



UNIVERSITATEA NAȚIONALĂ DE
ȘTIINȚĂ ȘI TEHNOLOGIE
POLITEHNICA BUCUREȘTI (UNSTPB)



Școala Doctorală de Electronică, Telecomunicații
și Tehnologia Informației

Decizie nr. 142 din 22-11-2023

REZUMAT TEZĂ DE DOCTORAT

Ing. Omid GHOZATLOU

ÎNVĂȚAREA CU ESANTIOANE ADVERSARIALE
PENTRU IMAGINI SATELITARE
MULTISPECTRALE
LEARNING WITH ADVERSARIAL SAMPLES FOR
EARTH OBSERVATION MULTISPECTRAL
IMAGES

COMISIA DE DOCTORAT

Prof. Dr. Ing. Gheorghe BREZEANU UNSTPB	Președinte
Prof. Dr. Ing. Mihai DATCU UNSTPB	Conducător de doctorat
Prof. Dr. Ing. Mihai CIUC UNSTPB	Referent
Prof. Dr. Ing. Cosmin ANCUTI Univ. Politehnica din Timisoara	Referent
Dr. Ing. Miguel HEREDIA CONDE University of Siegen	Referent

BUCUREȘTI 2023

Cuprins

1. Introducere	1
1.2. Scopul tezei	1
2. Învățarea activă (AL)	3
2.1. Provocări și soluții profunde AL.....	4
2.2. Comparația performanțelor de clasificare.....	6
2.3. Rezultate.....	7
2.4. Concluzie.....	8
3. Interogare după exemplu pentru preluarea imaginilor RS.....	11
3.1. Rezultate.....	13
3.2. Concluzie.....	13
4. DNN-uri conștient de fizic.....	15
4.1 GAN conștient de fizică pentru eliminarea în cloud	16
4.2. Rezultate.....	17
4.3. Concluzie.....	18
5. Generarea de imagini sintetice de către GAN-uri.....	19
5.1 De ce date sintetice?	19
5.2 De ce analiza imaginilor oceanice?.....	20
5.3 StyleGAN2 cu ADA	21
6. Concluzii	23
6.1. Contribuții originale	23
6.2. Lista lucrărilor originale	25
6.3. Perspective de dezvoltare ulterioară	26
Bibliografie	27

Capitolul 1

Introducere

Termenul „Observare a Pământului” (EO) este o componentă critică a teledetecției (RS), permițându-ne să înțelegem și să supraveghem mediul complex și în continuă schimbare al planetei noastre. Aceasta implică obținerea de informații despre suprafața și atmosfera Pământului de la diverși senzori poziționați pe sateliți, avioane, drone și platforme de la sol. În plus, joacă un rol crucial în monitorizarea și gestionarea unei game de aplicații, cum ar fi agricultura, silvicultură, planificarea urbană, pregătirea pentru dezastre, monitorizarea climei și conservarea mediului.

De-a lungul anilor, EO a evoluat semnificativ, condusă de progresele tehnologice, sistemele prin satelit și metodele de analiză a datelor. Recent, încorporarea tehnicilor de învățare profundă (DL) a revoluționat EO prin extragerea de informații valoroase din colecția vastă și în expansiune de imagini ale Pământului, cu creșterea continuă a numărului de sateliți de observare a Pământului și disponibilitatea de înaltă rezoluție, multispectrale și hiperspectrale. imaginilor, volumul datelor EO crește cu o rată fără precedent. Această creștere a datelor a prezentat atât noi provocări, cât și oportunități pentru cercetători, care se bazează tot mai mult pe DL ca un instrument puternic pentru a debloca potențialul neexploatat din aceste seturi de date.

Integrarea tehnicilor DL cu EO a extins frontierele pentru a culege informații valoroase din colecția extinsă și în continuă expansiune de imagini ale Pământului. Această dezvoltare a dus la crearea de aplicații inovatoare în monitorizarea populației, managementul dezastrelor și conservarea mediului. În plus, utilizarea imaginilor EO a avut un impact asupra societății și asupra politicilor, conducând la formularea unor cadre de reglementare inovatoare și cuprinzătoare, menite să echilibreze interesele publice și private în EO bazate pe spațiu.

