




# UNIVERSITATEA POLITEHNICA DIN BUCUREȘTI



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

Decizie nr. 970 din 08-12-2022

## REZUMAT TEZĂ DE DOCTORAT

**Ing. Mihai COCA**

---

METODE HIBRIDE DE INTELIGENȚĂ ARTIFICIALĂ PENTRU  
EXTRAGEREA INFORMAȚIILOR LATENTE DIN IMAGINI DE  
TELEDETECTIE: ANALIZA LA BORD A HAZARDELOR  
NATURALE

HYBRID ARTIFICIAL INTELLIGENCE METHODS FOR LATENT  
INFORMATION EXTRACTION FROM REMOTE SENSING  
IMAGES: ON-BOARD NATURAL HAZARD ANALYSIS

---

### COMISIA DE DOCTORAT

<b>Prof. Dr. Ing. Mihai CIUC</b> Univ. Politehnica din București	Președinte
<b>Prof. Dr. Ing. Mihai DATCU</b> Centrul Aerospațial German	Conducător de doctorat
<b>Prof. Dr. Ing. Cosmin ANCUȚI</b> Univ. Politehnica din Timișoara	Referent
<b>C.S. II Dr. Ing. Corina VĂDUVA</b> Univ. Politehnica din București	Referent
<b>Conf. Dr. Ing. Ștefan-Adrian TOMA</b> Academia Tehnică Militară Ferdinand I	Referent

**BUCUREȘTI 2022**

---

# Cuprins

<b>1</b>	<b>Introducere</b>	<b>1</b>
1.1	Prezentarea domeniului tezei de doctorat . . . . .	1
1.2	Scopul tezei de doctorat . . . . .	1
1.3	Conținutul tezei de doctorat . . . . .	1
<b>2</b>	<b>Noțiuni de bază în teledetecție</b>	<b>2</b>
2.1	Prezentare generală a hazardelor . . . . .	3
2.2	Prezentare generală a detectării modificărilor . . . . .	4
2.3	Prezentare generală a detectării anomaliilor . . . . .	4
2.3.1	Aplicații la sol . . . . .	5
2.3.2	Aplicații la bord . . . . .	5
<b>3</b>	<b>Detectarea schimbărilor în imagini SAR pe baza NCD</b>	<b>6</b>
3.1	Metrica NCD pentru detectarea schimbărilor . . . . .	6
3.2	Zone de studiu și seturi de date . . . . .	7
3.3	Metodă nesupervizată pentru detectarea schimbărilor . . . . .	8
3.3.1	Rezultate experimentale . . . . .	8
3.4	Metodă supravegheată pentru detectarea schimbărilor . . . . .	9
3.4.1	Rezultate experimentale . . . . .	9
3.5	Contributions . . . . .	10
<b>4</b>	<b>Detecția anomaliilor cu modele DNN hibride</b>	<b>11</b>
4.1	Învățare autosupravegheată . . . . .	11
4.1.1	Context actual . . . . .	11
4.1.2	Metodologie . . . . .	11
4.1.3	Zone de studiu și seturi de date . . . . .	14
4.1.4	Experimente . . . . .	16
4.2	Învățare nesupravegheată . . . . .	18
4.2.1	Metodologie . . . . .	18
4.2.2	Experimente . . . . .	19
4.3	Contribuții . . . . .	19

<b>5</b>	<b>Accelerator FPGA pentru detectarea anomaliilor prin meta-recunoaștere</b>	<b>20</b>
5.1	Context actual . . . . .	20
5.2	Metodologie . . . . .	20
5.2.1	Meta-Recunoaștere . . . . .	21
5.2.2	Cuantificarea și compilarea modelului . . . . .	22
5.3	Zone de studiu și seturi de date . . . . .	22
5.3.1	Seturi de date propuse . . . . .	22
5.4	Experimente . . . . .	23
5.5	Contribuții . . . . .	24
<b>6</b>	<b>Conclusions</b>	<b>25</b>
6.1	Original contributions . . . . .	25
6.2	List of original publications . . . . .	25
6.2.1	Journals . . . . .	25
6.2.2	Conference proceedings . . . . .	26
6.3	Perspectives for future developments . . . . .	26
	<b>Bibliografie</b>	<b>27</b>

# Capitolul 1

## Introducere

### 1.1 Prezentarea domeniului tezei de doctorat

Schimbările climatice globale în curs de desfășurare produc efecte pe termen lung care implică diverse dezastre, de la perioade mai lungi de secetă cu incendii mai frecvente, la inundații masive ca urmare a topirii rapide a zăpezii din amonte sau datorate creșterii duratei și intensității furtunilor tropicale [7]. Prin urmare, pentru a minimiza în mod eficient impactul pericolelor asupra oamenilor și a naturii, extragerea automată a informațiilor din imaginile din satelit pentru identificarea timpurie a unui pericol, precum și evaluarea pagubelor, este esențială în situații critice.

### 1.2 Scopul tezei de doctorat

Teza își propune să dezvolte metodologii eficiente pentru extragerea și modelarea informațiilor latente din volume masive de date satelitare, în scopul evaluării și detectării automate a evenimentelor dezastruoase de pe suprafața Pământului.

### 1.3 Conținutul tezei de doctorat

*Capitolul 2* prezintă o introducere în domeniul fundamental al teledetecției. *Capitolul 3* descrie o soluție bazată pe compresia datelor prin intermediul distanței prin compresie normalizată (NCD), pentru detecția inundațiilor în seriile temporale de imagini radar cu apertură sintetică (SAR). *Capitolul 4* prezintă două abordări statistice de învățare profundă pentru detectarea zonelor afectate de incendii în imagini multispectrale. *Capitolul 5* prezintă un model statistic de detectare a anomaliilor dezvoltat și optimizat pentru un dispozitiv cu arie programabilă (FPGA), potrivit pentru integrarea la bord unui satelit și detectarea imediată a incendiilor în scene multispectrale. *Capitolul 6* cuprinde contribuțiile tezei, lista articolelor publicate și perspectivele de viitor.

# Capitolul 2

## Noțiuni de bază în teledetecție

Conceptul de teledetecție se referă la orice instrument utilizat pentru a observa starea și condiția unui obiect, de la distanță, situat pe suprafața Pământului. Energia radiantă generată prin reflectarea unei energii incidente, provenind de la Soare sau generată artificial, este înregistrată de senzorii de la bord, stocată și transmisă la stația de la sol pentru prelucrarea datelor. Sistemele de senzori sunt clasificate în funcție de modul în care detectează energia electromagnetică, adică senzori pasivi, care detectează radiațiile generate de surse externe, și senzori activi, care își transmit propria energie către țintă și apoi captează reflexia [7]. Senzorii integrați la bordul unui satelit sunt concepuți pentru a capta date în diferite părți ale spectrului electromagnetic, sub diferite constrângeri de sistem, rezoluția spectrală, rezoluția temporală, rezoluția spațială și rezoluția radiometrică.

Primul satelit pentru observarea detaliată și de înaltă rezoluție a întregii suprafețe a Pământului a fost Landsat 1, lansat în 1972, ca parte a programului Landsat, care încă continuă să furnizeze date de teledetecție [37]. Sentinel-2 este o misiune europeană de achiziție a imaginilor multispectrale care cuprinde doi sateliți gemeni, care zboară pe aceeași orbită, cu o rezoluție temporală de 5 zile la ecuator. Instrumentul multispectral (MSI) plasat la bordul platformei Sentinel-2 eșantionează 13 benzi spectrale [21]. TerraSAR-X este un satelit german de observare a Pământului, având un senzor radar în banda X, care înregistrează imagini SAR cu o rezoluție de până la 1 m, indiferent de condițiile meteorologice, de gradul de acoperire a norilor sau de lipsa luminii naturale [13].

Există combinații convenabile pentru a extrage anumite informații, de exemplu, nivelurile de umiditate din vegetație prin combinarea benzilor Near InfraRed și Short-Wave InfraRed, Figura 2.1, unde culorile albastre înseamnă o vegetație mai umedă, în timp ce culorile roșii înseamnă că plantele sunt stresate din cauza umidității insuficiente. Deși imaginile optice au un potențial extraordinar pentru cartografiere, cu o capacitate de analiză robustă și o precizie ridicată a imaginilor, în condiții meteorologice dificile, adoptarea senzorilor SAR a demonstrat un potențial ridicat în cartografierea zonelor acoperite de nori.




Figura 2.1 București, România. Combinații convenabile pentru a afișa indicele de umiditate a vegetației utilizând benzile Sentinel-2.

## 2.1 Prezentare generală a hazardelor

Există mai multe tipuri de hazarde, din cauze naturale sau din intervenția umană. Sunt enumerate hazarde la scară mare, detectabile din satelit [29]:

- *Inundațiile* sunt cele mai distructive și mai costisitoare dezastre naturale, cu cel mai mare efect negativ asupra oamenilor în comparație cu alte dezastre naturale.
- *Incendiile de pădure* reprezintă unul dintre cele mai devastatoare hazarde naturale din lume, contribuind la încălzirea globală, la pierderi economice și, în cele din urmă, la pierderea de vieți omenești.
- *Erupțiile vulcanice* generează efecte care variază de la acoperirea mediului cu cenușă vulcanică până la gazele injectate în atmosferă, ceea ce duce la schimbări climatice.
- *Cutremurele* lovesc fără avertisment și provoacă pagube substanțiale într-un timp scurt.
- *Typhoon* este un ciclon tropical puternic, cu furtuni rotative care suflă cu peste 100 km/h, cu traiectorii imprevizibile.
- *Alunecările de teren* se produc în regiunile muntoase ca urmare a furtunilor puternice, erupțiilor vulcanice sau cutremurelor.
- *Deversările de petrol* sunt provocate în fiecare an prin activități ilegale deliberate sau accidente, cum ar fi deteriorarea conductelor de petrol.

Un singur satelit poate rata un dezastru natural în momentul în care se produce, dar o constelație eterogenă de mai mulți sateliți aflați deja pe orbită poate reduce drastic perioada de revizitare și poate furniza imagini din orice loc și în orice moment. Serviciile International Chapter Space and Major Disasters [29] și Copernicus Emergency Management Service (EMS) [12] oferă acces la imagini din satelit în timpul dezastrelor majore, care combinate cu soluții inteligente de detectare, generează un beneficiu major în controlul dezastrelor.

