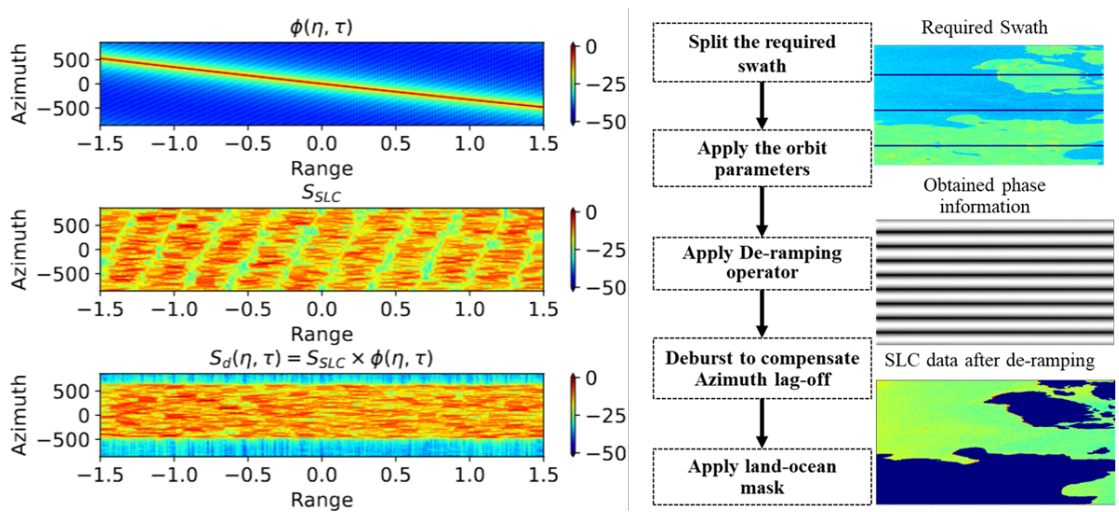


Figura 3.1 De-rampa folosind metoda ESA. (b) De-rampa folosind instrumentul SNAP.




Figura 3.2 OSC (m/s) derivat din centroid Doppler bazat pe date (b) SWH (m) derivat din RSV.

perfect cu datele de referință prezentate în Fig. 3.2 RSV este într-o potrivire bună și atinge până la 2,5 m/s în nucleu a pârâului. Viteza de suprafață pe sol este zero, deoarece terenul este mascat și pavajul zero doppler. Estimările rezonabile ale parametrilor care demonstrează eficacitatea și necesitatea reducerii rampei pentru datele SLC-IW TOPS. Estimarea erorii lipsește în această parte și mai rămân de investigat un parametru fizic referitor la câmpul curentului oceanic, care va fi efectuat în secțiunea ulterioară a acestui capitol.

3.2 Rețea cu valoare complexă pentru conservarea datelor SAR TOPS

Aplicațiile învățării profunde cresc rapid. Dezvoltarea rețelelor cu valoare complexă (CV) care pot procesa datele CV a deschis o mulțime de oportunități de utilizare a capacităților imense ale rețelelor profunde pentru date CV, inclusiv Radarul cu deschidere sintetică (SAR). În această secțiune este evaluată competența arhitecturilor profunde ale CV-ului pentru păstrarea proprietăților datelor SAR originale și modul în care acestea afectează regăsirea parametrului fizic. OSC-urile obținute sunt comparate pentru a demonstra capacitatea arhitecturilor profunde CV de a învăța modelul de date și de a păstra informațiile Doppler originale în datele SAR.

O rețea complet CV este utilizată în acest studiu pentru a reconstrui imaginile CV SAR. Toate straturile din această rețea, inclusiv straturile convoluționale, de grupare și de normalizare a loturilor, sunt în domeniul complex. Mai mult, greutatea și prejudecățile neuronilor și funcțiile de activare sunt complexe. Mai mult, o retropropagare CV, bazată pe coborârea gradientului stocastic, este utilizată pentru antrenarea autoencoderului CV. Cu toate acestea, funcția de pierdere rămâne în domeniul real pentru a minimiza problemele empirice [10].

Toate operațiile matematice din rețeaua CV sunt efectuate în domeniul complex. De exemplu, stratul convoluțional, care este o componentă importantă a rețelelor profunde și este utilizat în diferite arhitecturi profunde pentru a extrage caracteristici latente discriminante din datele de intrare, este aplicat în domeniul complex. Ieșirea convoluției, $y_i^{(l+1)} \in \mathbb{C}^{W_2 \times H_2 \times l}$ este calculată prin convoluția dintre harta caracteristică de intrare din stratul anterior, $X_{iC}^l \in \mathbb{C}^{(W_1 \times H_1 \times C)}$ și greutatea neuronilor, $w_{iC}^{(l+1)} \in \mathbb{C}^{F \times F \times C \times l}$ și apoi adăugând o părtinire, $b_i^{(l+1)} \in \mathbb{C}^l$.

Pentru a antrena rețeaua CV, calculul Wirtinger este utilizat pentru a efectua retro-propagarea în domeniul complex [11]. Conform calculului Wirtinger, derivatele parțiale ale unei funcții complexe $f(z)$ față de variabila complexă $z = x + jy \in \mathbb{C}$, $(x, y) \in \mathbb{R}^2$.

Arhitectura autoencoderului CV dezvoltat constă din două părți principale, un encoder și un decodor. Codificatorul este utilizat pentru a codifica imaginea SAR de intrare și pentru a crea caracteristicile încorporate în blocaj. Mai târziu, partea decodorului reconstruiește imaginea CV-SAR din caracteristicile încorporate. Conexiunile skip între codificator și decodor sunt folosite pentru a reduce riscul de degradare în rețeaua adâncă și pentru a asigura un flux neîntrerupt al gradientilor în rețea [12]. Ambele canale de polarizare ale datelor CV-SAR sunt introduse în rețea ca patch-uri de 100×100 pixeli. Rețeaua CV reconstruiește ambele canale de polarizare în același timp.

Evaluăm performanța autoencoderului CV și capacitatea acestuia de a păstra informațiile originale ale centrului Doppler. Autoencoderul CV, antrenat în [12], sunt utilizate date în modul Sentinel-1 StripMap (SM) cu canale de polarizare HH și HV (diferite de setul de date utilizat în acest studiu). Datele IW de-rampate cu canalele de polarizare VV și VH sunt reconstruite cu rețeaua antrenată. Rezultatele acestui experiment sunt adnotate ca fiind reconstruite (R).

Rețeaua este reantrenată, folosind datele SAR SLC-IW TOPS cu canale de polarizare VV și VH. Rețeaua este antrenată pentru 10 epoci, cu dimensiunea lotului 10, rata de învățare 0,001 și funcția de pierdere a erorii pătratice medii (MSE) cu 90% din date ca set de antrenament. Mai târziu, rețeaua reantrenată este utilizată pentru a reconstrui datele IW cu canalul de polarizare VV și VH (similar cu datele de antrenament). Rezultatele acestui experiment sunt adnotate ca fiind reconstruit-Trained (RT). Pe baza experimentelor noastre, canalul de polarizare VH este mai bun pentru estimarea OSC. După reconstrucția datelor CV-SAR cu autoencoderul CV, metoda de estimare Doppler a corelației (CDE) este utilizată pentru a estima f_{DC} și a prelua OSC. Terenul este mascat folosind instrumentul SNAP pentru a nu căuta Doppler pe uscat. Cu toate acestea, rezoluția și limitele spațiale sunt consistente în toate cele trei experimente pentru a observa vizual variația semnăturilor estimate OSC.

f_{DC} și OSC estimate din datele SAR originale adnotate cu O , datele SAR reconstruite din rețeaua [12] adnotate cu R și datele SAR reconstruite din rețeaua reantrenată adnotată cu RT sunt prezentate în Fig. 3.3. Comparând f_{DC} și OSC estimate din rețeaua [12] (Fig.3.3 (b) și (e)) cu datele SAR originale (Fig. 3.3 (a) și (d)), este vizibilă o diferență