1.1 Scopul tezei

În această teză, prezentăm noi soluții pentru a aborda această problemă. Ne concentrăm pe patru strategii care vor fi discutate mai detaliat în capitolele următoare. Aceste soluții includ învățare activă (AL), interogare prin exemplu, modele profunde conștiente de fizică și rețele generative adverse (GAN). AL poate aborda problema eşantioanelor adverse în clasificarea imaginilor RS prin selectarea iterativă a celor mai informative eşantioane pentru a îmbunătăți performanța modelului. Această

abordare ajută modelul să înțeleagă mai bine structura și proprietățile de bază ale datelor, făcându-l mai rezistent la atacurile adverse și îmbunătățind performanța generală.

O altă strategie pe care o studiem în această teză este Query-by-Example pentru regăsirea imaginilor RS. Această strategie își propune să găsească cea mai asemănătoare imagine cu interogarea și să optimizeze ponderile rețelei, astfel încât eșantioanele adverse să fie departe de imaginea interogării în spațiul latent. În acest fel, rețeaua va înțelege mostrele similare de interogare și nu va fi vulnerabilă împotriva eșantioanelor adverse.

O altă soluție este ghidarea DNN prin utilizarea proprietăților statistice ale datelor sau injectarea proprietăților fizice ale datelor în model. În general, modelele profunde conștiente de fizică pot aborda problema eșantioanelor adverse în clasificarea imaginilor RS și pot face modelul mai rezistent la atacurile adverse prin includerea cunoștințelor fizice în procesul de învățare. GAN-urile sunt un tip de model DL care constă din două rețele neuronale, un generator și un discriminator, care sunt antrenate împreună într-un proces cunoscut sub numele de antrenament adversar. Generatorul creează mostre sintetice, în timp ce discriminatorul încearcă să facă distincția între probele reale și cele sintetice. GAN-urile pot fi utilizate pentru a genera mostre adverse pentru analiza imaginilor RS, care pot fi apoi utilizate pentru a îmbunătăți robustețea modelului de clasificare împotriva atacurilor adverse

Capitolul 2

Învățarea activă (AL)

ML joacă un rol crucial în procesarea imaginii RS și a demonstrat beneficii impresionante pentru multe aplicații, cum ar fi analiza imaginii RS. În special, DNN a arătat proprietăți interesante pe seturile de date de imagine și sunt eficiente în extragerea caracteristicilor intrinseci de nivel înalt și clasificarea problemelor complexe. Una dintre cele mai provocatoare probleme ale algoritmilor ML este etichetarea datelor, deoarece antrenarea unui DNN este costisitoare și necesită un număr mare de mostre de antrenament. În RS, obținerea datelor etichetate poate fi costisitoare, consumatoare de timp sau chiar imposibilă.

O modalitate eficientă de a rezolva această problemă este prin AL, care poate fi folosit pentru a valorifica cantități mici de date etichetate. AL este un concept important în ML și are semnificație în analiza imaginii RS. AL se referă la o strategie de selecție pentru achiziționarea de date etichetate care permite algoritmului ML să selecteze în mod activ ce mostre să eticheteze, pentru a îmbunătăți performanța modelului cu mai puține date etichetate. Etichetarea selectivă a mostrelor îmbunătățește performanța algoritmilor ML în sarcini precum clasificarea sau segmentarea, fără a necesita cantități mari de date etichetate.

Această selecție se face printr-o strategie de interogare care oferă utilizatorului cele mai informative sau reprezentative mostre dintr-un set de date neetichetate. Pentru reantrenarea modelului, operatorul va reeticheta mostrele selectate și le va adăuga la setul de antrenament. Prin urmare, antrenăm modelul în mod interactiv, cu mai puține mostre de antrenament decât metodele tradiționale de învățare pasivă ML. De asemenea, este mai eficient (reducerea costului de adnotare) deoarece folosește mostre care sunt mai utile pentru învățare.