## 2.2 Prezentare generală a detectării modificărilor

Având în vedere cantitățile masive de date disponibile, simultan cu creșterea cerințelor de calcul, este necesară compararea automată a două imagini satelitare pentru a determina locația modificărilor într-un mod rapid, cu puține etape de procesare și minimă intervenție umană. Soluțiile de detecție a modificărilor (CD) extrag informații dependente de timp asupra țintele de interes din aceeași zonă geografică prin utilizarea imaginilor multitemporale [3].

Seriile temporale ale imaginilor SAR sunt utilizate pe scară largă în metodologiile CD, de obicei prin calcularea raportului pixel cu pixel a două imagini SAR consecutive [39]. Imaginea diferențială rezultată necesită selectarea unei valori de prag optime pentru a separa pixelii modificați de cei neschimbați [54]. Capacitatea mare de învățare a rețelelor neuronale profunde (DNN) a permis utilizarea autocodificatoarelor suprapuse (SAE) [42], sau a modelelor simetrice [56] în contextul CD, în imaginile SAR. În scenariile reale, există situații în care imaginea anterioară evenimentului din seria de timp este inutilizabilă sau achiziția este prea veche, ceea ce face imposibilă identificarea unei posibile modificări la nivelul solului de către un algoritm clasic de CD. Astfel, schimbările ar trebui să fie identificate numai din imaginea de după eveniment, unde eșantioanele deviate sunt interpretate ca anomalii.

## 2.3 Prezentare generală a detectării anomaliilor

Anomaliile sunt tipare din date care nu corespund unei percepții definite de un comportament normal. Definiția normalității datelor este strâns legată de domeniul analizat, de la modele geometrice cunoscute *a priori* în cadrul unei linii de producție, până la clasele uzuale de acoperire a suprafeței terestre. Anormalitatea datelor poate apărea la nivelul senzorilor, prin artefacte, datorate variabilității măsurătorilor, erorilor de moment sau zgomotului, sau în scena observată, prin anomalii semantice, datorate obiectelor care deviază semnificativ de la întreaga scenă.

Conceptele clasice pentru detectarea anomaliilor (AD) nesupervizată, extinse în mai multe discipline (de exemplu, statistică, medicină, inginerie, științe naturale), constau, printre altele, în metoda Principal Component Analysis (PCA), algoritmiile nearest

neighbor, metoda One-Class Support Vector Machine (OCSVM) și metoda Support Vector Data Description (SVDD). Din cauza muncii laborioase și aproape imposibile de etichetare a datelor pentru a caracteriza toate anomaliile din scenariile reale, o soluție pentru detectarea anomaliilor este învățarea unui model din distribuția normală a datelor care identifică anomaliile prin deviere.

### **2.3.1 Aplicații la sol**

Prelucrarea datelor din satelit se face în principal la sol, cu un feedback întârziat în aplicații, din cauza modului progresiv de colectare a datelor. În scenele de teledetecție (RS), algoritmi de detectare a anomaliilor caută porțiuni mici care deviază de la fundalul scenei, definit prin clase uzual întâlnite pe suprafața Pământului. Efectele produse de hazardele naturale sunt anomalii pe suprafața Pământului, cu potențial dăunător la scară mare.

Detectarea evenimentelor de pe suprafața Pământului este adesea esențială pentru abordarea imediată a impactului negativ asupra resurselor naturale, de exemplu, perturbări ale vegetației legate de secetă [48], inundații devastatoare [10], detectarea incendiilor active [43]. Incendiile de vegetație reprezintă un risc natural care a provocat daune grave în ceea ce privește siguranța oamenilor și ecosistemele naturale în ultimii ani [11].

### **2.3.2 Aplicații la bord**

În mediile dificile, misiunile spațiale trebuie să proceseze cantități uriașe de informații cu resurse limitate. Prelucrarea automată a datelor în apropierea senzorului [20], imediat după achiziție, poate reduce fluxul de informații către stațiile de la sol și poate detecta din timp evenimentele anormale de la nivelul solului. Misiunile cu sateliți de mici dimensiuni încorporează arii FPGA cu flexibilitate programatică, procesare paralelă și eficiență energetică. Dispozitivele hibride System-on-chip (SoC) [52] includ o unitate de procesare și o arie FPGA pe un singur cip, implementând aplicații spațiale pe un singur dispozitiv.

Misiunea PhiSat-1 [22] a fost făcută de primul satelit de observare a Pământului cu inteligență artificială (AI) la bord, utilizată pentru a maximiza informațiile relevante care urmează să fie transmise către stația de recepție de la sol [27]. Sistemul PhiSat a utilizat un model convoluțional la bord pentru a detecta norii din imagini cu scopul final de a filtra imaginile inutilizabile [26].

Procesarea imaginilor la bord necesită dimensiuni reduse și un consum limitat de energie pentru componentele hardware. Dispozitivele FPGA au performanțe mai bune decât unitățile de procesare grafică (GPU) în ceea ce privește consumul de energie, cu un sacrificiu redus în ceea ce privește performanța. Capacitatea de reconfigurare dinamică a ariilor FPGA, care permite adaptarea dinamică a problemei specifice la condițiile în schimbare, este o caracteristică specifică și atractivă pentru calculul la bord.



# Capitolul 3

## Detectarea schimbărilor în imagini SAR pe baza NCD

### 3.1 Metrica NCD pentru detectarea schimbărilor

Acest capitol propune o metodologie de detecție a schimbărilor provocate de inundații, în seriile temporale folosind compresia datelor. Distanța de compresie normalizată (NCD) este o metrică universală fără parametri aplicată cu succes ca măsură de similaritate pentru datele nestructurate. NCD este forma calculabilă a distanței normalizate a informației (NID) [2], care se bazează pe complexitatea Kolmogorov [34]. În teoria informației, complexitatea Kolmogorov a unui obiect este dimensiunea minimă a unui program de calcul care produce același obiect la ieșire. Li *et al.* [33] a propus o aproximare adecvată pentru NID prin înlocuirea operatorului Kolmogorov cu limita inferioară a unui compresor real, de exemplu, bzlib, zlib. Două obiecte sunt considerate apropiate dacă un proces poate comprima în mod semnificativ unul dintre ele având în vedere informațiile din celălalt, adică dacă două eșantioane sunt mai asemănătoare, atunci unul poate fi descris mai succint folosindu-l pe celălalt [9]. Pentru două obiecte  $x$  și  $y$ , metrica NCD este definită sub forma

$$NCD(x, y) = \frac{C(x, y) - \min(C(x), C(y))}{\max(C(x), C(y))}, \quad (3.1)$$

unde  $C(x, y)$  este dimensiunea compresiei concatenării  $x$  și  $y$ ,  $C(x)$  și  $C(y)$  sunt dimensiunile comprimării obiectelor  $x$  și  $y$ . Valoarea  $NCD(x, y)$  este un număr pozitiv, adică  $0 < NCD(x, y) < 1 + \epsilon$ , care reprezintă cât de diferite sunt cele două obiecte. Eroarea  $\epsilon$  apare din imperfecțiunile tehnicii de compresie [5].

CompLearn [8] este o bibliotecă care integrează tehnici de compresie în procesul de descoperire și învățare a modelelor. Această bibliotecă poate calcula o matrice NCD pentru o colecție de eșantioane eterogene cu diferite variante de compresoare. O abordare




Figura 3.1 Setul de date Sendai cu imagini SAR de amplitudine, pre-eveniment (a) și post-eveniment (b), achiziționate de satelitul TerraSAR-X. Subsetul Sendai1024 în subimagini de 1024x1024 pixeli.




Figura 3.2 Setul de date Stendal cu imagini SAR de amplitudine, pre-eveniment (a) și post-eveniment (b), achiziționate de satelitul TerraSAR-X.

mai rapidă a fost propusă în [45] folosind un compresor optimizat pentru rularea pe GPU, obținându-se o creștere a vitezei de compresie cu o mică scădere a preciziei.

Acest capitol prezintă două metode care calculează o imagine diferențială (DI) din serii temporale a două imagini SAR folosind operatorul NCD (3.1). DI este utilizată pentru a crea o hartă binară a modificărilor care evidențiază zonele afectate de inundații dintr-o scenă. Trebuie menționat faptul că toate metodele propuse în această teză funcționează la nivel de patch-uri.

## 3.2 Zone de studiu și seturi de date

Două scene care conțin efectele devastatoare ale unui tsunami (Figura 3.1) într-o parte a litoralului din Sendai, regiunea Tohoku, Japonia, respectiv efectele unei inundații cauzate de revărsarea râului Elba (Figura 3.2) în districtul Stendal, Germania. Ambele seturi de date, Sendai și Stendal, au fost studiate pentru prima dată în [16] cu ajutorul unui instrument interactiv, automat și rapid. Datele de intrare au fost sub forma unor colecții de subimagini, adică patch-uri, fiecare generată dintr-o scenă inițială care a fost împărțită în subimagini prin intermediul unei ferestre pătratice glisante fără suprapunere.

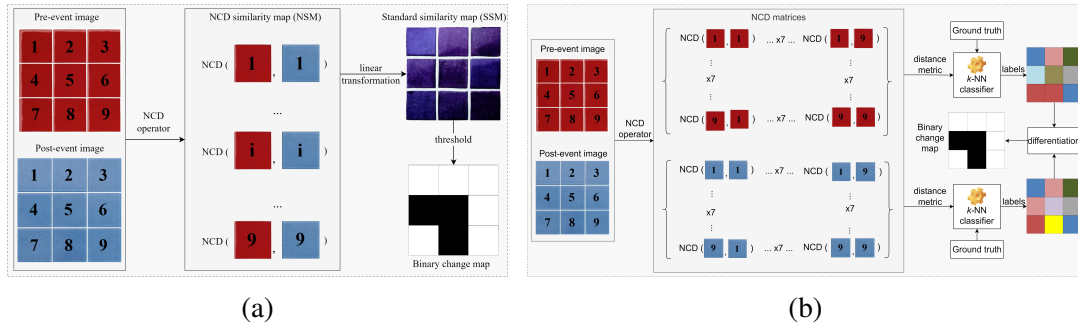


Figura 3.3 Metodologii pentru detectarea nesupervizată a modificărilor (a) și pentru detectarea supervizată a modificărilor (b).

### 3.3 Metodă nesupervizată pentru detectarea schimbărilor

În metoda nesupervizată propusă, operatorul NCD (3.1) a fost utilizat pentru a genera o hartă de similaritate pentru toate perechile de eşantioane dintr-o serie bi-temporală, harta de similaritate NCD (NSM). Apoi, s-a aplicat o transformare liniară asupra NSM pentru a se potrivească valorilor în intervalul  $[0, 255]$ . În continuare, harta de similaritate standard (SSM) a fost utilizată pentru a genera o hartă de schimbare binară bazată pe un prag determinat automat (Figura 3.3a).