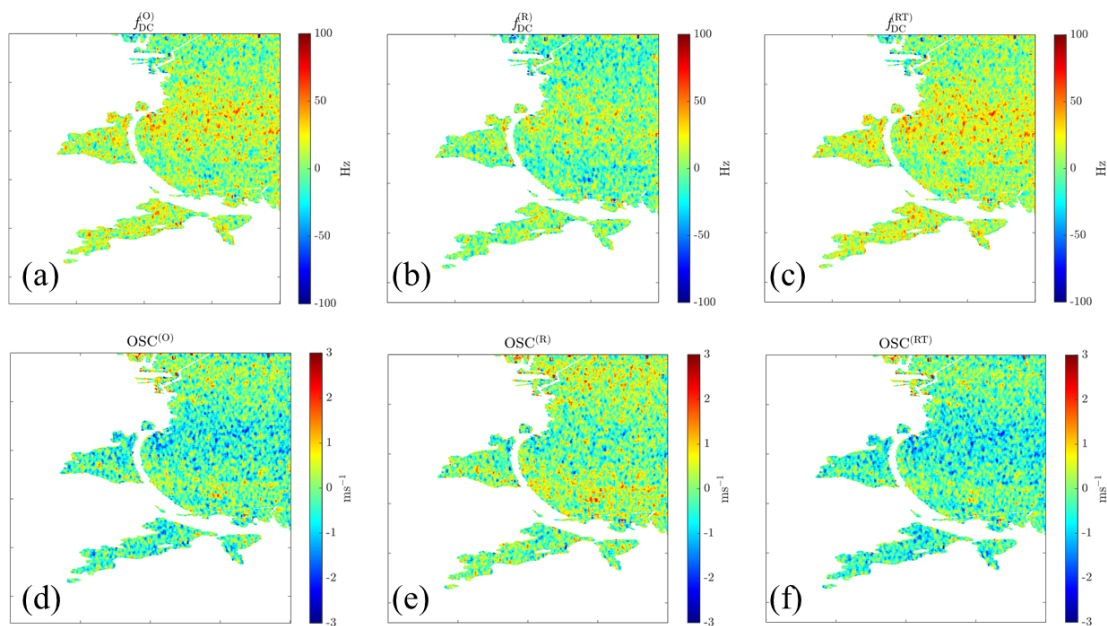


Figura 3.3 (a), (b) și (c) au calculat f_{DC} pe zona de studiu și (d), (e) și (f) OSC estimat din originalul (O), reconstruit cu rețeaua [12] (R) și, respectiv, Reconstruit cu imaginile SAR din rețeaua reantrenată (RT).

notabilă în parametrul estimat de circulație oceanică. Datele CV SAR reconstruite, în ciuda faptului că au un model OSC similar, tind să estimeze valori mai mici pentru Doppler-ul actual și mai slab. Cu toate acestea, atunci când autoencoderul CV este reantrenat folosind datele SAR SLC-IW TOPS, f_{DC} estimate și OSC (Fig.3.3 (c) și (f)) arată o asemănare foarte mare cu rezultate din datele SAR originale. Asemănarea mare dintre estimarea parametrului de circulație oceanică din original și datele SAR reconstruite demonstrează că autoencoderul CV a păstrat modelul de date SAR chiar și fără reantrenare (experiment adnotat cu R). Evident, reantrenarea rețelei cu un tip similar de date (canale de polarizare IW și VV-VH) a îmbunătățit semnificativ performanța autoencoderului CV.

În acest studiu, este evaluată competența auto-encoderilor CV de a păstra proprietățile originale și modelul fizic al datelor CV-SAR și modul în care acesta influențează regăsirea parametrului fizic din aceste date. În acest scop, un autoencoder CV este antrenat pentru a reconstrui imaginile CV-SAR și parametrii f_{DC} și OSC extrași din datele SAR originale și reconstruite. Compararea dintre parametrii obținuți a demonstrat că autoencoderul CV a învățat cu succes modelul de date SAR și a păstrat într-o bună măsură informațiile originale ale centrului Doppler.

Capitolul 4

Date polarimetrice SAR pentru detectarea țintei bazate pe CFAR

Extracția litoralului, monitorizarea țintei/traficului în timp marin și delimitarea stratului de gheață prin exploatarea imaginilor optice sunt provocatoare în condiții meteorologice nefavorabile. De fapt, colectarea datelor *in-situ* este costisitoare și nu întotdeauna posibilă. În consecință, abordările CFAR (Constante False Alarm Rate) au o gamă versatilă pentru identificarea țintei bazată pe SAR. Matricea pentru delimitarea țintei (adică f_{DC} , σ^0 , and ρ) suferă un proces de mediere a ansamblului, în urma căruia tehnica CFAR este aplicată la determinarea valorii prag esențială pentru a face distincția între entitățile țintă și cele ne-țintă. Ulterior, un bloc de procesare a imaginii este folosit pentru a cuantifica cu precizie limitele sau marginile țăintelor dorite.

4.1 Extracția coastei folosind imagini Doppler centroide

Este propusă o nouă metodă de extracție a litoralului bazată pe variația dinamică clasică a coastei, cum ar fi centroidul Doppler (f_{DC}), deoarece linia de coastă este statică și are Doppler zero în raport cu starea dinamică a mării. Parametrul Doppler este folosit pentru a delimita liniile de coastă atunci când nu sunt disponibile date *in-situ* și nici imagini optice fără nor. Rezultatele tehnicii noi bazate pe Doppler ne permit să investigăm impactul hazardelor naturale asupra degradării coastei [6].

Impresia generală este că linia de coastă este statică în raport cu marea și, teoretic, asigură rata doppler zero. Astfel, naturile dinamice și statice disting cu ușurință apa și pământul. f_{DC} este estimat prin metoda noastră CDE dată în capitolul 2. Folosind fereastra glisantă 'w' cu dimensiunea 9×9 calculată local f_{DC} . Următorul pas este extragerea liniei de coastă, sporind în același timp separarea pământului și a apei. f_{DC} estimat este setat la valorile sale absolute, de dragul simplității, pentru a utiliza o singură valoare de prag $|f_{DC}^{[VH]}| = |f_{DC}(\eta, \tau)|$. Metoda CFAR este aplicată peste ROI care intenționează să ofere o imagine heterologică de la $f_{DC}^{[VH]}$ la 2σ pentru a




Figura 4.1 Pentru un set de date dat, r_c , σ_{pq} , σ_{qq} și f_{DC} , urmați îndeaproape Gaussian, Gamma inversă, Gamma și Burr distribuțiile respectiv.




Figura 4.2 Rândul unu reprezintă hărțile de coastă extrase ale Sentinel-2 (S2), $|f_{DC}^{VH}|$, r_c , σ_{pq} și σ_{qq} cu imaginile respective asupra rentabilității investiției legate de scena colectată. Harta coastei S2 (verde) este suprapusă cu $|f_{DC}^{VH}|$ (magnetic), r_c (roșu), σ_{pq} (albastru), și σ_{qq} (negru) așa cum se arată în rândul 2.

discrimina clar între uscat și mare. Pentru comparație, extragerea liniei de coastă se realizează utilizând SOA matricele de corelație incluzând dual-pol, co-pol și cross-pol, ($r_c = \langle |S_{VH}| \cdot |S_{VV}| \rangle$, $\sigma_{pq} = \langle |S_{VH}|^2 \rangle$, $\sigma_{qq} = \langle |S_{VV}|^2 \rangle$). Relațiile date urmează distribuțiile inverse Gamma, Gamma, Burr și Gaussian pentru a obține pragul folosind metoda CFAR așa cum se arată în Fig 4.1.[13].

$|f_{DC}|$ estimat este influențat de undele bragg dinamice și variațiile la scară medie. Distribuția empirică pentru f_{DC} peste regiunea apei netede este suprapusă cu distribuția Gaussiană teoretică. Cu toate acestea, pentru diferitele matrice de estimare și condițiile stării mării, valoarea pragului ' T_{CFAR} ' și distribuția variază ambele de la date la date. Există alarme false după aplicarea „ T_{CFAR} ”, de fapt, câțiva pixeli din zona oceanului au Doppler zero, așa că pentru a elimina aceste alarme false este nevoie de o abordare anterioară σ_{pq} pentru a le filtra zero pixeli Doppler peste apă. Acest criteriu a fost ales pentru a izola variația cauzată de dinamica mării și a extrage efectiv linia de coastă.