În acest capitol, folosim ResNet18 ca clasificator pentru a compara atât strategiile clasice cât și cele de ultimă oră în cadrul aceluiași cadru. Sunt utilizate cinci metode de vârf AL profunde, dintre care cea mai recentă nu a fost testată niciodată pe date RS. De asemenea, propunem o nouă măsurătoare de performanță AL bazată pe numărul de mostre etichetate. Folosim strategia de eșantionare aleatorie ca bază și comparăm performanța strategiilor cu acuratețea maximă obținută de linia de bază. Această măsurătoare nouă calculează câte eșantioane mai puține etichetate sunt necesare pentru o anumită strategie de eșantionare pentru a obține aceeași acuratețe maximă ca o strategie de eșantionare aleatorie. În cele din urmă, studiile de ablație au fost efectuate pe patru clasificatoare diferite și dimensiuni de interogare AL lotului. Acest studiu discută o revizuire a AL în RS pentru diverse aplicații. Sunt apoi

discutate provocările combinării DL și AL și sunt oferite soluții profunde pentru AL. În cea de-a treia secțiune, este prezentată o comparație între strategiile AL clasice și cele profunde. În cele din urmă, sfera de aplicare și perspectiva viitoare a AL în RS sunt discutate.

2.1 Provocări și soluții profunde AL

În ultimul deceniu, modelele DL au demonstrat o pricepere remarcabilă în procesarea semnalului. Valorificându-și capacitatea de a capta caracteristici ierarhice din diverse tipuri de date - cum ar fi numerice, imagini, text și audio - modelele DL au apărut ca soluții puternice pentru sarcini care acoperă probleme de recunoaștere, regresie, semi-supravegheate și nesupravegheate. Trăsăturile distinctive îl deosebesc pe Deep AL (DAL) de AL tradițional. În primul rând, DAL utilizează interogare de eșantioane bazată pe loturi, o abatere de la metoda de interogare unu câte unul utilizată în mod obișnuit în algoritmi AL tradiționali. Această schimbare nu numai că reduce recalificarea frecventă a modelului, dar abordează și variația limitată a datelor de antrenament, o preocupare care poate exacerba supraadaptarea. În al doilea rând, în timp ce AL clasică folosește adesea algoritmi tradiționali ML, cum ar fi SVM, DAL implică cursanți DL, cum ar fi CNN-urile. Această adaptare a fost examinată în diferite arhitecturi DL, inclusiv CNN-uri bayesiene și mașini Boltzmann restricționate stivuite, pentru clasificarea imaginilor și a textului. Este de remarcat faptul că majoritatea metodologiilor DAL propuse depășesc în mod constant eșantionarea aleatoare cu o marjă substanțială, indiferent de strategia bazată pe incertitudine și clasificatorul folosit.

DAL este o abordare inovatoare și complicată care încearcă să valorifice punctele forte ale metodologiilor DL și AL. Integrarea AL cu arhitecturi profunde, cum ar fi CNN-urile, prezintă provocări. Tehnicile AL se bazează în principal pe funcții probabilistice care analizează distribuția probabilității unui eșantion de apartinență la clase existente. Acest lucru se confruntă cu majoritatea arhitecturilor DL, care de obicei produc etichete de clasă precise în loc de probabilități de clasă, deoarece le lipsește o mapare inerentă a incertitudinii. Pentru a aborda această dilemă, anumite studii valorifică proprietățile rețelelor bayesiene și concep rețelele neuronale bayesiene (BNN) pentru a obține distribuții de probabilitate pe ponderile rețelei. De exemplu, în [51], un BNN este introdus pentru a extrage o matrice de probabilitate de ieșire din datele de intrare. Această matrice facilitează aplicarea funcției probabilistice a lui AL, oferind estimări ale incertitudinii și o interpretare probabilistică a modelelor DL prin inferențe ale distribuțiilor de ponderi. Mai mult, în domeniul monitorizării seismo-vulcanice introduce un CNN temporal bayesian (B-TCN) pentru detectarea și clasificarea continuă a evenimentelor. Acest cadru extrage eficient cele mai incerte evenimente din fluxurile continue de date. În esență, DAL reprezintă o convergență dinamică a metodologiilor DL și AL, valorificând punctele forte complementare ale acestora. Incorporarea rețelelor neuronale bayesiene și a arhitecturilor inovatoare exemplifică pașii făcuți pentru a depăși provocările combinării acestor două

paradigme, deschizând în cele din urmă căi pentru luarea deciziilor mai informate și mai robuste în domenii complexe precum monitorizarea seismo-vulcanică.