În această abordare, metrica NCD calculează gradul de similitudine dintre două patch-uri din aceeași locație geografică, dar în momente diferite. Pornind de la valorile histogramei SSM, au fost implicați trei algoritmi pentru a estima un prag optim, și anume, metoda lui Otsu [41], metoda lui Kittler [31] și metoda lui Kapur [30].

#### 3.3.1 Rezultate experimentale

Pentru a testa metoda nesupravegheată propusă pe subșutul Sendai1024, dimensiunea patch-urilor a fost stabilită la 64x64 pixeli. Dimensiunea de 64x64 pixeli este o limită inferioară care oferă spațiu pentru identificarea modelelor în scopul comprimării datelor.

Figura 3.4 ilustrează intervalele de rezultate ale metricii NCD pentru diferite dimensiuni ale patch-urilor. În interiorul intervalului de valori NCD, între valorile minime și maxime, au fost evidențiate pragurile estimate obținute prin intermediul celor 3 algoritmi, aplicați histogramei SSM. Algoritmul Frost [23] a fost utilizat pentru a filtra zgomotele, păstrând în același timp marginile în imaginile SAR, pentru a testa ipoteza că operatorul NCD este rezistent la zgomot [5].

În Tabelul 3.1, cel mai bun rezultat obținut pe subșutul Sendai1024 pe diferite dimensiuni de patch-uri a fost dat de algoritmul Kittler cu o valoare a ratei de eroare de 4,20%, și o acuratețe de detecție de 95,80% pentru dimensiunea de 32x32 a patch-ului, respectiv metoda Otsu cu o valoare a ratei de eroare de 0,78%, și o detecție foarte precisă de 99,22% pentru dimensiunea de 64x64 a patch-ului. Faptul că cele mai bune rezultate




Figura 3.4 Gama de valori NCD, minime și maxime, precum și valorile de prag ale algoritmilor Otsu, Kapur și Kittler.

au fost obținute atunci când nu s-a aplicat nicio iterație de filtrare a validat faptul că operatorul NCD este rezistent la zgomot.

### 3.4 Metodă supravegheată pentru detectarea schimbărilor

În metoda supravegheată propusă, operatorul NCD (3.1) a fost utilizat pentru a genera o matrice NCD care conține informații relaționale din întreaga colecție de patch-uri din interiorul unei scene. Informațiile de distanță au fost utilizate de algoritmul de clasificare k-NN pentru a clasifica eșantioanele. Un algoritm simplu de diferențiere a adnotărilor, aplicat rezultatelor celor două scene inițiale, a produs o hartă a modificărilor (Figura 3.3b).

#### 3.4.1 Rezultate experimentale

Setului de date Sendai a avut o nomenclatură de 10 clase pentru imaginea de pre-eveniment și 12 clase pentru post-eveniment. În cadrul abordării supravegheate, dimensiunea patch-ului de intrare a fost stabilită la 160x160 pixeli [17]. Luând în considerare o fereastră fără suprapunere de 160x160 pixeli, a rezultat o colecție de 5673 de patch-uri per imagine, pentru setul de date Sendai.

O hartă de adevăr pentru setul de date Sendai, utilizată în evaluarea clasificării, a fost determinată în [18] și rafinată manual în unele cazuri. Clasificatorul k-NN a fost antrenat cu o rată de 40% din întreaga colecție de eșantioane Sendai. Parametrul  $k$  din

Tabel 3.1 Rezultate pentru metoda nesupravegheată pe subsetul Sendai1024.

Thresholding algorithm	Filtering iterations	Patch dimension							
		32x32				64x64			
		Error	Accuracy	False-positive	T	Error	Accuracy	False-positive	T
Kapur	0	11.04%	88.96%	10.31%	85	9.77%	90.23%	10.17%	68
Otsu		9.28%	90.72%	8.35%	91	<b>0.78%</b>	<b>99.22%</b>	<b>0%</b>	<b>99</b>
Kitter		<b>4.20%</b>	<b>95.80%</b>	<b>2.37%</b>	<b>118</b>	1.17%	98.83%	0.42%	87

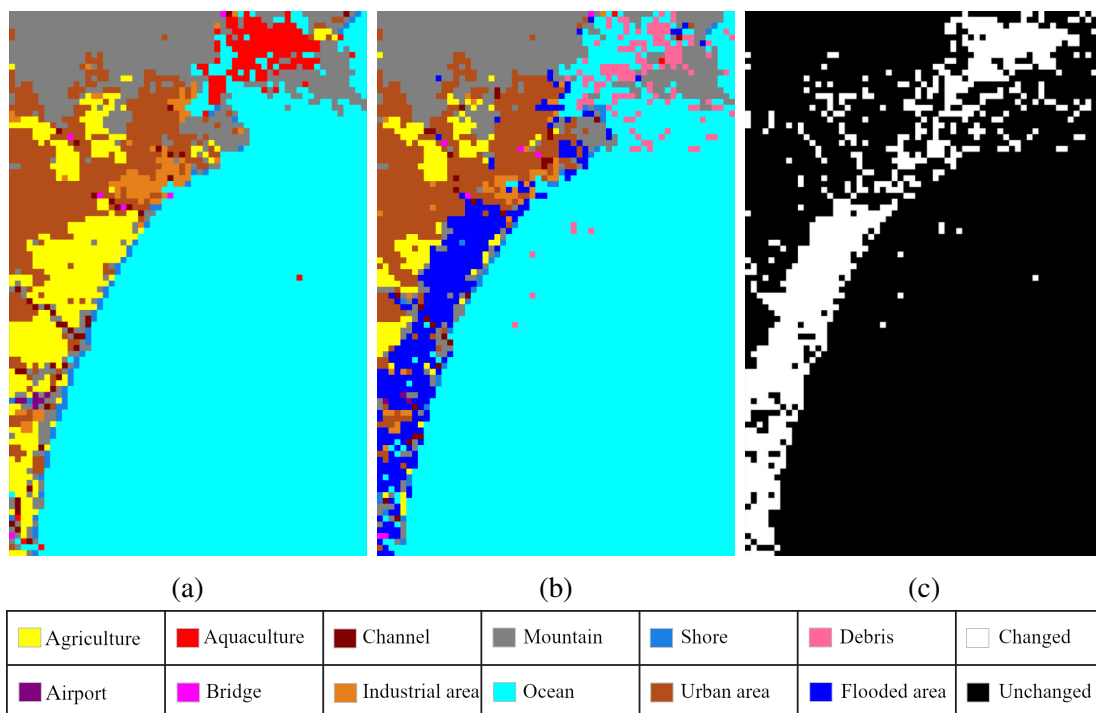


Figura 3.5 Rezultatele clasificării pe setul de date Sendai. Harta de clasificare a imaginilor pre-eveniment (a), post-eveniment (b), harta modificărilor binare (c) și legenda asociată etichetelor.

algoritmul k-NN a fost setat la 11 pentru clasificarea pre-eveniment, respectiv la 13 pentru clasificarea post-eveniment (Figura 3.5).

Evenimentul tsunami a generat unele tranziții de clasă, și anume de la clasa *Acvacultură* la clasa *Debris*, în timp ce clasa *Agricultură* de coastă a fost în mare parte acoperită de clasa *Zonă inundată*. A rezultat o acuratețe globală de 95,06% pentru imaginea pre-eveniment și de 92,97% pentru imaginea post-eveniment. În cazul imaginii post-eveniment, acuratețea a fost mai slabă deoarece variația dintre clase pentru clasele de inundații și resturi rezultate a fost mică. Harta de schimbare binară evidențiată în Figura 3.5c a fost obținută prin diferențierea celor două hărți de clasificare prezentate în Figurile 3.5a și 3.5b. În cele din urmă, harta binară a modificărilor rezultată a identificat cu o precizie de 90,7% zonele care au suferit modificări din cauza efectelor hazardelor naturale.

### 3.5 Contributions

În acest capitol, au fost propuse două metode care se bazează pe compresia datelor pentru a extrage informațiile de distanță din imagini SAR. Informațiile de distanță au fost utilizate pentru a calcula un prag automat, respectiv pentru a antrena o instanță k-NN în vederea generării unei hărți de schimbare binare.

# Capitolul 4

## Detecția anomaliilor cu modele DNN hibride

### 4.1 Învățare autosupravegheată

Învățarea autosupravegheată dispune învățarea unor reprezentări convenabile folosind etichete autogenerate. În imaginile de teledetecție, caracteristicile discriminatorii sunt extrase atât din formele obiectelor, cât și din informațiile de textură [49]. În această secțiune, este propusă o metodă hibridă de detectare a anomaliilor, o componentă Deep Convolutional Neural Network (DCNN) combinată cu un model clasic de distribuție Dirichlet, care identifică anomaliile în scenele Sentinel-2.

#### 4.1.1 Context actual

Imaginile din satelit încorporează multe variații semantice, iar în ultima vreme au fost definite diferite variante pentru a detecta anomaliile contextuale, statistici multivariate [24], metode bazate pe reconstrucție [51], reducere de dimensiune urmată de OCSVM în evaluarea incendiilor de vegetație [11].

#### 4.1.2 Metodologie

Abordările de detecție a anomaliilor (AD) integrează două componente, o statistică care are un feedback cunoscut la distribuția normală a datelor și o regulă de decizie care inspectează statistica. În acest capitol este propusă o metodă de detectare a anomaliilor bazată pe ierarhizare (Figura 4.1), care are ca scop detectarea anomaliilor doar din imaginea post-eveniment.