Hărțile de coastă detectate pe baza experimentelor de mai sus sunt prezentate în Fig. 4.2. Hărțile de coastă obținute din $|f_{DC}^{VH}|$, r_c și σ_{pq} , având variații minime cu

Tabela 4.1 Analiza cantitativă bazată pe acordul general (OA)

OA \ Comparație	S2 vs f_{DC}^{VH}	S2 vs r_c	S2 vs σ_{pq}	S2 vs σ_{qq}
Teren	0.3414	0.3418	0.3447	0.2524
Apă	0.5799	0.5792	0.5693	0.6294
Teren + Apă	0.9214	0.9210	0.9140	0.8818

hărți similare, în afară de σ_{qq} sunt eronate din cauza impactului unghiului de incidență mai mic. Hărțile de coastă extrase pentru $|f_{DC}^{VH}|$ și σ_{pq} propuse ale metodei SOA în culorile roșu și, respectiv, albastru, sunt suprapuse pentru a cuantifica acuratețea dintre două metode și se poate observa un bun acord. Imaginea Sentinel-2 (S2) detectează cu acuratețe linia de coastă și ținta de apă mică, harta coastei este evidențiată cu culoarea verde dată în Fig. 4.2 rândul unu. Pentru a cuantifica performanța, acordul global (OA) este calculat între S2 și atât metodele propuse, cât și SOA, așa cum este prezentat în Tabelul 4.1., [14]. Numărul total de pixeli clasificați ca mare, pământ și atât mare + pământ. Valorile experimentale ale clasificării pixelilor pentru uscat și mare împreună, arată că $|f_{DC}^{VH}|$ funcționează robust ca r_c , σ_{pq} , totuși, σ_{pq} este sub influența unghiului de incidență.

Sunt descrise impactul parametrilor de circulație oceanică asupra structurii litoralului. Seturile de date sunt colectate la diferite intervale pentru a prezice cu exactitate impactul parametrilor Doppler asupra liniilor de coastă. Pe liniile de coastă se observă variații ale structurilor fizice. Linia de coastă de la două date diferite arată că linia de coastă se confruntă cu tăieturi și starea mării este ușor agitată, ceea ce este un impact al parametrilor Doppler ridicat.

4.2 Descompunerea SA pentru detectarea navei

Contrastul dintre țintele navei și marea înconjurătoare poate fi îmbunătățit în imaginile SAR prin împărțirea lățimii de bandă în sub-apertura (SA) pentru a obține o rezoluție azimut ridicată. Această secțiune descrie descompunerea SA pentru detectarea navelor în mișcare. Metoda de mediere a SA-urilor cu dublu pol propusă utilizează abordarea CFAR urmată de distribuția statistică Gamma (Γ) pentru a determina valoarea pragului pentru distingerea navelor și a apei. În plus, parametrul de viteză al navei în direcția azimutală este estimat pe baza deplasării SA.

Pentru a obține o rezoluție înaltă a azimutului, SA înlocuiește deschiderea reală a antenei prin procesarea semnalului de-a lungul dimensiunii azimutului. Conceptul de SD generează imagini SA în mod sintetic, care optimizează și mai mult detectarea obiectelor [15]. SA produse sunt mediate pentru ambele polarizări pentru detectarea navei. Modulul corelației nenormalizate dintre canalele co-pol și cross-pol este definit de matricea de

corelație $r = \langle |S'_{\text{VH}}| \cdot |S'_{\text{VV}}| \rangle$, dat fiind că; $S'_{\text{VH}} = \frac{1}{N} \sum_i^N S_{\text{VH}}^{(i)}$, and $S'_{\text{VV}} = \frac{1}{N} \sum_i^N S_{\text{VV}}^{(i)}$. Unde S' reprezintă media SA pentru fiecare polarizare, N este numărul de SA.

Cadrul algoritmului de detectare automată a navelor utilizează abordarea CFAR, distribuția empirică a apei netede este suprapusă cu distribuția teoretică. Gamma generalizată aproximează bine distribuția statistică empirică a r . Scopul dezvoltării detectorilor automati de prag este de a menține constantă probabilitatea unei alarme false. Prag, $T_{\text{CFAR}} = \Gamma(1 - P_{\text{fa}}, \frac{\mu^2}{\sigma^2}, \frac{\mu}{\sigma^2})$, unde μ și σ sunt parametrul de scalare nenegativ și, respectiv, abaterea standard. Probabilitatea unei alarme false ($P_{\text{fa}} = 10^{-6}$) pentru estimarea T_{CFAR} este dată ca: $P_{\text{fa}} = \int_0^{T_{\text{CFAR}}} \text{PDF}(r^{(w)}) dr$, unde $r^{(w)}$ reprezintă dezordinea apei. Odată ce imaginea logică este obținută, ținta navei pixel cu pixel este extrasă folosind algoritmul de detectare a marginilor Sobel.

Viteza navei se obține cu Metoda deplasării SA, care utilizează valoarea de corelație de vârf și deplasarea pixelilor, dată ca; $V_S = \sum_{i=1}^N \frac{r_i \Delta_x^i S_{\Delta z_i}}{T_{\text{SA}}} / \sum_{i=1}^N r_i$, unde r_i este corelația încrucișată a două SA, T_{SA} este timpul de deschidere sintetică și Δ_x^i este deplasarea în azimut unde $S_{\Delta z_i}$ prezintă distanța dintre pixeli. Deschiderea SAR, împărțită în trei SA, este reconstruită folosind trei ferestre Hamming $h(w)$; prin urmare, SD produce mai multe SA din SAR original. SA sunt mediate în polarizările lor respective și o metrică de corelație cu dublu poli ' r ' este adaptată pentru detectarea navei, așa cum se arată în Fig. 4.3(a). Distribuția empirică a imaginii r este suprapusă cu distribuția teoretică gamma (Γ), așa cum se arată în Fig. 4.3(b). Apoi, valoarea obținută a lui T_{CFAR} a discriminat între mare și navă pentru a fi afișată sub forma unei imagini binare, așa cum se arată în Fig. 4.3(c). În cele din urmă, detectorul de margine Sobel oferă limite pentru a identifica navele și limitele apei, iar prin suprapunerea unei imagini de amplitudine și a rezultatelor extracției generale, navele detectate sunt prezentate cu galben în Fig. 4.3(d).

Valorile proprii ($\lambda = \sum_{i=1}^2 p_i \lambda_i$) furnizează dimensiunea totală sau informațiile despre acoperișul țintei. Prin urmare, dimensiunea navei obținută prin metoda de mediere a SA propusă este comparată cu λ pentru a estima acuratețea ambelor metode, așa cum se arată în Fig. 4.3(e). Dimensiunile navei obținute din valoarea Eigen (în albastru) sunt comparate cu abordarea propusă (în roșu). Ambele tehnici oferă nave de dimensiuni aproximative fiabile, cu o precizie de 90%. Deplasarea în SA nu afectează dimensiunile reale, dar alegerea dimensiunii ferestrei o face.




Figura 4.3 (a) imagine r , (b) distribuția empirică și teoretică a regiunii apei, (c) imagine binară pentru a discrimina între navă și apă, (d) rezultatul detectării navei prin metoda generală și (e) compararea navei dimensiunea obtinuta de λ si r -imagine.

4.3 Delimitarea stratului de gheață folosind metoda CFAR

Imaginile prin satelit teledetecționate joacă un rol important pentru monitorizarea ghețarilor și a straturilor de gheață care sunt greu de observat de la sol din cauza mărimii lor uriașe și a condițiilor severe de mediu. SAR este o sursă de încredere pentru monitorizarea gheții datorită duratelor sale frecvente de revizie. Prin urmare, această secțiune se concentrează pe o metodă nesupravegheată pentru extragerea acoperirii de gheață prin exploatarea datelor SAR detectate la sol Sentinel-1 cu două poli, peste Insula Devon, care este înconjurată de oceane. Un detector CFAR a fost adaptat cu distribuția teoretică "Burr" pentru a deriva valoarea pragului CFAR pentru a delimita stratul de gheață. Precizia de extracție a stratului de gheață a matricei propuse și a matricei SOA cu un singur pol au fost comparate meticolos cu stratul de gheață detectat de datele S2.