În plus, tărâmul martorilor AL se străduiește să perfecționeze procesul AL prin fuziunea diverselor criterii. Un exemplu notabil care introduce un algoritm AL inovator care maximizează două criterii de selecție — eșantionarea reprezentativă și cea de incertitudine. Acest algoritm se desfășoară în două etape: în primul rând, un proces de învățare a caracteristicilor nesupravegheat creează un dicționar incremental ponderat bazat pe datele de antrenament, facilitând estimarea reprezentativității datelor; ulterior, faza de învățare supravegheată folosește acest cadru pentru a estima incertitudinea datelor. Abordând provocarea datelor limitate de antrenament etichetate de înaltă calitate, studiile recente se orientează către tehnici semi-supravegheate. Astfel de tehnici generează pseudo-etichete dintr-un set mic de exemple etichetate, care, la rândul lor, îmbogățește setul de antrenament etichetat. În special, modelele ML pot prezenta predicții sigure, dar incorecte, în special atunci când setul de date de antrenament nu reușește să descrie spațiul latent.

O abordare alternativă pentru a aborda deficitul de date etichetate în DAL este prin GAN-uri, utilizate frecvent pentru a sintetiza mostre de antrenament. AL adversar câștigă tracțiune în acest cadru. De exemplu, [59] lansează o strategie AL adversativă orientată pe caracteristici, utilizând caracteristici de nivel înalt dintr-un strat intermediar al unui clasificator DL pentru a stabili o euristică de achiziție bazată pe GAN. Mai mult, [32] introduce o nouă schemă activă de extracție a caracteristicilor profunde, care încorporează atât criterii reprezentative, cât și informative. Un autoencoder adversar adaptat servește ca pas inițial pentru a facilita extragerea caracteristicilor profunde specifice clasificării. Încorporarea învățării dicționarului și a unei măsuri de distanță cu variații multiple și distribuționale ghidează selecția eșantioanelor valoroase de formare a candidaților.

În căutarea îmbunătățirii performanței DAL, modificările funcției de pierdere sau implementarea metodelor de ansamblu profund vin în prim-plan. Un modul suplimentar este adesea încorporat pentru a îmbunătăți performanța modelului țintă și pentru a ghida selecțiile DAL. O astfel de abordare implică prezicerea cazurilor în care modelul țintă ar putea greși prin introducerea unui model de predicție a pierderilor alături de modelul principal țintă. În plus, un studiu construiește o rețea profundă auxiliară pentru cursantul de bază, dedicată învățării incertitudinii eșantioanelor neetichetate din setul de date candidat. Converghând caracteristicile datelor de antrenament originale și cele ale stratului ascuns intermediar al cursantului de bază, este concepută o rețea complet conectată, susținută de o nouă funcție de pierdere adaptată sarcinii.

În rezumat, cercetătorii inovează pe diverse fronturi pentru a amplifica eficacitatea DAL. Aceste strategii cuprind combinații complicate de criterii de selecție, integrarea tehnicilor semi-supravegheate, exploatarea GAN-urilor și AL adversarilor și creșterea modelelor țintă prin diverse module suplimentare. Aceste abordări pe mai multe direcții contribuie în mod colectiv la evoluția DAL, prezentând un peisaj nuanțat de tehnici pentru a face față provocărilor și a-și avansa capacitățile.

2.2 Compararea performanțelor de clasificare

În această secțiune, prezentăm în detaliu nouă strategii de interogare. Aceste strategii se bazează în mare parte pe incertitudine și urmăresc să selecteze noi eșantioane de date care să reducă la maximum incertitudinea la cursanții de bază.

{Entropie}

Entropia maximă selectează instanțe pe baza entropiei distribuției de predicție a modelului. Se bazează pe ideea că cazurile pentru care modelul are entropie ridicată, adică cazurile pentru care modelul este incert cu privire la eticheta corectă, sunt susceptibile să ofere cele mai multe informații pentru îmbunătățirea modelului.

{Cel mai puțin încrezător}

Least Confidence este o strategie de interogare AL bazată pe incertitudine care selectează cazurile pentru care modelul este cel mai puțin încrezător. Cu alte cuvinte, modelul selectează cazurile pentru care are cea mai mare incertitudine în predicțiile sale. Modelul clasifică instanțele după scorurile lor de încredere în predicție, iar instanțele cu cele mai mici scoruri sunt selectate pentru etichetare.