#### Transformări numerice

Etapele de preprocesare a imaginii se fac în conformitate cu funcția *PreprocessData* definită în Algoritmul 1, prin standardizare sau max-normalizare. În faza de transformare,

---

**Algorithm 1:** Detectarea anomaliilor folosind transformări numerice

---

**Input:**  $F_k$ : o serie de transformări numerice,  $g_\theta$ : model de clasificare multinomial

**Output:**  $scores$ : Scoruri de anomalie

**Data:**  $I_{train}$ : scena cu date normale,  $I_{test}$ : scena cu date normale și anormale

```
1 Function PreprocessData( $I, t$ ):
2    $(W, H, C) \leftarrow size(I)$ 
3    $I \leftarrow reshape(I, W * H, C)$ 
4   if  $t = 1$  then
5      $\{mean_j\}_{j=0}^{C-1} \leftarrow \{\frac{1}{W*H} \sum_{i=0}^{W*H-1} I_{i,j}\}$ 
6      $\{stddev_j\}_{j=0}^{C-1} \leftarrow \{\sqrt{\frac{\sum_{i=0}^{W*H-1} (I_{i,j} - mean_j)^2}{W*H-1}}\}$ 
7      $\{Y_{i,j}\}_{i,j=0}^{W*H-1, C-1} \leftarrow \{\frac{I_{i,j} - mean_j}{stddev_j}\}$ 
8   else
9      $\{Y_{i,j}\}_{i,j=0}^{W*H-1, C-1} \leftarrow \{2 * (I_{i,j} / 2^{16}) - 1\}$ 
10   $Y \leftarrow reshape(Y, W, H, C)$ 
11  return  $\{NonOverlappingPatching(Y)\}$ 
12
13 Function AnomalyScore( $F_k, g_\theta, I_{train}, I_{test}$ ):
14   $X_n \leftarrow PreprocessData(I_{train}, 1)$ 
15   $X_{an} \leftarrow PreprocessData(I_{test}, 1)$ 
16   $X_t \leftarrow \{(F_j(x), j), x \in X_n, 0 \leq j < k\}$ 
17  while not converged do
18    Train  $g_\theta$  on labeled dataset  $X_t$ 
19   $i \leftarrow 0$ 
20   $n \leftarrow |X_n|$ 
21   $|scores| \leftarrow |X_{an}|$ 
22   $scores \leftarrow 0$ 
23  while  $i < k$  do
24     $X_{i,train} \leftarrow \{softmax(g_\theta(F_i(x))), x \in X_n\}$ 
25     $X_{i,test} \leftarrow \{softmax(g_\theta(F_i(x))), x \in X_{an}\}$ 
26     $m \leftarrow 0$ 
27     $p \leftarrow 0$ 
28    foreach  $x_j \in X_{i,train}$  do
29       $m \leftarrow m + x_j$ 
30       $p \leftarrow p + \log x_j$ 
31     $\bar{m} \leftarrow \frac{1}{n} m$ 
32     $\bar{p} \leftarrow \frac{1}{n} p$ 
33     $\alpha_{0,i} \leftarrow \bar{m} \frac{n(k-1)(-\Psi(1))}{n \sum \bar{m} \log(\bar{m}) - \sum \bar{m} p}$ 
34    while not converged do
35       $\bar{\alpha}_{0,i} \leftarrow \Psi^{-1}(\Psi(\sum \alpha_{0,i}) + \bar{p})$ 
36       $scores \leftarrow \{scores + \frac{1}{k} \sum_{j=0}^{k-1} (\bar{\alpha}_{0,i} - 1) * \log x_j, x_j \in X_{i,test}\}$ 
37       $i \leftarrow i + 1$ 
38  return  $scores$ 
```

---

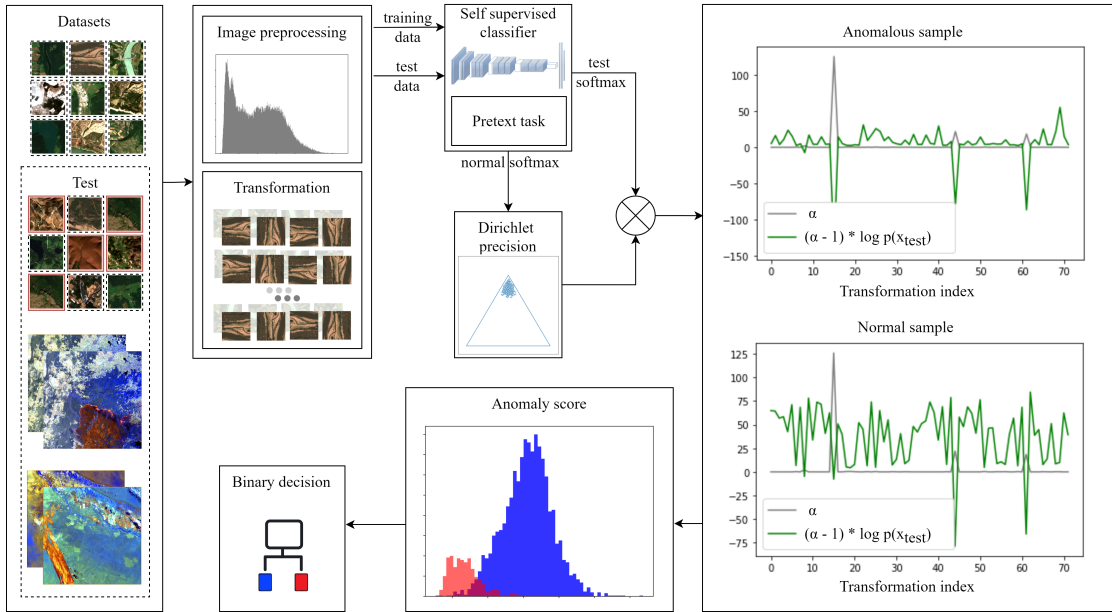


Figura 4.1 Arhitectura generală a metodei de detectare a anomaliilor bazată pe ierarhizare. O imagine Sentinel-2 Level-2A este procesată pentru a genera o colecție de patch-uri fără suprapunere, scalate și transformate geometric. Un clasificator autosupravegheat este antrenat pentru a face diferența între  $k$  transformări geometrice. Un modul de estimare a ierarhizării ia un produs între un vector softmax și o precizie Dirichlet calculată pentru fiecare transformare implicată și produce un scor de anomalie care este utilizat în final într-o decizie binară.

fiecărui eșantion normal  $i$  s-a aplicat un set de transformări geometrice discrete,  $F_k = \{f, f(x, flip, tx, ty, rk) : X \rightarrow X^i, i \in [0, k - 1], flip \in \{false, true\}, (tx, ty) \in \mathbb{Z}, rk \in \{0, 1, 2, 3\}\}$ , unde termenii  $flip, (tx, ty), rk$  parametrizează transformările geometrice comune, cum ar fi bascularea, translația, respectiv rotația. Parametrul  $rk$  reprezintă numărul de rotații în sens trigonometric cu  $90^\circ$ . O imagine transformată este generată prin aplicarea a trei transformări la un moment dat. În continuare, funcția de ierarhizare este definită

$$r_c(x) = \sum_{i=0}^{k-1} \log p(\text{softmax}(g_\theta(F_i(x))) | F_i), \quad (4.1)$$

unde este implicată o probabilitate logaritmică combinată a rezultatului de inferență  $\log p(y|F_k)$ , condiționată de fiecare dintre transformările adaptate în  $F_k$ , sub o distribuție estimată a eșantioanelor normale.

### Distribuția Dirichlet

În interesul proprietăților sale analitice ușor de tratat, distribuția Dirichlet este preferată ca distribuție anterioară în învățarea Bayesiană [25]. O variabilă aleatoare Dirichlet cu  $m$  dimensiuni  $p = (p_1, \dots, p_m)$  descrie o distribuție peste  $m$  clase și ia valori în  $(m - 1)$ -



simplex dacă  $p_k \geq 0, 1 \leq k \leq m$  și  $\sum_{k=1}^m p_k = 1$ . Variabila aleatoare  $p$  are următoarea densitate de probabilitate (4.2) pe  $(m-1)$ -simplex

$$Dir(p|\alpha) = \frac{\Gamma(\alpha_0)}{\prod_{k=1}^m \Gamma(\alpha_k)} \prod_{k=1}^m p_k^{\alpha_k-1}, \alpha_0 = \sum_{k=1}^m \alpha_k, \quad (4.2)$$

unde parametrul  $\alpha$  este un ansamblu de componente ale concentrației  $\alpha_k > 0$ ,  $\alpha_0$  este precizia distribuției,  $p$  este un vector de probabilități și  $\Gamma(\cdot)$  este funcția Gamma. Vectorul parametru  $\alpha$  poate fi aproximat dintr-o colecție de formare a datelor multinomiale observate,  $D = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N\}$  prin maximizarea funcției de probabilitate logaritmică a lui  $D$ , care este dată de

$$G(\alpha) = N(\log \Gamma(\sum_k \alpha_k) - \sum_k \log \Gamma(\alpha_k) + \frac{1}{N} \sum_k (\alpha_k - 1) \sum_i \log p_{ik}). \quad (4.3)$$

Metoda de iterație în punct fix [38] oferă o procedură de convergență pentru estimarea parametrilor  $\alpha_k$ . Estimarea inițială pentru  $\alpha$  se bazează pe metoda Maximum Likelihood Approximation (MLA) [50]. Noua predicție a lui  $\alpha$  (4.4) este

$$\alpha_k^{new} = \Psi^{-1}(\Psi(\sum_k \alpha_k^{old}) + \frac{1}{N} \sum_i \log p_{ik}), \quad (4.4)$$

unde  $\Psi = \frac{d \log \Gamma(x)}{dx}$  este funcția digamma care poate fi inversată prin utilizarea unei proceduri Newton-Raphson.

În Algoritmul 1, linia 33, este utilizată MLA pentru a calcula precizia distribuției Dirichlet, adică  $\alpha_0$ . Funcția Digamma  $\Psi(\cdot)$  este prima derivată a funcției log Gamma și este utilizată pentru a converge la maxim, singurul punct staționar în Dirichlet. Inversa funcției digamma este calculată numeric (liniile 34-35) folosind cinci iterații Newton-Raphson. În (4.3), primele două elemente pot fi reduse deoarece sunt invariante în raport cu  $\mathbf{p}_k$ , rezultând o rescriere a (4.1) sub forma

$$r_c(x) = \sum_{i=0}^{k-1} (\bar{\alpha}_i - 1) \log(\text{softmax}(g_\theta(F_i(x)))). \quad (4.5)$$

### 4.1.3 Zone de studiu și seturi de date

Focul este o parte recurentă a naturii, cu lucruri bune și aspecte rele. În 2019, au fost declanșate numeroase incendii alarmante care au provocat pagube fără precedent.