Preprocesarea datelor a fost exclusă pentru a determina eficacitatea metodei. Datele SAR dublu-pol cu o metrică de corelație (ρ) sunt utilizate pentru detectarea stratului de gheață, după cum urmează: $\rho = \langle S_{HV} \cdot S_{HH} \rangle$. Zgomotul petele poate fi redus prin filtrare spațială. Prin urmare, folosind o fereastră glisantă de dimensiunea 15×15 pentru a calcula local media ansamblului informațiilor spațiale, unde $\langle \cdot \rangle$ este filtrul de medie spațială. Pasul următor este de a căuta distribuția empirică în regiunea de gheață pentru a se alinia cu distribuția teoretică. Pragul CFAR este calculat din zona de petec de gheață ca PDF de probabilitate a distribuției Burr (β), după cum urmează: $T_{CFAR} = \beta [P_{fa}^{-\frac{1}{\alpha}} - 1]^{\frac{1}{\mu}}$, unde μ și α sunt parametri de formă nenegativi, iar β este un parametru de scară nenegativ. Probabilitatea unei alarme false (P_{fa}) pentru estimarea T_{CFAR} bazată pe distribuția Burr este dată ca; $P_{fa} = \int_{T_{CFAR}}^{\infty} \frac{\alpha \beta^{\alpha} \mu \rho_i^{\mu-1}}{(\beta + \rho_i^{\mu})^{\alpha+1}} d\rho$, $\rho > 0$, unde ρ_i reprezintă dezordinea de gheață. Prin urmare, valoarea T_{CFAR} discriminează corect țintele de gheață și cele fără gheață. Odată ce imaginea logică I_L este obținută, gheața vizată pixel cu pixel este extrasă folosind algoritmul de detectare a marginilor Canny. Rezultatele sunt comparate cu matrice de corelație co- și încrucișată, și anume $\sigma_{HH} = \langle S_{HH} \cdot S_{HH} \rangle$ și $\sigma_{HV} = \langle S_{HV} \cdot S_{HV} \rangle$ respectiv [16]. Când se compară rezultatele cu datele *in situ* și două tipuri de date au rezoluții diferite, pentru a facilita o comparație semnificativă, a fost dezvoltată o metodă de co-înregistrare în setul de instrumente SNAP pentru a alinia ambele produse de date la aceeași rezoluție.

Aplicația acestei cercetări este estimarea retragerii gheții. Pentru a estima viteza sau retragerea stratului de gheață între două date diferite, sunt selectate două puncte. În primul rând, este selectat punctul primei linii de gheață care este cel mai îndepărtat de a doua linie, iar distanța dintre aceste două puncte este măsurată în metri. În al doilea rând, este selectat punctul celei de-a doua linii de gheață cel mai apropiat de prima linie, iar distanța dintre aceste două puncte este măsurată în metri. În cele din urmă, calculați retragerea împărțind deplasarea euclidiană la intervalul de timp (z_i). Viteza de retragere V_R este dată de: $V_R = \frac{\|X_C - X_F\|}{T_S} = \frac{\sqrt{(X_{C1} - X_{C2})^2 + (X_{F1} - X_{F2})^2}}{T_S}$, unde X_C , X_F și T_S sunt cele mai apropiate puncte de pe linia de gheață 1, cele mai îndepărtate puncte de

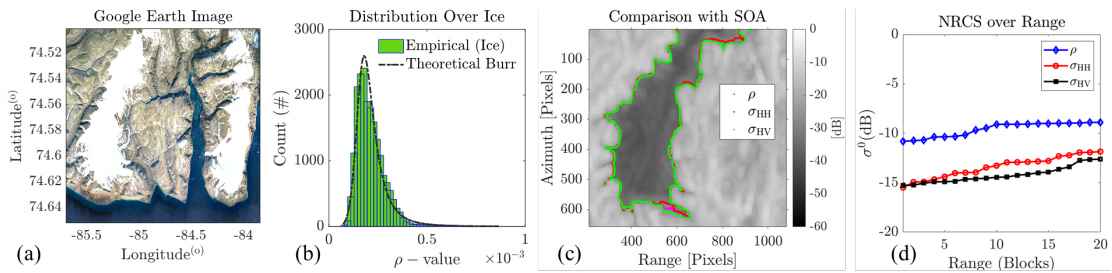


Figura 4.4 (a) Imagine Google Earth a acoperirii de gheață date. (b) Distribuția empirică a gheții s-a suprapus cu distribuția teoretică Burr. (c) Acoperirea de gheață detectată de ρ , σ_{HH} , and σ_{HV} și (d) NRCS ale matricelor date, unde matricea propusă a arătat o îmbunătățire NRCS pentru o mai bună extracție a stratului de gheață.




Figura 4.5 Petic omogen de pixeli de gheață și teren pentru a cuantifica acuratețea fiecărei matrice (b) $\rho - \sigma_{HV}$ (c) $\rho - \sigma_{HH}$ și (d) $\rho - S2$.

pe linia de gheață 2 și, respectiv, intervalul de timp pe zi. Metodologia este adaptată pentru a gestiona caracteristicile unice ale dezordinei prezente în corpurile infestate cu gheață sau cu gheață. Distribuțiile empirice și teoretice au fost derivate dintr-o regiune de gheață, oferind o perspectivă asupra proprietăților statistice ale datelor. Regiunea de gheață pavează distribuția bavurilor; prin urmare, CFAR pentru această distribuție a fost implementat. Stratul de gheață a fost delimitat cu mare precizie folosind metoda propusă cu datele SAR S1, așa cum se arată în rândul-1 din Fig. 4.4. În contrast, Fig 4.4 (a). Imaginea Google Earth arată o foaie de gheață obținută peste tot Devon Islanda. Figura 4.4 (b) prezintă distribuția empirică urmată de distribuția teoretică a Burr pe regiunea de gheață la extrage capacul de gheață. Figura 4.4 (c) prezintă stratul de gheață extras folosind ρ , σ_{HH} , and σ_{HV} , marginile de gheață sunt cuantificate de detectorul de margine Canny și imaginea geocodificată suprapusă la ilustrează procesul general. Și graficul NRCS pentru fiecare matrice unde ρ arată NRCS îmbunătățit așa cum este reprezentat în figura 4.4 (d).

Un petic de pixeli de gheață (alb) și teren (negri) din Fig. 4.5(a) cuantifică acuratețea matricei. În (b), diferențele de linii de gheață-teren sunt afișate pentru ρ și σ_{HV} , în timp ce (c) le afișează pentru ρ și σ_{HH} . Această variație apare din diferite matrice. Cu toate acestea, (d) evidențiază o deplasare distinctă S1 (magenta) la S2 (roșu), legată de diferența de timp a setului de date, oferind o oportunitate de estimare a vitezei de retragere.

Capitolul 5

Reconstrucția imaginii SAR invers și extragerea caracteristicilor rare

Odată cu progresul tehnologiei radar, imagistica a devenit o funcție importantă a radarelor. Tehnologia radarului cu deschidere sintetică inversă (ISAR) oferă imagini ale obiectelor care sunt rotite în raport cu radarul. Acest capitol cuprinde trei aplicații distincte: imagistica ISAR, extragerea caracteristicilor rare și imagistica CS-ISAR [1, 3].

5.1 Evaluarea imagistică ISAR

Un model monostatic de ISAR a fost implementat pentru a colecta date de retrodifuzare radar în banda de undă milimetrică (mm) (67–110 GHz) folosind ținte cu forme circulare, dreptunghiulare și non-canonice. Experimentele ISAR au fost efectuate pentru a evalua performanța imagistică a celor trei metode, inclusiv numărul de undă ($\omega - k$), compensarea frontului de undă sferic și proiecția înapoi. Pentru a evalua metodele, am calculat funcția de împrăștiere a punctului (PSF) pentru răspunsul la impuls al firului cu undă mm. Există un compromis: domeniul $\omega - k$ pierde rezoluția în comparație cu metodele SWFC și BP, dar poate obține o imagine satisfăcătoare la un cost de calcul mai mic [17].

Metoda modificată $\omega - k$ este eficientă din punct de vedere computațional deoarece utilizează o funcție încorporată pentru interpolarea 2D și o transformată Fourier rapidă (FFT) inversă [18]. Procesul de interpolare îndepărtează migrarea celulelor de gamă (RCM) și cuplarea gamă-azimut.

$$\text{ISAR}_{\omega-k} = \sum_i^N \text{interp2}([K_{X,Y}], S_h(\omega, k), [K_r, \theta]) \quad (5.1)$$

unde K_X și K_Y sunt dimensiuni ale grilei, S_h sunt date ISAR preprocesate și K_r, θ este funcția de transformare polară.