{Marja}

Margin Sampling selectează instanțe pentru etichetare pe baza diferenței dintre probabilitatea maximă prezisă a modelului și a doua cea mai mare probabilitate prezisă. Ideea este că cazurile cu o marjă mare între probabilitatea maximă și a doua cea mai mare probabilitate prezisă sunt susceptibile să ofere cele mai multe informații pentru îmbunătățirea modelului.

{Mean Std.}

Mean Std. se bazează pe abaterea standard a probabilităților prezise ale modelului pentru fiecare clasă. Se bazează pe ideea că cazurile pentru care probabilitățile prezise ale modelului au o abatere standard mare este probabil să ofere cele mai multe informații pentru îmbunătățirea modelului. Maximizează media abaterii standard a probabilităților prezise pentru toate clasele.

{CHEL}

Batch Bayesian AL by Disagreements (BALD) este o aproximare practică a informațiilor reciproce între un lot de puncte și parametrii modelului. Această aproximare servește ca funcție de achiziție, permițând selecția comună a mai multor puncte informative în contextul învățării active bayesiene profunde. BALD se concentrează pe alegerea punctelor de date așteptate pentru a maximiza informațiile obținute din parametrii modelului, în special informațiile reciproce dintre predicții și modelul posterior.

{BADGE}

Batch AL by Diverse Gradient Embeddings (BADGE) folosește diverse înglobări de gradient pentru a capta variabilitatea predicțiilor unui model. Selectează un subset divers de eșantioane care se întinde pe spațiul de încorporare, măsurând incertitudinea ca magnitudinea gradientului privind parametrii din stratul de ieșire. Acest calcul se bazează pe eticheta cea mai probabilă conform modelului. Obiectivul BADGE este de

a reduce redundanța și de a spori diversitatea eșantioanelor selectate, contribuind la eficiența și eficacitatea procesului de învățare activă.

{VAAL}

Variational Adversarial AL (VAAL) este un algoritm AL care combină autoencodere variaționale (VAE) și antrenament adversarial pentru a selecta mostre informative pentru adnotare. Utilizează VAE pentru a modela distribuția datelor și pentru a genera noi eșantioane care sunt apropiate de datele reale, iar antrenamentul adversar pentru a discrimina între eșantioanele reale și cele generate. VAAL selectează apoi cele mai informative eșantioane pe baza unei măsuri de incertitudine și diversitate și le folosește pentru a actualiza modelul. Combinând VAE și antrenamentul adversar, VAAL poate genera mostre diverse și informative, iar procesul AL poate fi mai eficient și mai eficient. S-a demonstrat că VAAL depășește câțiva alți algoritmi AL de ultimă generație pe diferite seturi de date de referință.

{WAAL}

Wasserstein Adversarial AL (WAAL) oferă perspective teoretice prin încadrarea procesului interactiv în Active Learning (AL) ca potrivire de distribuție, utilizând distanța Wasserstein. În această metodă, sunt alese și încorporate în setul de antrenament eșantioane informative dificil de clasificat pentru modelul actual pentru a îmbunătăți performanța modelului. Selecția celor mai informative eșantioane implică o combinație de măsuri de incertitudine și diversitate. Distanța Wasserstein este apoi utilizată pentru a identifica exemple care maximizează diferența dintre distribuțiile prezise și adevărate, făcându-le mai probabil să fie informative. Utilizarea distanței Wasserstein permite WAAL să genereze mai multe eșantioane informative și diverse, îmbunătățind astfel eficiența și eficacitatea procesului AL. WAAL a demonstrat performanțe superioare în comparație cu câțiva alți algoritmi AL de ultimă generație în diferite seturi de date de referință.

{LPL}

Loss Prediction Loss (LPL) este o strategie din 2019 care încorporează un mic modul parametric într-un model țintă. Acest modul este antrenat pentru a prezice pierderea intrărilor neetichetate referitoare la modelul țintă. Ulterior, modulul poate recomanda date pentru care modelul țintă este predispus să facă predicții incorecte. Obiectivul acestei abordări este de a îmbunătăți performanța modelului țintă prin valorificarea predicțiilor modulului de predicție a pierderilor.