#### Setul de date BigEarthNet

BigEarthNet [46], [47] este o arhivă de referință, formată din 590.326 de patch-uri Sentinel-2, achiziționate între iunie 2017 și mai 2018 în 10 țări din Europa. BigEarthNet este un set de date multi-etichetă, cu 43 de etichete. Un subset din toate patch-urile




Figura 4.2 Trei perechi de câte două imagini fiecare, de la stânga la dreapta, seturile de date BigEarthNet test (primul), Robore (al doilea) și Sydney (al treilea).

care conțin cel puțin etichetele *Mixed forest*, *Coniferous forest*, *Broad-leaved forest* și *Pastures* din BigEarthNet original, conținând 2570 de eșantioane, a fost utilizat pentru a crea un set de date de instruire (adică 2400 de eșantioane aleatorii sau 93,4%) și un set de date de testare (adică restul de 170 de eșantioane sau restul de 6,6%). În setul de date de testare menționat mai sus, alte 29 de eșantioane specifice care conțin cel puțin etichetele *Mixed forest*, *Broad-leaved forest* și *Burned areas*, filtrate din întregul set de date BigEarthNet, au fost adăugate pentru a obține subsetul *BigEarthNet test* cu 199 de eșantioane. Setul de date de antrenare, adică *BigEarthNet train*, a fost utilizat atât pentru faza de antrenare, cât și ca date observate pentru a estima parametrii distribuției Dirichlet. În Figurile 4.2a și 4.2b se prezintă un patch BigEarthNet în două vizualizări diferite, care conține zone arse evidențiate prin culoarea roșie. Harta de adevăr a fost estimată din colecția de etichete furnizată pentru fiecare eșantion, unde toate eșantioanele care conțineau eticheta *Burned areas* au fost considerate anormale.

### Seturi de date cu zone arse

Fiecare set de date de mai jos este o subzonă de 72 km x 72 km generată dintr-un produs Sentinel-2A, cu imagini pre- și post-eveniment pentru a genera o hartă de adevăr prin intermediul indicilor spectrali clasici, Normalized Burn Ratio (NBR), Normalized Difference Water Index (NDWI), Relativized Burn Ratio (RBR). Fiecare imagine a fost divizată în patch-uri care nu se suprapun, folosind o dimensiune de 120x120 pixeli.

### Robore

Scena cuprinde o zonă din sud-estul orașului Robore, Bolivia, America de Sud. Figurile 4.2c și 4.2d prezintă un eșantion anomal în compozit de culori reale (TC) și în compozit de culori false (FC), cu zona arsă evidențiată în roșu-portocaliu.

### Sydney

Scena originală a cuprins o zonă de sud-vest a orașului Sydney, New South Wales, Australia. Figurile 4.2e și 4.2f prezintă un eșantion anomal în compozit TC și compozit FC, cu zona arsă evidențiată în roșu deschis și roșu-portocaliu.




Figura 4.3 Două seturi de câte trei imagini, de la stânga la dreapta, scena Robore (prima), scena Sydney (a doua).

Intervalul de valori RBR calculat a fost de  $[-4, 23, 0, 93]$  (Robore), respectiv  $[-87, 65, 0, 98]$  (Sydney), iar pe baza metodei Otsu [41], a rezultat un prag de 0,2596, respectiv 0,2725 pe histograma RBR. Condiția binară de prag asupra histogramei RBR produce o hartă de adevăr la nivel de pixel (Figurile 4.3c și 4.3f), care este utilizată pentru a obține o hartă de adevăr la nivel de patch prin intermediul unei condiții simple: dacă mai mult de 50% din pixeli sunt anormalii, întregul patch este considerat anormal.

#### 4.1.4 Experimente

Arhitectura propusă a fost implementată folosind Keras cu backend Tensorflow. Experimentele efectuate au inclus 72 de transformări, adică  $k = 72$ , constând în translații cu  $\{0, \pm 30\}$  pixeli (mod de reflectare), rotații în sens trigonometric cu  $90^\circ$  și basculări în direcția stânga/dreapta. Un model de clasificare profundă cu 72 clase a fost antrenat pe setul de date *BigEarthNet train* pentru a învăța caracteristici semantice într-o manieră autosupraveheată. Modelul de clasificare a fost construit pe baza învățării reziduale, ResNet-50 [28]. Rețelele bazate pe ResNet sunt mai aplicabile pentru învățarea autosupraveheată a reprezentărilor, păstrând reprezentările să nu se degradeze spre finalul rețelei [32]. Modelul de clasificare cu 72 clase  $g_\theta$  a fost antrenat pentru 50 de epoci, cu o dimensiune a lotului egală cu 600 de eșantioane, în 2 ore și 50 de minute. Funcția de estimare Dirichlet în punct fix a utilizat maximum 1000 de iterații și a convers atunci când norma L2 asupra iterațiilor parametrilor Dirichlet a fost mai mică de  $1e - 9$ .




Figura 4.4 Rezultatele AUROC de precizie medie pentru metodele de preprocesare prinstandardizare (a) și max-normalizare (b). Precizia medie a rezultatelor AUPR pe metoda de preprocesare max-normalizare atunci când zona arsă este studiată ca fiind clasa pozitivă (c) și clasa negativă (d).




Figura 4.5 Distribuțiile de probabilitate ale scorurilor pentru seturile de date Sydney (stânga) și Robore (dreapta).

## Rezultate

În Figurile 4.4a și 4.4b, setul de date *BigEarthNet test* a avut performanțe bune încă de la prima transformare, cu mici scăderi ale performanței pe măsură ce au fost incluse mai multe transformări, în timp ce *Robore* și *Sydney* au început cu rezultate slabe, dar s-au îmbunătățit pe măsură ce au fost procesate mai multe transformări. Area Under Precision-Recall (AUPR) este implicată în calcularea unei precizii medii pentru fiecare indice de transformare atunci când sunt disponibile cunoștințe prelabile privind proporția de anomalii. O performanță mai bună este obținută atunci când anomalia este operată ca și clasă negativă pe toate cele trei seturi de date de testare (Figurile 4.4c și 4.4d). Rezultatele sunt prezentate pentru primele 16 transformări geometrice.

Distribuțiile de probabilitate ale scorurilor pentru *Sydney* și *Robore* sunt afișate în Figura 4.5, în modul suprapunere. Distribuțiile scorurilor pentru seturile de date *Sydney* și *Robore* sunt bimodale, respectiv, trimodale. Prin calcularea derivatei a doua a funcției de densitate de probabilitate, punctele de inflexiune obținute au determinat un prag optim pentru fiecare histogramă, 90725,44 pentru setul de date *BigEarthNet test*, 128987,73 pentru setul de date *Sydney*, respectiv 193960,43 pentru setul de date *Robore*.

Tabel 4.1 Evaluarea acurateții pentru seturile de date de testare folosind modelul propus (DCNN-Dirichlet) și un model fără parametri (NCD)

Dataset	Method	Precision	Recall	F1-score
BigEarthNet test	NCD	<b>0.964</b>	0.714	0.781
	DCNN-Dirichlet	0.930	<b>0.941</b>	<b>0.935</b>
Robore	NCD	0.960	0.823	0.877
	DCNN-Dirichlet	<b>0.986</b>	<b>0.885</b>	<b>0.933</b>
Sydney	NCD	0.948	0.845	0.888
	DCNN-Dirichlet	<b>0.977</b>	<b>0.970</b>	<b>0.974</b>

În Tabelul 4.1 sunt prezentate diferite metrice pentru a compara rezultatele obținute prin metoda propusă și o metodă robustă, metoda NCD fără parametri. Fiecare set de date de testare a fost împărțit aleatoriu în proporție de 60:40 și, pe baza unei matrice NCD calculată pentru fiecare set de date de testare, a fost rulat un clasificator binar în spațiu 2-D, unde fiecare dimensiune reprezintă distanța medie față de clasa normală, respectiv clasa anormală.

## 4.2 Învățare nesupravegheată

Metodele de detecție a anomaliilor în imagistică se concentrează pe discriminarea spectrală și spațială, folosind modele statistice [14], reprezentare colaborativă [35] sau modele de detecție a anomaliilor bazate pe rețele neuronale profunde [6]. Autocodificatoarele calculează erorile de reconstrucție între o imagine restaurată și imaginea originală de intrare. Fiind antrenate pe date cu distribuție normală, este de așteptat ca anomaliile să aibă erori de reconstrucție mari, în timp ce datele din fundal au erori de reconstrucție mici [36]. În această secțiune, este introdusă o metodă care estimează anomaliile în datele Sentinel-2 pe baza potențialului capacității de reconstrucție a unui autoencoder.

### 4.2.1 Metodologie

Metodologia propusă s-a bazat în mare măsură pe o arhitectură de codare-decodare ResNet [28] (Figura 4.6a). Matricea de covarianță a fiecărei intrări a fost calculată pentru a fi utilizată ca o caracteristică spațială puternică în vederea clasificării. Datele latente extrase din spațiul încorporat al autocodicatorului sunt utilizate în cele din urmă pentru a antrena o instanță OCSVM.

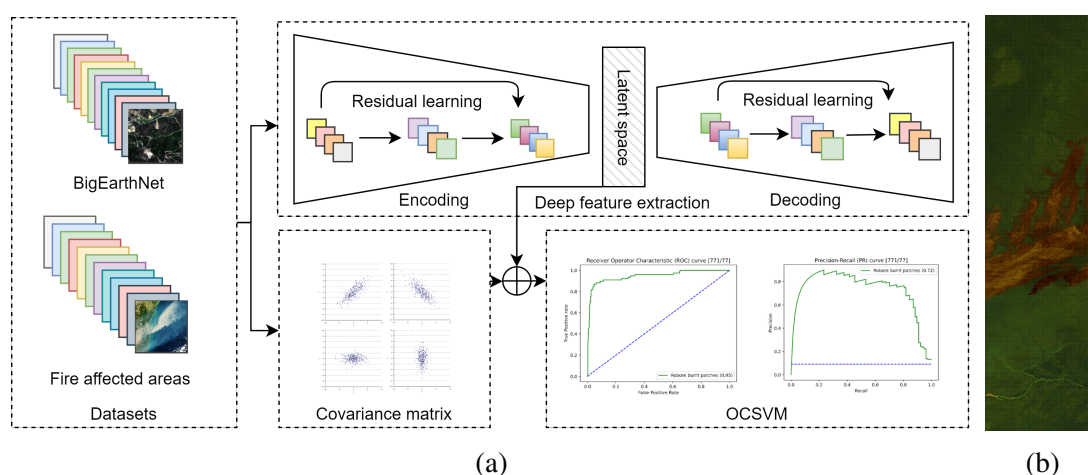


Figura 4.6 Prezentare generală a metodei propuse, care constă în trei module: extragerea caracteristicilor profunde, caracteristica matricei de covarianță și detectorul de valori aberante OCSVM (a). Imagine Sentinel-2, Robore, Bolivia, 23 august 2019 în reprezentare FC (B12, B11, B9) (b).