În metoda SWFC, datele din toate unghiurile plăcii rotative sunt adunate pentru a compensa fronturile de undă. SWFC este dat ca; $S_\psi = \sqrt{(R\cos\phi\cos\theta + X)^2 + (R\cos\phi\sin\theta + Y)^2}$, unde ϕ este unghiul de incidență dintre radar și țintă 'R' este distanța de la țintă la radar. X, și Y sunt elemente ale unei grile 2D predefinite. Imaginea ISAR complexă finală este:

$$\text{ISAR}_{\text{SWFC}} = \int_0^\infty \int_{-\pi}^{+\pi} S_h(f, \theta) \exp(2jk \times S_\psi) df d\theta \quad (5.2)$$

unde $k = \frac{2\pi f_{\text{vec}}}{c}$ și f_{vec} este vectorul de frecvență pentru un interval dat de lățime de bandă și f denotă mostre de date.

Idea de bază a abordării BP este de a scădea distanța dintre radar și țintă și de a o compensa în termeni de fază de acumulare coerentă, evitând migrarea distanței: $S(x, y) = \int_y \int_x f(x, y) \exp(-j2kR(x\sin\theta - y\cos\theta)) dx dy$. Unde, $f(x, y)$ este funcția datelor brute comprimate în interval.

Având în vedere că, $S_\zeta = \sqrt{(R\cos\phi\cos\theta - X)^2 + (R\cos\phi\sin\theta - Y)^2}$ este compensarea distanței în termeni de fază dintre radar și grila imaginii. Imaginea ISAR proiectată în spate este dată astfel:

$$\text{ISAR}_{\text{BP}} = \int_x \text{Interp1} \left([K_{X,Y}], f_h(x, y), S_\zeta \right) * \exp\left(-j\frac{4\pi f_{\text{vec}}}{c} \times S_\zeta\right) dx \quad (5.3)$$

Capacitățile metodelor ISAR sunt exprimate în termeni de "Point Spread Function" (PSF), utilizând răspunsul la impuls al unui fir cu undă mm cuplat între radar și unitatea




Figura 5.1 Rezultatele imagistice ale țintelor cilindrice, dreptunghiulare și non-canonice. (a) prezintă rezultatele obținute prin metoda $\omega - k$, (b) prezintă rezultatele obținute prin metoda SWFC și (c) validează rezultatele obținute prin metoda BP. (d) Imaginile PSF de -25 dB pentru IR al firului mm pentru domeniul $\omega - k$, SWFC și metodele BP.

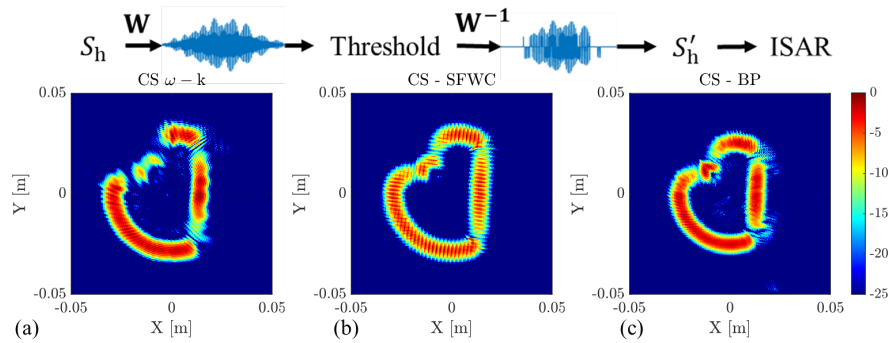


Figura 5.2 ISAR images obtained with 70% of the data (compressed or sparse at 30%) after a thresholded 2D-DWD. (a) $\omega - k$, (b) SWFC, and (c) BP.

de procesare. Cu toate acestea, PSF este imaginea reconstruită a unui singur dispensor (fir) situat la originea sistemului de coordonate. Aceasta compară capacitățile metodelor implementate pentru a obține rezoluții spațiale submilimetrice. Mai mult, a fost evaluată capacitatea metodelor ISAR menționate mai sus de a gestiona date compresibile. Descompunerea wavelet discretă 2D (2D-DWD) este aplicată pentru a face datele compresibile atât în dimensiunea intervalului, cât și a intervalului transversal prin reducerea dimensionalității.

Rezultatele imagistice pentru metoda $\omega - k$ sunt prezentate în coloana (a) din Fig. 5.1. Rezultatele imagistice sunt în strânsă corespondență cu adevărul de bază în ceea ce privește dimensiunea și forma. Metoda $\omega - k$ are o reconstrucție eficientă a imaginii ISAR care rămâne independentă de distanța țintă-radar. În special, în comparație cu algoritmi tradiționali SWFC și BP, așa cum se arată în coloanele (b) și (c) din Fig. 5.1, numărul de puncte reconstruite incorect a fost redus. Imaginile PSF ale metodelor SWFC și BP au concentrații perfecte în centru, așa cum se arată în Fig. 5.1 coloana (d). Imaginile au fost focalizate în raport cu centru, iar lobi laterali au fost reduși rapid.

În schimb, imaginea PSF a domeniului $\omega - k$ arată valori relativ mari ale lobilor laterali. Cu toate acestea, imagistica cu unde milimetrice, cu un cost de calcul mai mic și o rezoluție largă, are un potențial mare pentru detectarea obiectelor în diferite domenii. Fig. 5.2 prezintă rezultatele analizei de performanță a imaginii ISAR pentru o țintă complexă non-canonice folosind date comprimate sau rare de 30% obținute după 2D-DWD. Acest lucru arată scăderi $\omega - k$ în imagistica din cauza atenuării intervalelor de procesare coerente (IPC) utile în comparație cu SFWC și BP. Cu toate acestea, prin aplicarea oricărei tehnici CS, rezoluția poate fi restabilită, rezultând o imagine mai bine focalizată, super-rezolvată în comparație cu aceasta.

5.2 Estimarea proprietăților de împrăștiere a imaginilor ISAR

Tehnica de descompunere dual-pol permite regăsirea precisă a mecanismelor de împrăștiere ($H-\alpha$), permițând diverse aplicații. A fost prezentat un nou studiu de caz al imaginilor

2D ISAR pentru estimarea proprietăților de împrăștiere. Au fost folosiți descriptorii de vectori proprii pentru a identifica mecanismul de împrăștiere bazat pe planul $H-\alpha$ Lee și Pottier. Acest mecanism a fost prezentat pentru prima dată în configurația ISAR. Având în vedere că descompunerea îmbunătățește caracterizarea țintei pentru studierea mecanismelor de împrăștiere, aplicarea indicelui de vegetație radar (RVI) demonstrează modul în care imaginile ISAR cu polarizare dublă pot fi utilizate pentru identificarea vegetației [19].

Măsurătorile au fost efectuate cu ajutorul radarului experimental COBRA pe placa turnantă de pe terenul Fraunhofer cu o configurație cvasi-monostatică care pavajează canalele VV și VH. Canalele recepționate se află la o anumită distanță unghiulară de ținte și au o anumită întârziere care este compensată de $\Delta\tau = \frac{c \times R}{4\pi f_c}$, unde R și f_c sunt distanța radar la țintă și frecvența purtătoare. Imaginile 2D ISAR sunt obținute prin utilizarea metodei SWFC, așa cum sa discutat în Secțiunea 5.1. Toate unghiurile plăcii rotative au fost adunate pentru a reconstrui o imagine ISAR 2D. Pentru ambele imagini ISAR focalizate pe polarizare sunt S_{VV} și S_{VH} .