2.3 Rezultate

În evaluarea strategiilor de învățare activă (AL), ResNet este folosit ca clasificator, iar AUBC, acuratețea finală și valorile LDN sunt prezentate atât pentru EuroSAT (RGB) cât și pentru EuroSAT (MS). Setul de date este împărțit uniform în 50% seturi de antrenament și 50% seturi de testare. Rezultatele sunt prezentate în Tabelul 1 când $M=500$ și $Q=10000$. Strategiile AL convenționale arată în mod constant performanțe cu 1% până la 3% mai mari în comparație cu selecția aleatorie în ceea ce privește AUBC. Dintre acestea, Entropia prezintă cea mai mare AUBC (76,01%) și precizie

finală (88,57%). Mean Std. de asemenea, se comportă deosebit de bine. Strategiile DAL (Diversitatea în învățare activă), precum VAAL și LPL, ating valori și mai mari ale AUBC, în jur de 80%. WAAL și BALD depășesc, de asemenea, strategiile convenționale, cu valori AUBC de 77,8% și, respectiv, 76,18%. În ceea ce privește acuratețea finală, toate strategiile DAL depășesc strategiile convenționale. LPL, VAAL și WAAL obțin acuratețe finale de 94,12%, 92,98% și, respectiv, 92,66% - reprezentând o precizie cu peste 7% mai mare decât Random după epuizarea Q. Alte strategii, cum ar fi BALD și BADGE, ating, de asemenea, o acuratețe finală mai mare, în jur de 90% și, respectiv, 89%. Printre strategiile convenționale, Entropia și Mean Std. depășesc marja și cel mai puțin încrezător în setul de date EuroSAT (RGB). Pe scurt, strategiile AL avansate, în special tehnicile DAL, îmbunătățesc considerabil acuratețea și eficiența în diferite seturi de date.

După cum sa discutat mai devreme, metrica LDN elucidează procentul de date etichetate necesare pentru a obține performanța optimă obținută prin eșantionarea aleatorie. Valorile LDN mai mici denotă performanțe superioare. Tabelul 2.2 prezintă eficiența convingătoare a anumitor strategii. VAAL și LPL, de exemplu, necesită doar 50% din Q în comparație cu Random, permițându-le să atingă precizia maximă a Random cu doar jumătate din bugetul de etichetare. În mod similar, WAAL și BALD prezintă valori LDN reduse în comparație cu strategiile AL convenționale. Când se compară media LDN din strategiile convenționale (75,25%) cu cea a strategiilor DAL (63,85%), apare o revelație: strategiile DAL necesită aproximativ 12% mai puține date pentru a atinge acuratețea maximă a Random. În special, în timp ce BADGE se mândrește cu o precizie finală lăudabilă, LDN-ul său ridicat și AUBC relativ scăzut îi diminuează performanța generală pe întregul proces AL.

Extinzând evaluarea noastră la setul de date EuroSAT (MS), constatăm că informațiile sporite culese din cele 13 benzi MS se traduce prin performanță îmbunătățită. În linii mari, valorile AUBC și ale preciziei finale cresc în toate strategiile AL atunci când sunt aplicate setului de date MS în comparație cu RGB. Apar disparități relevante; în special, Entropia și Least Confident obțin o precizie cu aproximativ 5% și, respectiv, 6% mai mare pe EuroSAT (MS) comparativ cu EuroSAT (RGB). Printre strategiile DAL, BALD demonstrează o îmbunătățire lăudabilă cu 4%, în timp ce celelalte strategii prezintă o îmbunătățire de peste 6%. LPL și WAAL ies în evidență, atingând 85,68% și, respectiv, 84,43% - evidențiind pricepera lor ca fiind cele mai bune și a doua cea mai bună strategie.

Apare o observație intrigantă: atât Entropia, cât și Least Confident prezintă un AUBC cu aproximativ 1% mai mare decât BALD, prezentând o dinamică nuanțată pentru EuroSAT (MS). În plus, acuratețea finală a tuturor strategiilor din setul de date MS o depășește pe cea a EuroSAT (RGB). LPL și VAAL conduc grupul, asigurând cea mai mare și, respectiv, a doua cea mai mare precizie finală. Majoritatea strategiilor convenționale AL, cu excepția Marginului, ating rate finale de precizie care depășesc 91%. Această marjă nu este departe de acuratețea finală medie a strategiilor DAL, care se situează în jurul valorii de 94%. Acest rezultat robust accentuează capacitatea setului de date MS de a împuternici modelele cu informații mai cuprinzătoare, culminând cu performanțe superioare.