Tabel 4.2 Evoluția AUPRC pe baza cantității de anomalii.

Burned patches (#)	Burned patches in dataset (%)	AUPRC [0-1]
7	0.9	0.46
15-53	1.94-6.8	0.54-0.66
61	7.9	0.71
69-77	8.9-9.9	0.72

## Model

Un autocodificator codifică o imagine de intrare într-o reprezentare latentă de dimensiuni mai mici, apoi decodifică reprezentarea latentă înapoi într-o imagine asemănător, totul cu o eroare minimă de reconstrucție. A fost utilizată rețeaua standard ResNet-18 [28], cu primul strat adaptat la 12 canale de intrare. Pentru datele de intrare, s-a efectuat interpolarea bicubică pentru canalele de rezoluție de 20 m și 60 m.

## Seturi de date

BigEarthNet (4.1.3) a fost utilizat pentru a antrena modelul. Pentru testare, o zonă de 109,8 km x 30 km (Figura 4.6b) a fost împărțită în patch-uri care nu se suprapun, folosind dimensiunea de 120x120 pixeli.

### 4.2.2 Experimente

A fost efectuat un experiment folosind un set de date de testare care conține 771 de patch-uri normale și 77 de patch-uri anormale, din jumătatea stângă a scenei din Figura 4.6b. Setul de date de testare a început cu 0,9% date anormale și a fost incrementat iterativ cu ~0,9% până când au fost incluse toate cele 77 de eșantioane anormale disponibile. Procesul de antrenare OCSVM a implicat numai date normale, din BigEarthNet, iar raportul dintre zonele normale și cele anormale a fost stabilit empiric la 0,7.

În Tabelul 4.2 este evidențiată evoluția curbei AUPR în funcție de procentul de date anormale incluse în setul de date de testare. Pentru 7,9% patch-uri anormale în setul de date, clasificatorul face o distincție cu o precizie de 0,71.

## 4.3 Contribuții

În acest capitol, a fost propus un model DCNN-Dirichlet care detectează anomaliile în imaginea post-eveniment. În plus, a fost propus modelul DCNN-OCSVM care identifică zonele arse pe baza capacității de reconstrucție.

# Capitolul 5

## Accelerator FPGA pentru detectarea anomaliilor prin meta-recunoaștere

Acest capitol propune o metodologie care transferă efortul de calcul la bordul satelitului pentru detectarea hazardelor naturale, precum incendiile în imaginile multispectrale.

### 5.1 Context actual

Metodele de clasificare și detectare în timp real la bord pentru imaginile de teledetecție se bazează pe diferite tehnici, calcularea matricei de covarianță a datelor și a inversei [15], strategia de proiecție ortogonală [19, 4], detectarea progresivă a anomaliilor pe linie [55] și, în ultimul timp, AI [27].

### 5.2 Metodologie

În acest capitol, a fost propus un algoritm de extindere a caracteristicilor latente extrase din imaginile din satelit prin estimarea probabilității, cu scopul de a asocia eșantioanele deviante la o clasă anormală. Sunt realizate două etape, implementarea, antrenarea și testarea algoritmului pe un cluster GPU (Figura 5.1 (stânga)), urmate de un flux de optimizare și implementare a algoritmului pe un dispozitiv FPGA (Figura 5.1 (dreapta)).

În Figura 5.1 (stânga), un clasificator convoluțional (DCNN) este antrenat pe date observate și utilizat ca extractor de caracteristici. Caracteristicile statistice de fundal sunt approximate prin ajustarea distribuțiilor Weibull pe fiecare clasă observată din setul de date de instruire, privind o metrică de distanță pentru a determina un prag pentru o decizie binară. Această metodologie este legată de conceptul de meta-recunoaștere propus în [1]. În Figura 5.1 (dreapta), fluxul de implementare a implicat Vitis AI Framework, pentru a converti un model Tensorflow DCNN într-un format compatibil cu cel acceptat de componenta Deep Learning Processing Unit (DPU) [53]. Modelul antrenat a fost

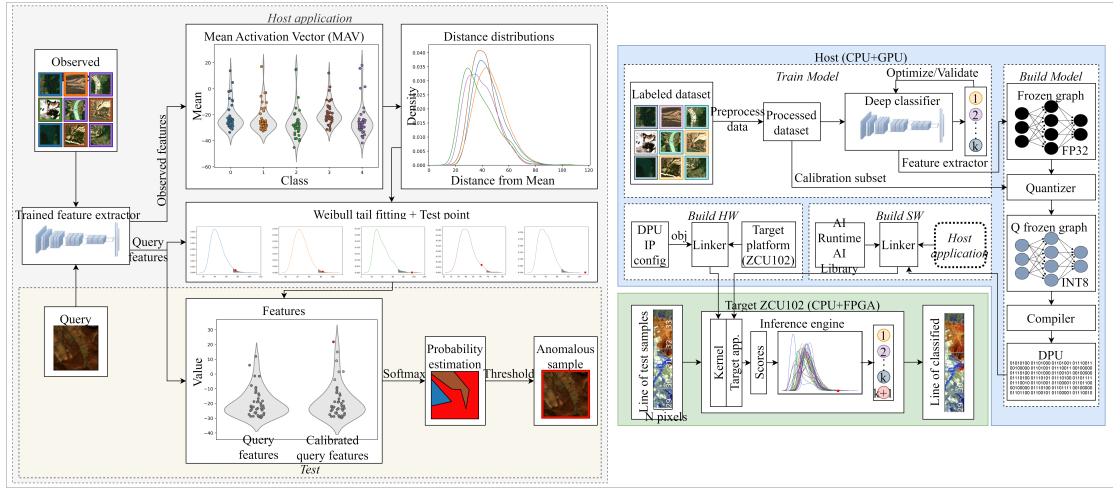


Figura 5.1 Aplicația principală pentru detectarea anomaliilor (stânga), organigrama pentru optimizarea și implementarea acceleratorului de detectare a anomaliilor la bord (dreapta).

cuantificat și compilat într-un model de inferență care este apelat de *aplicația principală* și rulat pe o placă țintă FPGA.

## 5.2.1 Meta-Recunoaștere

Meta-Recunoașterea [44] este o metodă de predicție care utilizează teoria statistică a valorilor extreme (EVT) pentru analiza scorului după recunoaștere. Practic, un clasificator statistic bazat pe distribuția Weibull [44] este substanțial mai bun decât un prag standard alicat datele de scor originale. Recunoașterea poate fi asimilată cu situația datelor reale în care un clasificator respinge clasele nevăzute în momentul testării. Pentru ajustarea Weibull, se utilizează funcția FitHigh, disponibilă în biblioteca libMR [44].

Imaginile de teledetecție au nevoie de o caracterizare multi-etichet. Un extractor de caracteristici cu etichete multiple este antrenat pe clase normale  $C_i$ ,  $1 \leq i \leq k$  pentru a calcula pentru fiecare clasă  $\mu_i = \text{mean}(v_{ij})$ ,  $1 \leq i \leq k$ ,  $1 \leq j \leq |C_i|$  folosind vectorul de activare  $v$ . Cu  $S_n$  a fost notat setul de indici, în ordine descrescătoare, al celor mai mari  $n$  probabilități generate de un strat Sigmoid pe vectorul de activare  $v$ . În continuare, pentru fiecare clasă  $C_i$ , se calculează un model Weibull  $\rho_{C_i} = (\tau_{C_i}, \lambda_{C_i}, \kappa_{C_i})$ ,  $1 \leq i \leq k$  cu trei parametri, deplasarea datelor  $\tau$ , scara Weibull  $\lambda$ , respectiv forma Weibull  $\kappa$ . Parametrul  $\tau$  este dinamic și depinde de datele în sine, adică este cel mai mic scor pe vectorul de activare testat  $v$ , având ca scop deplasarea lui  $v$  în zero (5.1a). Modelul  $\rho_{C_i}(x)$  oferă o probabilitate estimată de meta-recunoaștere care determină dacă eșantionul de interogare  $x$  este anormal sau nu.

În cea de-a doua fază, activările unui eșantion de interogare  $x$  ajustează  $\alpha$  activările, adică cele mai mari  $\alpha$  probabilități de date, prin aproximarea funcției de distribuție Weibull (5.1a)

$$w_i(x) = 1 - f(i)(1 - e^{-\left(\frac{x-\tau_i}{\lambda_i}\right)^{\kappa_i}}), \quad 1 \leq i \leq k, \quad (5.1a)$$



$$f(i) = \begin{cases} \frac{\alpha+1-\text{rank}_i(S_\alpha(v))}{\alpha} & \text{if } i \in S_\alpha(v) \\ 0 & \text{otherwise} \end{cases}. \quad (5.1b)$$

După calcularea CDF Weibull pe distanța dintre eșantionul de interogare  $x$  și MAV-urile activărilor  $\alpha$ , se calculează vectorul de activare revizuit (5.2a), unde operatorul  $\circ$  este utilizat pentru produsul scalar dintre doi vectori.

$$\hat{v}(x) = v(x) \circ w(x), \quad (5.2a)$$

$$\hat{v}_{k+1}(x) = \sum_{i=1}^k v_i(x)(1 - w_i(x)). \quad (5.2b)$$

Ulterior, se calculează o pseudo-activare pentru clasa nevăzută  $C_{k+1}$ , păstrând constant nivelul total de activare (5.2b). În cele din urmă, respingerea este decisă în funcție de probabilitățile revizuite ale claselor normale  $C_i$ ,  $1 \leq i \leq k$ , în raport cu clasa anormală  $C_{k+1}$  (5.3).

$$p_i(x) = \frac{e^{\hat{v}_i(x)}}{\sum_{j=1}^{k+1} e^{\hat{v}_j(x)}}, \quad 1 \leq i \leq k+1, \quad (5.3)$$

unde  $x$  este anormal dacă  $p_{k+1}$  este cel mai mare din  $p_i$ ,  $1 \leq i \leq k+1$  sau mai mare decât un prag  $\eta$ .

## 5.2.2 Cuantificarea și compilarea modelului

Eta de cuantificare a inclus un proces de post-antrenare în care a fost utilizat un subset de 1000 de imagini de calibrare în analiza distribuției activărilor și pentru a limita degradarea preciziei. Algoritmul Data-Free Quantization (DFQ) [40] a fost utilizat în procesul de post-antrenare pentru a egaliza ponderile și pentru a corecta erorile introduse în timpul cuantificării.