Descompunerea coerentă a dual-polului oferă valori proprii și vectori proprii ai matricei de coerență [20]. Vectorul de împrăștiere pentru datele ISAR cu polarizare duală este reprezentat ca $\mathbf{k}_{Dp} = [S_{VV} \ S_{VH}]^T$. Matricea de coerență 2×2 ne permite să obținem imaginile entropiei (H), alfa (α) și span (λ) pentru arbori. Descompunerea $H - \alpha$ poate fi exprimată prin exploatarea valorilor proprii nenegative ($\lambda_i, i = 1, 2$) și a vectorilor proprii corespunzători, iar entropia este exprimată ca:

$$H = - \sum_{i=1}^2 (p_i) \log_2(p_i), \text{ în care } , p_i = \frac{\lambda_i}{\lambda_1 + \lambda_2} \quad (5.4)$$

unde unghiul mediu de împrăștiere (α) și intervalul sau mărimea medie a mecanismului (λ) sunt date astfel:

$$\alpha = \sum_{i=1}^2 p_i \alpha_i, \text{ and } \lambda = \sum_{i=1}^2 p_i \lambda_i \quad (5.5)$$

în timp ce α și λ furnizează natura împrăștierii și, respectiv, intervalul sau dimensiunea țintei. Împrăștierea radarului este foarte influențată de tipul vegetației, structură, umiditate și fenologie; astfel se definește RVI, care ia în considerare acești parametri și este foarte util în monitorizarea vegetației la scară largă.

$$RVI = \left(\frac{\langle |S_{VH}| \rangle}{\langle |S_{VV} + S_{VH}| \rangle} \right)^{1/2} \left(\frac{4 \times \langle |S_{VH}| \rangle}{\langle |S_{VV} + S_{VH}| \rangle} \right) \quad (5.6)$$

RVI este o măsură aleatorie a împrăștierii care variază de la 0 la 1, dar este mai puțin sensibilă la geometria măsurătorilor radar. Pentru suprafețe netede, RVI este aproape de zero, crește pe măsură ce vegetația crește. Rezultatele RVI sunt comparate cu $DpRVI$ care se bazează pe doi parametri și îmbunătățește estimările. $DpRVI = (1 - m_{Dp} \cdot \beta)$, $0 \leq$

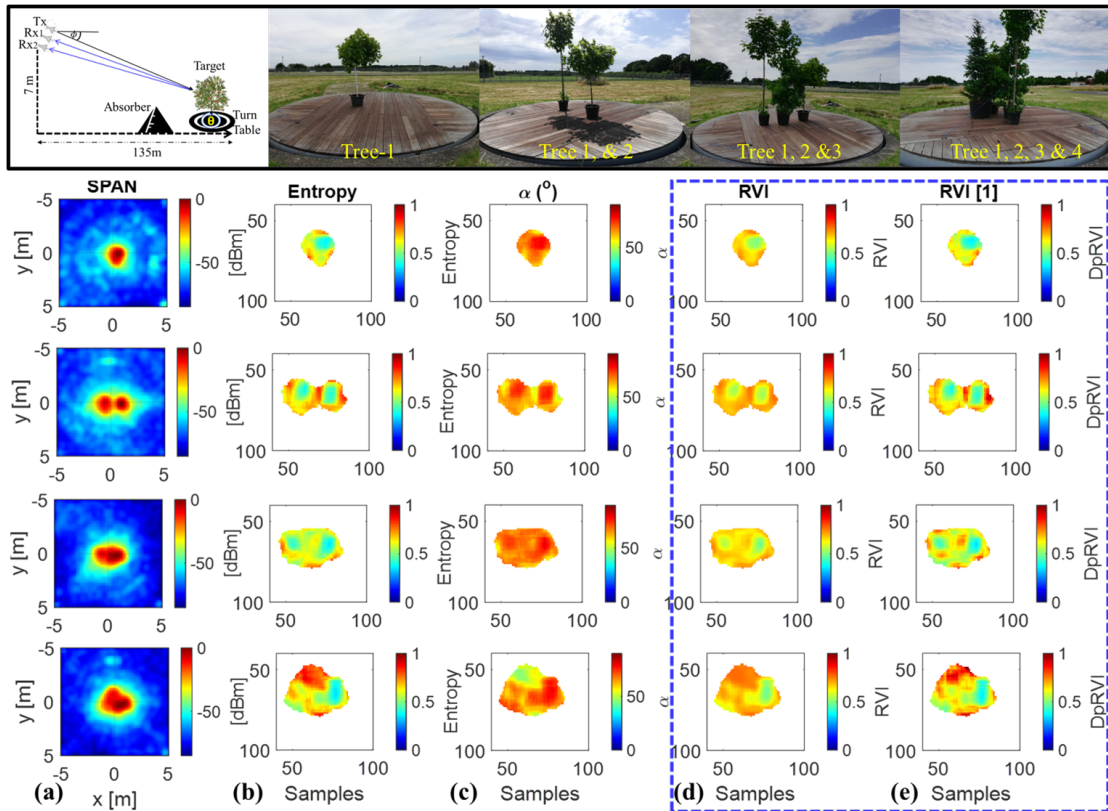


Figura 5.3 Rândul de sus este modelul geometric și țintele instalate pentru configurarea ISAR. (a) Imagini ISAR ale copacilor. (b) Entropia împrăștierii arborilor. (c) α reprezintă unghiul mediu de împrăștiere. (d) Semnături spațiale ale RVI bazate pe polarizare parțială. (e) Semnături spațiale ale RVI bazate pe gradul de polarizare.

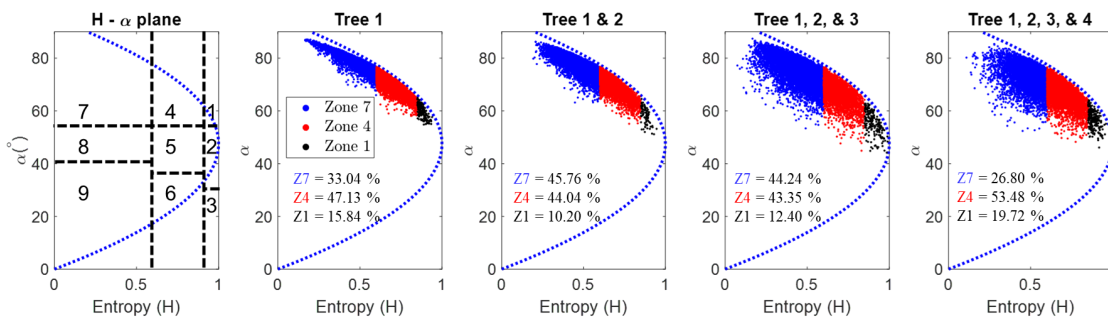


Figura 5.4 Descompunerea $H - \alpha$ arată că mecanismul de împrăștiere se încadrează în zonele 1, 4 și 7 pe baza metodei lui Lee și Pottier.

$m_{Dp} \leq 1$, unde β este spectrul de valori proprii de T_2 și m_{Dp} este gradul de polarizare.

Fig. 5.3 imaginea de sus demonstrează configurația de măsurare și placa turnantă în care sunt plasate țintele copacilor. Fig. 5.3 (a) arată mărimea medie λ a imaginilor ISAR 2D ale arborilor. În Fig. 5.3 (b), valorile mai mari de entropie indică o împrăștiere inversă de amplitudine foarte mică, unde zonele copacului arborilor prezintă vegetație rară. Prezența valorilor ' α ' (unghiul mediu) în zonele dense ale frunzelor, unde cele mai multe valori sunt mai mari de 45° , reprezintă împrăștierea de suprafață multiplă, așa cum se arată în Fig. 5.3 (c). Semnătura RVI a fost obținută folosind imagini ISAR

cu două poli, iar valoarea sa aleatorie a variat între 0 și 1, așa cum se arată în Fig. 5.3 (d) și 5.3 (e). RVI este estimat folosind un filtru boxcar de 5×5 prin două abordări, una bazându-se doar pe polarizări, iar cealaltă pe gradul de polarizare și, respectiv, pe spectrul propriu. Semnăturile spațiale au fost calitativ aceleași, ceea ce indică faptul că imaginile ISAR pot fi utilizate pentru estimarea RVI. Cu toate acestea, pe baza planului $H-\alpha$, împrăștierea pentru fiecare caz apar în zonele 1, 4 și 7, care corespund zonelor de împrăștiere multiplă a vegetației cu entropie mare, medie și, respectiv, joasă, ca prezentat în Fig. 5.4.