Una dintre cele mai interesante analize se învârtă în jurul conceptului de LDN, aruncând lumină asupra eficienței WAAL și LPL. În mod impresionant, aceste strategii necesită doar 20% din datele etichetate pentru a obține același vârf de precizie ca eșantionarea aleatorie. Această revelație subliniază importanța lor strategică, în special atunci când se confruntă cu constrângeri bugetare care limitează cheltuielile de etichetare. La fel de convingătoare sunt valorile LDN pentru VAAL și BADGE, situându-se la 34,8% și, respectiv, 39,31%.

Un aspect important reiese din performanța BADGE pe setul de date EuroSAT (MS). Aici, afișează o îmbunătățire excepțională de 6% în AUBC și o reducere remarcabilă de aproape 40% în LDN în comparație cu setul de date RGB. Acest lucru subliniază potențialul remarcabil al BADGE, în special în scenariile în care probele etichetate sunt mai abundente. Studiul comparativ al performanței strategiei de învățare activă (AL) între EuroSAT (RGB) și EuroSAT (MS) dezvăluie puterea de transformare a încorporării imaginilor Multi-Spectrale (MS). Această integrare abordează în mod eficient provocările generate de datele limitate etichetate, rezultând o creștere generală a performanței modelului.

2.4 Concluzie

În acest capitol, am efectuat o comparație cuprinzătoare a nouă strategii AL distincte într-un cadru unificat, concentrându-ne pe performanța acestora pe două seturi de date de imagini RS. În special, unele dintre aceste strategii au fost folosite pe seturile de date RS pentru prima dată, arătând noutatea și amploarea explorării noastre. Analiza noastră a cuprins două clasificatoare, RF și ResNet18, elucidând performanța acestora în cantități variate de mostre etichetate. Descoperirile subliniază tendința generală în care DNN-urile, în special, prezintă performanțe îmbunătățite cu un număr mai mare de mostre de date etichetate, întărind valoarea abundenței datelor.

Comparând strategiile AL convenționale folosind clasificatoare ResNet și RF, am observat că, deși RF demonstrează curbe stabile de performanță-buget, nu atinge nivelurile de precizie ale ResNet în timpul procesului AL. Un studiu de ablație a analizat impactul numărului de eșantioane de interogări per runda AL ($\$ M\$$) asupra performanței ResNet, dezvăluind că un $M\$$ mai mare generează curbe de performanță-buget mai stabile. Mai mult, studiul nostru a introdus o măsură nouă, LDN, pentru evaluarea strategiilor AL. LDN a dezvăluit că anumite strategii DAL, cum ar fi LPL și WAAL, au atins cea mai scăzută cerință pentru ca datele etichetate să funcționeze la nivelul de bază. Această caracteristică poziționează aceste strategii ca fiind deosebit de benefice atunci când se confruntă cu bugete limitate de etichetare. În plus, studiul nostru a oferit o imagine de ansamblu cuprinzătoare a evoluției AL în domeniul RS, începând cu strategiile inițiale naive de AL și urmărind perfecționarea lor continuă în timp. Am evidențiat recenta creștere a atenției față de valorificarea DL în AL și am elucidat necesitatea critică de a folosi AL în contextul rețelelor DL. Am abordat provocări unice pentru DL, indicând soluții inovatoare, cum ar fi rețele bayesiene pentru a aborda natura non-probabilistă a DNN-urilor, amalgamarea

diverselor criterii pentru a asigura informativitatea și reprezentativitatea, aplicarea tehnicilor semi-supravegheate pentru pseudoetichetare și utilizarea GAN-urilor pentru a atenua deficitul de date etichetate. În plus, am pledat pentru proiectarea rețelelor specializate pentru AL prin modificarea funcțiilor de pierdere, arătându-și potențialul de a îmbunătăți procesul general AL. În esență, acest studiu constituie o explorare cu mai multe fațete, care oferă perspective asupra eficienței diferitelor strategii AL privind seturile de date RS, noi metrice de performanță și soluții inovatoare pentru a aborda provocările în integrarea AL cu rețelele DL. Descoperirile noastre contribuie la o înțelegere mai profundă a sinergiei dintre AL și RS, oferind îndrumări valoroase pentru achiziția și adnotarea eficientă și eficientă a datelor în acest domeniu dinamic.