## 5.3 Zone de studiu și seturi de date

### 5.3.1 Seturi de date propuse

#### Zamora

Scena Zamora conține incendii dezastruoase care au avut loc în Zamora, Spania, în iunie 2022. În Figura 5.2a este prezentată o imagine în culori false care redă părțile nevizibile ale spectrului electromagnetic.




Figura 5.2 Scena din Zamora (Spania, 2022) (a), scena din Bordeaux (Franța, 2022) (b). Formatul imaginii în culori false (R: banda 12; G: banda 11; B: banda 8A). Zonele arse sunt evidențiate în culoarea maro.

### Bordeaux

Scena din Bordeaux conține incendii devastatoare care au avut loc în Gironde, în apropiere de orașul Bordeaux. Compoziția benzilor SWIR din Figura 5.2b oferă o imagine a zonelor arse și dezvăluie zonele cu incendii în curs de desfășurare.

## 5.4 Experimente

Extractorul de caracteristici spectral-spațiale, bazat pe un model ResNet [28] cu 50 de straturi convoluționale, a fost antrenat pe versiunea curată a BigEarthNet (4.1.3), adică au fost eliminate eșantioanele complet acoperite de zăpadă sezonieră, nori și umbre de nori. Clasa *Burnt areas* a fost filtrată din versiunea curată a BigEarthNet, rezultând o nomenclatură de 42 de clase [47]. A fost adoptată regula 60:20:20 pentru alegerea aleatorie a seturilor de date de antrenare, validare și testare. După antrenarea clasificatorului multiclasă, MAV-urile au fost calculate pe setul de date de antrenament, pentru fiecare clasă, luând în considerare toate eșantioanele care au fost clasificate corect. După găsirea MAV-urilor, vectorii de distanță au fost calculați cu distanța cosinus (5.4)

$$\cos(\theta) = \frac{A \cdot B}{\|A\|_2 \|B\|_2}, \quad (5.4)$$

Tabel 5.1 Timpul de execuție a algoritmului pentru o colecție de 60 de eșantioane

Device	# threads	FPS	Run time [s]
XCZU9EG MPSoC	4	77.813 ± 1.726	0.771 ± 0.017
	8	<b>85.677 ± 0.954</b>	<b>0.700 ± 0.007</b>
Tesla K80 GPU	multithread	19.861 ± 3.252	3.128 ± 0.744

Tabel 5.2 Evaluarea acurateții detecției de anomalii pe seturi de date de test

Dataset	Device	Precision	Recall	F1-score
Zamora	Tesla K80 GPU	0.823	0.750	0.784
	XCZU9EG MPSoC	0.727	0.721	0.723
Bordeaux	Tesla K80 GPU	0.829	0.723	0.772
	XCZU9EG MPSoC	0.787	0.683	0.731

unde  $A$  este vectorul de activare al unui eșantion observat și  $B$  este MAV corespunzător clasei.

În cadrul implementării la bord, platforma țintă este o placă de evaluare Xilinx Zynq Zynq UltraScale+ MPSoC ZCU102, care combină un sistem de procesare (PS) puternic și o logică programabilă de către utilizator (PL) într-un MPSoC puternic, și anume Zynq UltraScale+ XCZU9EG-2FFVB1156E MPSoC. Acest sistem hibrid CPU-FPGA a fost programat pe fiecare parte, CPU cu logica de procesare a intrărilor și ieșirilor și FPGA cu execuția arhitecturii DCNN. Aplicația țintă este rulată pe CPU cu apeluri de aplicație către accelerator pe timpul execuției.

O linie de 60 de eșantioane este evaluată pe dispozitivul Zynq UltraScale+ XCZU9EG-2FFVB1156E MPSoC în 0,7 secunde (Tabelul 5.1). Cea mai bună performanță în timp este obținută atunci când algoritmul de detecție a anomaliilor este rulat pe dispozitivul MPSoC XCZU9EG cu 8 fire de execuție pe partea PS, obținându-se o viteză de procesare de 81,018 ns/pixel. Pe dispozitivul Tesla K80 GPU, timpul de execuție este de aproximativ 4,46x mai lent decât cel mai bun timp obținut pe dispozitivul FPGA. În plus, puterea consumată de dispozitivul Tesla K80 GPU este de 135 W, comparativ cu cea a întregii plăci Zynq UltraScale+, care este de 30 W, rezultând un factor de eficiență de 4,5 pentru dispozitivul FPGA.

În Tabelul 5.2, rezultatele algoritmului propus sunt evidențiate prin intermediul indicatorilor de Precizie, Recall și F1-score. Din cauza cuantificării, a existat o mică scădere a metricii F1-score atunci când algoritmul este rulat pe platforma embedded, și anume 0,061 pentru setul de date Zamora și 0,041 pentru setul de date Bordeaux. Pragul de anomalie  $\eta$  a fost setat la 0,5. Metrica de precizie obținută prin rularea algoritmului pe dispozitivul FPGA a fost de 0,727 pentru setul de date Zamora, respectiv, de 0,787 pentru setul de date Bordeaux.

## 5.5 Contribuții

În acest capitol, a fost proiectată o arhitectură hardware optimizată pe un dispozitiv MP-SoC încorporat, procesând toate straturile convoluționale în logica FPGA. Acceleratorul propus a atins o viteză de procesare de 0,7 secunde pentru 60 de eșantioane, ceea ce este de aproximativ 4,46x mai rapid și de 4,5x mai eficient din punct de vedere energetic decât implementarea GPU.

# Capitolul 6

## Concluzii

### 6.1 Contribuții originale

În cele ce urmează, sunt enumerate principalele contribuții originale ale tezei:

- Elaborarea a două modele fără parametri, bazate pe compresia datelor, care extrag caracteristici condiționate și imparțiale din serii bi-temporale pentru a determina hărți de schimbare binare [C1, J1, J5];
- Dezvoltarea a două abordări de detecție a anomaliilor bazate pe învățare profundă care identifică eșantioanele deviate de la distribuția de probabilitate normală a datelor, respectiv suprimă reconstrucția anomaliilor, în imagini multispectrale [C3, J2];
- Un nou model statistic de detectare a anomaliilor, dezvoltat și optimizat pentru un dispozitiv FPGA, care estimează probabilitatea ca un eșantion multispectral să aparțină unei clase anormale [J3, J4].

### 6.2 Lista publicațiilor originale

#### 6.2.1 Jurnale

[J1] **M. Coca**, A. Anghel and M. Datcu, "Unbiased Seamless SAR Image Change Detection Based on Normalized Compression Distance," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 12, no. 7, pp. 2088-2096, July 2019, doi: 10.1109/JSTARS.2019.2909143. (**Impact Factor:3.784 - Q2**)

[J2] **M. Coca**, I. Coca Neagoe and M. Datcu, "Hybrid DNN-Dirichlet Anomaly Detection and Ranking: Case of Burned Areas Discovery," in IEEE Transactions on Geoscience and Remote Sensing, vol. 60, pp. 1-16, 2022, Art no. 4414116, doi: 10.1109/TGRS.2022.3207311. (**Impact Factor:5.6 - Q1**)

[J3] **M. Coca** and M. Datcu, "FPGA Accelerator for Meta-Recognition Anomaly Detection: Case of Burned Area Detection," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing (under review).

[J4] Cavallaro, Gabriele and B. Heras, Dora and Wu, Zebin and Maskey, Manil and Lopez, Sebastian and Gawron, Piotr and **Coca, Mihai** and Datcu, Mihai, "High-Performance and Disruptive Computing in Remote Sensing: HDCRS—A new Working Group of the GRSS Earth Science Informatics Technical Committee [Technical Committees]," in IEEE Geoscience and Remote Sensing Magazine, vol. 10, no. 2, pp. 329-345, June 2022, doi: 10.1109/MGRS.2022.3145478. (**Impact Factor:7.741 - Q1**)

[J5] Mihai Stoica and **Mihai Coca**, "GPU-Based Normalized Compression Distance for Satellite Images," in Journal of Military Technology, vol. 5, no. 1, pp. 49-54, July 2022, doi: 10.32754/JMT.2022.1.07.

### 6.2.2 Lucrări conferințe

[C1] **M. Coca**, A. Anghel and M. Datcu, "Normalized Compression Distance for SAR Image Change Detection," IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, 2018, pp. 5784-5787, doi: 10.1109/IGARSS.2018.8518126.

[C2] **M. Coca**, I. Neagoe and M. Datcu, "Physically Meaningful Dictionaries for EO Crowdsourcing: A ML for Blockchain Architecture," IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium, 2020, pp. 3688-3691, doi: 10.1109/IGARSS39084.2020.9324361.

[C3] **M. Coca** and M. Datcu, "Anomaly Detection in Post Fire Assessment," 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, 2021, pp. 8620-8623, doi: 10.1109/IGARSS47720.2021.9554169.

## 6.3 Perspective pentru evoluții viitoare

În cele ce urmează, sunt enumerate principalele perspective viitoare ale acestei teze:

- Integrarea metodelor propuse și rulate la sol în serviciile de gestionare a hazardelor naturale, cum ar fi Serviciul Copernicus de gestionare a situațiilor de urgență;
- Dezvoltarea unor metode de detecție a anomaliilor care utilizează fuziunea datelor multisenzoriale pentru a evita obstacolele întâlnite de instrumentele optice;
- Îmbunătățirea metodei propuse pentru detectarea anomaliilor la bord prin creșterea gradului de utilizare a dispozitivului FPGA.