5.3 Estimarea CTF pentru Imagistica CS-ISAR

Comprimarea semnalului (CS) permite realizarea imaginilor cu mai puține date, presupunând existența rarității în anumite domenii. Am propus o metodă revoluționară de estimare grosieră-la-fine (CTF) care reconstruieste imagini cu suport semnal mai mic peste grile fine. Datorită stocării și utilizării explicite în cadrul reconstrucției rare, matricea de semnalizare (SM) necesită resurse, chiar și pentru dimensiuni mici ale problemei. Pentru a atenua această problemă, procedura CTF elimină un anumit număr de coloane din SM pe măsură ce reconstrucția progresează de la scală mai grosieră la cea mai fină ($X_{1/F} = 2^{2F}$). Procesul de reconstrucție implică restricționarea progresivă a suportului semnalului, eliminând astfel un număr specific de coloane din SM pe măsură ce algoritmul trece de la un factor la altul. Tehnica propusă nu necesită o lanț de preprocesare și introduce o soluție directă de reconstrucție care ia în considerare în mod strategic atât costul computațional, cât și rezoluția imaginii. Strategia CTF elimină numărul maxim de frecvențe nedorite în etapa fină, reconstruieste imaginea cu mai puține eșantioane și obține o rezoluție înaltă cu un zgomot neglijabil. Fie \mathbf{X} o reprezentare a scării grosiere. Dimensiunea scării $\mathbf{X}_{1/F} \in \mathbb{C}^{M \times M}$ crește printr-un factor de 2^{2F} , unde $F \in \{0.25, 0.5, 1\}$ este factorul de grosime (**Mai grosier, Grosier, Fin**). Fig. 5.5 prezintă schema pentru estimarea CTF limitată la regiunile fezabile de suport al semnalului. Mască la nivelul mai grosier (X_4) a fost obținută prin identificarea suportului de semnal, care a fost apoi transformat într-o mască inițială pentru următorul nivel grosier (X_2), iar doar suporturile de semnal fezabile au fost păstrate la un nivel fin (X_1). Astfel, etapa fină utilizează câteva mostre din vectorul imagine \mathbf{S} și forțează regiunile dezordine să aibă valori zero. Imaginea reconstruită în stadiul fin a atins o rezoluție mai mare decât lățimea de bandă exploataată, deoarece existau goluri de frecvență.

Rezultatele imagistice pentru datele in situ (Yak-42) sunt prezentate în Fig. 5.6, utilizând grile de dimensiuni 64×64 , 128×128 și 256×256 . Fig. 5.6(a) prezintă imaginile reconstruite obținute folosind metoda 2D FFT fără nicio compensare a mișcării; totuși, necesită cardinalitate deplină. Fig. 5.6(b) prezintă imagini reconstruite prin CS-ISAR, utilizând un SM de secvențe Doppler discrete, deși cu cerințe de calcul mari pentru grila completă. Pentru a rezolva acest lucru, am aplicat tehnica CTF propusă, conducând

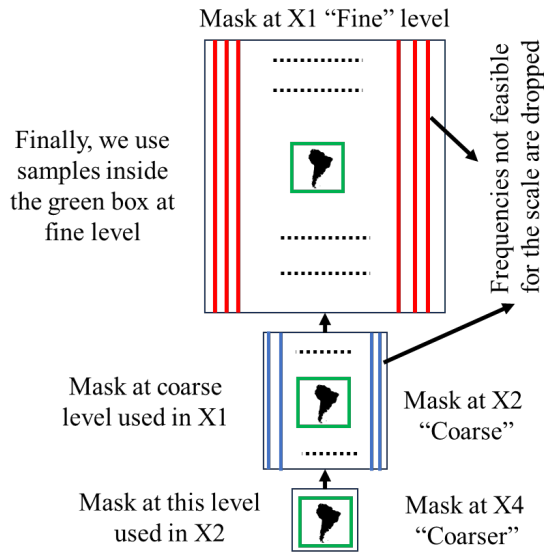


Figure 5.5 CTF estimation flow graph. Selection of the target mask from the coarser (bottom) to coarse (middle) and fine (top) stages. This allow to remove maximum number of unwanted samples at X1.




Figure 5.6 Imaging results for “Yak-42” aircraft. (a) Image focusing using conventional 2D FFT from coarse-to-fine level (b) CS-ISAR imaging using a dictionary of discrete Doppler sequences (c) CTF CS-ISAR imaging using the least squares (LS) method; (d) CTF CS-ISAR imaging using OMP for reconstruction.

la reconstrucția imaginii folosind metodele LS și OMP, așa cum se arată în Fig. 5.6 (c-d). Pentru abordarea LS în stadiul fin, ca urmare a aplicării măștii, am utilizat 4340 (în ciuda a 65536) cardinalități din vectorul de imagine, în timp ce abordarea lacomă

OMP a folosit 2048 cardinalități pentru a obține reconstrucția imaginii de înaltă rezoluție. Am evaluat eficiența algoritmului greedy OMP în gestionarea reconstrucției imaginii la fiecare scară.

În concluzie, este propusă o metodă de estimare CTF multi-scale care propagă o mască care restricționează suportul țintei pe scară, ceea ce permite restrângerea domeniului țintă inițial atunci când se estimează imaginea ISAR și masca de ieșire la scara următoare. Această tehnică reduce supraîncărcarea memoriei pentru utilizarea în timp real în cazurile în care mostrele de date sunt limitate. Această avansare către costuri de calcul scăzute și cerințe mai mici de memorie ne aduce mai aproape de aplicațiile practice.

Capitolul 6

Concluzie

6.1 Concluzie

Această teză abordează în mod detaliat mai multe aspecte ale prelucrării semnalelor și analizei spectrale a datelor SAR și ISAR pentru imagistică, detectarea țintelor și estimarea parametrilor fizici. Acestea includ o comparație a trei abordări de stare a artei pentru f_{DC} , fluxul de prelucrare propus similar cu modul stripmap pentru SAR TOPS și extinderea fluxului de lucru TOPS pentru a încorpora un model de învățare profundă pentru conservarea parametrilor Doppler în rețelele CV. Motivul principal în dezvoltarea sau modificarea acestor algoritmi a fost de a obține extragerea de caracteristici și imagine cu costuri computaționale minime. Un avans semnificativ este realizat în estimarea Doppler prin calcul paralel, care nu numai că rezolvă constrângerile de memorie, ci se dovedește benefic și pentru aplicațiile practice și la bord. În domeniul imagisticii ISAR, calculul poate fi costisitor datorită integralelor. Pentru a rezolva această problemă, s-a dovedit a fi utilă imagistica prin interpolare 2D. Această abordare s-a dovedit deosebit de utilă pentru grile mari sau pentru imagistica scenei țintei, deoarece a redus semnificativ costurile computaționale. Acest avans deschide posibilități pentru adaptarea tehnologiei la punctele de control de securitate pentru detectarea obiectelor ascunse. În cele din urmă, se propune o estimare de la gros la subțire pentru Imagistica cu Înaltă Rezoluție a Ariei Rare. Această abordare ia în considerare eficient atât constrângerile de memorie, cât și rezoluția imaginii, ducând la avansuri semnificative în acest domeniu.

6.2 Muncă viitoare

Viitoarele linii de cercetare constau în optimizarea soluțiilor dezvoltate pentru configurațiile SAR și ISAR. În ceea ce privește SAR, posibila activitate viitoare în acest domeniu este testarea tehnicii propuse cu seturi de date de la doi senzori SAR diferiți pentru a încorpora interferometria de-a lungul pistei (ATI) pentru estimarea OSC observată direct de mișcarea a doi senzori. Mai mult, delimitarea coastei va fi efectuată prin exploatarea

datelor de la cei doi sau trei senzori SAR pentru a îmbunătăți și mai mult aplicabilitatea algoritmului f_{DC} propus pentru a funcționa cu toate tipurile de date SAR.

Tehnicile analitice ajută la extragerea caracteristicilor și la detectarea țintei folosind SAR și ISAR; cu toate acestea, clasificarea caracteristicilor este la fel de importantă. Prin urmare, rețelele de învățare profundă avansează pentru a îmbunătăți clasificarea caracteristicilor din datele SAR sau ISAR, ceea ce va fi un privilegiu pentru a adapta aceste rețele pentru precizia clasificării caracteristicilor. Pe baza cercetărilor prezentate în contextul ISAR, o potențială fază ulterioară va implica efectuarea de măsurători folosind o configurație bistatică pentru ISAR. Această configurație oferă o abordare benefică pentru investigarea caracteristicilor țintei, deoarece permite achiziționarea de date suplimentare privind elevația acesteia. Obținerea unor astfel de perspective topografice ar necesita dezvoltarea și integrarea unor algoritmi noi adaptați pentru imagistica bistatică.

6.3 Publicații

[JP1] M. A. Iqbal, A. Anghel and M. Datcu, "*Coastline Extraction From SAR Data Using Doppler Centroid Images*," in IEEE Geoscience and Remote Sensing Letters, vol. 19, pp. 1-5, 2022, Art no. 1506205, doi: 10.1109/LGRS.2022.3214496.

[JP2] M. A. Iqbal, A. Anghel and M. Datcu, "*Subaperture Decomposition for Ship Detection and Velocity Estimation from SLC SAR data*," IEEE Geoscience and Remote Sensing Letters, (Submitted)

[CP1] M. A. Iqbal, A. Anghel and M. Datcu, "*Doppler Centroid Estimation for Ocean Surface Current Retrieval from Sentinel-1 SAR Data*," 2021 18th European Radar Conference (EuRAD), London, United Kingdom, 2022, pp. 429-432, doi: 10.23919/EuRAD50154.2022.9784550.

[CP2] M. A. Iqbal, A. Anghel and M. Datcu, "*On the De-Ramping of SLC-IW Tops SAR Data and Ocean Circulation Parameters Estimation*," IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia, 2022, pp. 6817-6820, doi: 10.1109/IGARSS46834.2022.9884331.

[CP3] M. A. Iqbal, R. M. Asiyabi, O. Ghozatlou, A. Anghel, M. Datcu, "*Towards Complex-Valued Deep Architectures with Data Model Preservation for Sea Surface Current Estimation from SAR Data*," In IEEE 20th International Conference on Content-based Multimedia Indexing CBMI-2023, DOI: 10.1145/3617233.3617271.

[CP4] M. A. Iqbal, A. Anghel and M. Datcu, "*Ice Cover Delineation Over Devon Iceland Using Sentinel Polarimetric SAR and Optical Data*", In IEEE International Workshop on Metrology for the Sea; Learning to Measure Sea Health Parameters (MetroSea), 2023, Valletta, Malta pp. 415-420.

[CP5] M. A. Iqbal, A. Anghel, M. Datcu, I. Ederra, and J. C. Iriarte, "*Assessment of mm-Wave High Resolution Inverse SAR Imaging both with Compact and Sparse Data*," 2023 20th European Radar Conference (EuRAD), Berlin, Germany, 2023, pp. 266-269

[CP6] M. A. Iqbal, A. Anghel, M. Datcu, A. Bathelt., S. Sigger, "*Exploiting Inverse SAR Images and Dual-Pol Decomposition For The Estimation Of Tree Scattering Properties*," IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium, Pasadena, USA, 2023, pages 1622 - 1625.

[CP7] M. A. Iqbal, M. H. Conde, A. Anghel and M. Datcu, "*Sparse Reconstruction for High-Resolution Inverse SAR Imaging*", Doctoral Symposium on Electronics, Telecommunications, and Information Technology, 2023, Bucharest, Romania.

[CP8] M. A. Iqbal, M. H. Conde, A. Anghel and M. Datcu, "*Coarse-to-fine Estimation: Compressive Sensing for High-Resolution Inverse SAR Imaging*", In IEEE European Synthetic Aperture Radar Conference (EuSAR), 2024, Munich, Germany, (Submitted)

Bibliografie

- [1] Gang Xu, Bangjie Zhang, Hanwen Yu, Jianlai Chen, Mengdao Xing, and Wei Hong. Sparse synthetic aperture radar imaging from compressed sensing and machine learning: Theories, applications, and trends. *IEEE Geoscience and Remote Sensing Magazine*, 10(4):32–69, 2022.
- [2] Alberto Moreira, Pau Prats-Iraola, Marwan Younis, Gerhard Krieger, Irena Hajnsek, and Konstantinos P Papathanassiou. A tutorial on synthetic aperture radar. *IEEE Geoscience and remote sensing magazine*, 1(1):6–43, 2013.
- [3] Lei Zhang, Zhi-jun Qiao, Mengdao Xing, Yachao Li, and Zheng Bao. High-resolution isar imaging with sparse stepped-frequency waveforms. *IEEE Transactions on Geoscience and Remote Sensing*, 49(11):4630–4651, 2011.
- [4] Muhammad Amjad Iqbal, Andrei Anghel, and Mihai Datcu. Doppler centroid estimation for ocean surface current retrieval from sentinel-1 sar data. In *2021 18th European Radar Conference (EuRAD)*, pages 429–432. IEEE, 2022.
- [5] Muhammad Amjad Iqbal, Andrei Anghel, and Mihai 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*, pages 6817–6820. IEEE, 2022.
- [6] Muhammad Amjad Iqbal, Andrei Anghel, and Mihai Datcu. Coastline extraction from sar data using doppler centroid images. *IEEE Geoscience and Remote Sensing Letters*, 19:1–5, 2022.
- [7] Xiufang Zou and Qunying Zhang. Estimation of doppler centroid frequency in spaceborne scansar. *Journal of Electronics (China)*, 25:822–826, 2008.
- [8] S Norvang Madsen. Estimating the doppler centroid of sar data. *IEEE Transactions on aerospace and electronic systems*, 25(2):134–140, 1989.
- [9] Bertrand Chapron, Fabrice Collard, and Fabrice Ardhuin. Direct measurements of ocean surface velocity from space: Interpretation and validation. *Journal of Geophysical Research: Oceans*, 110(C7), 2005.
- [10] Jose Agustin Barrachina, Chenfang Ren, Christele Morisseau, Gilles Vieillard, and J-P Ovarlez. Complex-valued vs. real-valued neural networks for classification perspectives: An example on non-circular data. In *ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 2990–2994. IEEE, 2021.
- [11] Wilhelm Wirtinger. Zur formalen theorie der funktionen von mehr komplexen veränderlichen. *Mathematische Annalen*, 97(1):357–375, 1927.
- [12] Reza Mohammadi Asiyabi, Mihai Datcu, Andrei Anghel, and Holger 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*, 2023.

- [13] Emanuele Ferrentino, Andrea Buono, Ferdinando Nunziata, Armando Marino, and Maurizio Migliaccio. On the use of multipolarization satellite sar data for coastline extraction in harsh coastal environments: The case of solway firth. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14:249–257, 2020.
- [14] Ramona Pelich, Marco Chini, Renaud Hostache, Patrick Matgen, and Carlos López-Martínez. Coastline detection based on sentinel-1 time series for ship-and flood-monitoring applications. *IEEE Geoscience and Remote Sensing Letters*, 18(10):1771–1775, 2020.
- [15] Nicolae-Cătălin Ristea, Andrei Anghel, Mihai Datcu, and Bertrand Chapron. Guided unsupervised learning by subaperture decomposition for ocean sar image retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 2023.
- [16] Mozhgan Zahriban Hesari, Ferdinando Nunziata, Giuseppe Aulicino, Andrea Buono, and Maurizio Migliaccio. Analysis of fine-scale dynamics of the drygalski ice tongue in antarctica using satellite sar data. *International Journal of Remote Sensing*, 43(7):2581–2598, 2022.
- [17] Risto Vehmas and Nadav Neuberger. Inverse synthetic aperture radar imaging: A historical perspective and state-of-the-art survey. *IEEE Access*, 9:113917–113943, 2021.
- [18] Xiahan Yang, Yahong R. Zheng, Mohammad Tayeb Ghasr, and Kristen M. Donnell. Microwave imaging from sparse measurements for near-field synthetic aperture radar. *IEEE Transactions on Instrumentation and Measurement*, 66(10):2680–2692, 2017.
- [19] Reza Shirvany. *Estimation of the degree of polarization in polarimetric SAR imagery: Principles and applications*. PhD thesis, 2012.
- [20] Jong-Sen Lee and Eric Pottier. *Polarimetric radar imaging: from basics to applications*. CRC press, 2017.
- [21] Tiantian Yin, Zhun Wei, and Xudong Chen. Wavelet transform subspace-based optimization method for inverse scattering. *IEEE Journal on Multiscale and Multiphysics Computational Techniques*, 3:176–184, 2018.
- [22] Yuanhao Cai, Jing Lin, Xiaowan Hu, Haoqian Wang, Xin Yuan, Yulun Zhang, Radu Timofte, and Luc Van Gool. Coarse-to-fine sparse transformer for hyperspectral image reconstruction. In *European Conference on Computer Vision*, pages 686–704. Springer, 2022.
- [23] Jiyuan Chen, Letao Xu, Xiaoyi Pan, Pu Zheng, and Shunping Xiao. High-resolution isar imaging with sparse aperture vfm waveforms under low snr condition. *IEEE Access*, 7:110651–110659, 2019.