# Bibliografie

- [1] Bendale, A. and Boulton, T. (2016). Towards Open Set Deep Networks. In *Computer Vision and Pattern Recognition (CVPR), 2016 IEEE Conference on*. IEEE.
- [2] Bennett, C., Gacs, P., Li, M., Vitányi, P., and Zurek, W. (1998). Information distance. *IEEE Transactions on Information Theory*, 44(4):1407–1423.
- [3] Bovolo, F. and Bruzzone, L. (2007). A split-based approach to unsupervised change detection in large-size multitemporal images: Application to tsunami-damage assessment. *IEEE Transactions on Geoscience and Remote Sensing*, 45(6):1658–1670.
- [4] Caba, J., Díaz, M., Barba, J., Guerra, R., Escolar, S., and López, S. (2022). Low-power hyperspectral anomaly detector implementation in cost-optimized fpga devices. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15:2379–2393.
- [5] Cebrian, M., Alfonseca, M., and Ortega, A. (2007). The normalized compression distance is resistant to noise. *IEEE Transactions on Information Theory*, 53(5):1895–1900.
- [6] Chalapathy, R. and Chawla, S. (2019). Deep learning for anomaly detection: A survey. *arXiv:1901.03407*.
- [7] Chuvieco, E. (2016). *Fundamentals of Satellite Remote Sensing: An Environmental Approach*. Number 2nd Edition in -. Boca Raton, CRC Press.
- [8] Cilibrasi, R., Cruz, A. L., de Rooij, S., and Keijzer, M. (2008). Complearn. <https://complearn.org/index.html>. [Online; Accessed Oct. 15, 2022].
- [9] Cilibrasi, R. and Vitányi, P. (2005). Clustering by compression. *IEEE Transactions on Information Theory*, 51(4):1523–1545.
- [10] Coca, M., Anghel, A., and Datcu, M. (2019). Unbiased Seamless SAR Image Change Detection Based on Normalized Compression Distance. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(7):2088–2096.
- [11] Coca, M. and Datcu, M. (2021). Anomaly Detection in Post Fire Assessment. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, pages 8620–8623.
- [12] Copernicus (2012). Emergency Management Service. <https://emergency.copernicus.eu/index.html>. [Online; Accessed Nov. 11, 2022].
- [13] DLR (2020). TerraSAR-X - Germany's radar eye in space. <https://www.dlr.de/content/en/articles/missions-projects/terrasar-x/terrasar-x-earth-observation-satellite.html>. [Online; Accessed Nov. 12, 2022].

- [14] Du, B. and Zhang, L. (2014). A discriminative metric learning based anomaly detection method. *IEEE Transactions on Geoscience and Remote Sensing*, 52(11):6844–6857.
- [15] Du, Q., Tang, B., Xie, W., and Li, W. (2021). Parallel and distributed computing for anomaly detection from hyperspectral remote sensing imagery. *Proceedings of the IEEE*, 109(8):1306–1319.
- [16] Dumitru, C. O., Cui, S., Faur, D., and Datcu, M. (2015). Data analytics for rapid mapping: Case study of a flooding event in germany and the tsunami in japan using very high resolution sar images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(1):114–129.
- [17] Dumitru, C. O. and Datcu, M. (2013). Information content of very high resolution sar images: Study of feature extraction and imaging parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 51(8):4591–4610.
- [18] Dumitru, C. O., Schwarz, G., and Datcu, M. (2018). Sar image land cover datasets for classification benchmarking of temporal changes. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5):1571–1592.
- [19] Díaz, M., Guerra, R., Horstrand, P., López, S., and Sarmiento, R. (2019). A line-by-line fast anomaly detector for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 57(11):8968–8982.
- [20] Esposito, M. and Marchi, A. Z. (2019). In-orbit demonstration of the first hyperspectral imager for nanosatellites. In *International Conference on Space Optics—ICSO 2018*, volume 11180, pages 760–770. SPIE.
- [21] European Space Agency (ESA) (2014). Resolution and Swath. <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/instrument-payload/resolution-and-swath>. [Online; Accessed Aug. 5, 2022].
- [22] European Space Agency (ESA) (2020). Phi-sat Artificial Intelligence for Earth Observation. [https://www.esa.int/Applications/Observing\\_the\\_Earth/Ph-sat](https://www.esa.int/Applications/Observing_the_Earth/Ph-sat). [Online; Accessed Nov. 9, 2022].
- [23] Frost, O. (1972). An algorithm for linearly constrained adaptive array processing. *Proceedings of the IEEE*, 60(8):926–935.
- [24] Gawlikowski, J., Saha, S., Kruspe, A., and Zhu, X. X. (2022). An advanced dirichlet prior network for out-of-distribution detection in remote sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 60:1–19.
- [25] Geiger, D. and Heckerman, D. (1996). A characterization of the Dirichlet distribution with application to learning Bayesian networks. In *Maximum entropy and Bayesian methods*, pages 61–68. Springer, Dordrecht.
- [26] Giuffrida, G., Diana, L., de Gioia, F., Benelli, G., Meoni, G., Donati, M., and Fanucci, L. (2020). Cloudscout: A deep neural network for on-board cloud detection on hyperspectral images. *Remote Sensing*, 12(14).
- [27] Giuffrida, G., Fanucci, L., Meoni, G., Batič, M., Buckley, L., Dunne, A., van Dijk, C., Esposito, M., Hefele, J., Vercruyssen, N., Furano, G., Pastena, M., and Aschbacher, J. (2022). The phi-sat-1 mission: The first on-board deep neural network demonstrator for satellite earth observation. *IEEE Transactions on Geoscience and Remote Sensing*, 60:1–14.

- [28] He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 770–778.
- [29] International Chapter Space and Major Disasters (March 28, 2013). Charter Brochure. <https://disasterscharter.org/documents/10180/187832/charterbrochure28032013.pdf>. [Online; Accessed Nov. 9, 2022].
- [30] Kapur, J., Sahoo, P., and Wong, A. (1985). A new method for gray-level picture thresholding using the entropy of the histogram. *Computer Vision, Graphics, and Image Processing*, 29(3):273–285.
- [31] Kittler, J. and Illingworth, J. (1986). Minimum error thresholding. *Pattern Recognition*, 19(1):41–47.
- [32] Kolesnikov, A., Zhai, X., and Beyer, L. (2019). Revisiting Self-Supervised Visual Representation Learning. In *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1920–1929.
- [33] Li, M., Chen, X., Li, X., Ma, B., and Vitányi, P. (2004). The similarity metric. *IEEE Transactions on Information Theory*, 50(12):3250–3264.
- [34] Li, M. and Vitányi, P. (1997). *An Introduction to Kolmogorov Complexity and Its Applications*. Berlin, Germany: Springer-Verlag.
- [35] Li, W. and Du, Q. (2015). Collaborative representation for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 53(3):1463–1474.
- [36] Makhzani, A., Shlens, J., Jaitly, N., Goodfellow, I., and Frey, B. (2016). Adversarial autoencoders. arXiv:1511.05644.
- [37] Masek, J. G., Wulder, M. A., Markham, B., McCorkel, J., Crawford, C. J., Storey, J., and Jenstrom, D. T. (2020). Landsat 9: Empowering open science and applications through continuity. *Remote Sensing of Environment*, 248:111968.
- [38] Minka, T. (2000). Estimating a dirichlet distribution.
- [39] Muhuri, A., Ratha, D., and Bhattacharya, A. (2017). Seasonal snow cover change detection over the indian himalayayas using polarimetric sar images. *IEEE Geoscience and Remote Sensing Letters*, 14(12):2340–2344.
- [40] Nagel, M., van Baalen, M., Blankevoort, T., and Welling, M. (2019). Data-free quantization through weight equalization and bias correction.
- [41] Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1):62–66.
- [42] Planinšič, P. and Gleich, D. (2018). Temporal change detection in sar images using log cumulants and stacked autoencoder. *IEEE Geoscience and Remote Sensing Letters*, 15(2):297–301.
- [43] Rostami, A., Shah-Hosseini, R., Asgari, S., Zarei, A., Aghdami-Nia, M., and Homayouni, S. (2022). Active fire detection from landsat-8 imagery using deep multiple kernel learning. *Remote Sensing*, 14(4).
- [44] Scheirer, W. J., Rocha, A., Micheals, R. J., and Boulton, T. E. (2011). Meta-recognition: The theory and practice of recognition score analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(8):1689–1695.



- [45] Stoica, M. and Coca, M. (2022). GPU-Based Normalized Compression Distance for Satellite Images. *Journal of Military Technology*, 5(1):49–54.
- [46] Sumbul, G., Charfuelan, M., Demir, B., and Markl, V. (2019). Bigearthnet: A Large-Scale Benchmark Archive for Remote Sensing Image Understanding. In *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, pages 5901–5904.
- [47] Sumbul, G., de Wall, A., Kreuziger, T., Marcelino, F., Costa, H., Benevides, P., Caetano, M., Demir, B., and Markl, V. (2021). BigEarthNet-MM: A large-scale, multimodal, multilabel benchmark archive for remote sensing image classification and retrieval [software and data sets]. *IEEE Geoscience and Remote Sensing Magazine*, 9(3):174–180.
- [48] Verbesselt, J., Zeileis, A., and Herold, M. (2012). Near real-time disturbance detection using satellite image time series. *Remote Sensing of Environment*, 123:98–108.
- [49] Vincenzi, S., Porrello, A., Buzzega, P., Cipriano, M., Fronte, P., Cuccu, R., Ippoliti, C., Conte, A., and Calderara, S. (2021). The color out of space: learning self-supervised representations for earth observation imagery. In *2020 25th International Conference on Pattern Recognition (ICPR)*, pages 3034–3041, Los Alamitos, CA, USA. IEEE Computer Society.
- [50] Wicker, N., Muller, J., Kalathur, R. K. R., and Poch, O. (2008). A maximum likelihood approximation method for Dirichlet’s parameter estimation. *Computational Statistics and Data Analysis*, 52:1315–1322.
- [51] Xia, Y., Cao, X., Wen, F., Hua, G., and Sun, J. (2015). Learning Discriminative Reconstructions for Unsupervised Outlier Removal. In *2015 IEEE International Conference on Computer Vision (ICCV)*, pages 1511–1519.
- [52] Xilinx (2021). Zynq ultrascale+ mpsoc data sheet: Overview (ds891), v1.9. <https://docs.xilinx.com/v/u/en-US/ds891-zynq-ultrascale-plus-overview>. [Online; Accessed Nov. 22, 2022].
- [53] Xilinx (2022). DPUCZDX8G for Zynq UltraScale+ MPSoCs Product Guide (PG338). <https://docs.xilinx.com/r/en-US/pg338-dpu/Introduction?tocId=Bd4R4bhnWgMYE6wUISXDLw>. [Online; Accessed Nov. 22, 2022].
- [54] Xiong, B., Chen, Q., Jiang, Y., and Kuang, G. (2012). A threshold selection method using two sar change detection measures based on the markov random field model. *IEEE Geoscience and Remote Sensing Letters*, 9(2):287–291.
- [55] Zhang, L., Peng, B., Zhang, F., Wang, L., Zhang, H., Zhang, P., and Tong, Q. (2017). Fast real-time causal linewise progressive hyperspectral anomaly detection via cholesky decomposition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(10):4614–4629.
- [56] Zhao, W., Wang, Z., Gong, M., and Liu, J. (2017). Discriminative feature learning for unsupervised change detection in heterogeneous images based on a coupled neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 55(12):7066–7080.