Capitolul 3

Interogare după exemplu pentru imaginea RS Recuperare

Datorită capacității de a imita o funcție neliniară a DNN, aceste modele sunt capabile să surprindă caracteristicile esențiale ale imaginilor. Încorporarea în straturile spațiale latente a modelelor DNN poate fi considerată ca caracteristici de nivel înalt pentru a reprezenta în mod cuprinzător conținutul vizual al imaginilor RS. Ca rezultat, DL oferă cele mai comune și utile metode de extragere a caracteristicilor cu multe aplicații în procesarea imaginilor RS. Principala problemă cu utilizarea DL este că este avid de date pentru a optimiza un număr masiv de parametri. Dacă un model DNN urmează să fie instruit într-o manieră supravegheată, este necesară o cantitate mare de date etichetate.

În era de date mari RS, putem colecta cu ușurință o cantitate mare de date brute, dar etichetarea cu precizie a datelor supradimensionate devine o provocare, deoarece există multe tipuri de imagini RS în comparație cu formatul RGB fix al imaginilor naturale în domeniul vederii computerizate. Din acest motiv, experții studiază metode DL nesupravegheate pentru a aborda problema etichetării datelor. Cu toate acestea, aceste metode pot avea rezultate extrem de inexacte și necesită îmbunătățiri și îmbunătățiri pentru a obține rezultate mai precise și mai fiabile. În studii recente, multe tehnici de îmbunătățire au fost propuse pentru a ajuta sau ghida modelele DL. DL conștient de fizică, combinarea abordărilor de extracție a caracteristicilor cu DNN, modificarea arhitecturii rețelei și proiectarea funcțiilor de cost sunt câteva exemple ale acestor tehnici, care sunt descrise mai jos.

În RS, experții acordă atenție extragerii informațiilor fizice în diferite benzi de lungimi de undă ale imaginilor multispectrale. Pe lângă caracteristicile spectrale, caracteristicile spațiale oferă informații importante despre date. De exemplu, autorii din [139] furnizează o metodă de captare a detaliilor spațiale. Prin urmare, este propusă o rețea convoluțională grafică cu constrângere de similaritate pe perechi pentru a aborda regăsirea imaginii RS. În general, diferitele caracteristici de formă ajută la compensarea defectelor celuilalt. În consecință, combinația de caracteristici multiple realizate manual prezintă adesea o capacitate de reprezentare mai puternică și beneficii în îmbunătățirea regăsirii imaginilor RS.

Lucrarea noastră are în vedere, de asemenea, proiectarea unei noi funcții de pierdere care poate grupa caracteristici similare (sau înglobări) în spațiul latent. Ideea principală este folosită pentru detectarea anomaliilor, care este o problemă

nesupravegheată prin natură. Recuperarea imaginilor precum detectarea anomaliilor poate fi considerată o clasificare cu o singură clasă care poate fi efectuată prin orice fel de metodă de clasificare. Prin urmare, aceasta poate fi o soluție inteligentă pentru a rezolva deficitul de date de antrenament etichetate. De exemplu, autorii au propus un autoencoder de minimizare a bilei care include date pentru detectarea modificărilor. De asemenea, un alt studiu a sugerat un clasificator de o singură clasă bazat pe GAN pentru detectarea intruziunilor în rețea, în care numai eşantioane de date normale sunt utilizate pentru antrenament și probele de date normale și anormale sunt utilizate în timpul testării pentru a identifica probe anormale în setul de testare. În conformitate cu această cercetare, am selectat și utilizat o metodologie de clasificare cu o singură clasă. Cu toate acestea, am îmbunătățit strategia prin crearea unei noi funcție de cost pentru a modela datele multispectrale pentru sarcina de recuperare a imaginii RS.

În acest capitol, exploatăm și modificăm ideea de deep SVDD [2] pentru regăsirea imaginilor RS. Deep SVDD este inspirat de clasificarea de o clasă bazată pe nucleu și utilizează o rețea neuronală pentru a mapa majoritatea reprezentărilor rețelei de date într-o hipersferă. Prin urmare, un DNN este instruit în comun pentru a mapa datele într-o hipersferă de volum minim în spațiul latent. Este de așteptat ca eşantioanele relevante (similare) cu interogarea să fie concentrate în interiorul hipersferei, iar eşantioanele irelevante (abere sau ambigue) să fie îndepărtate din hipersferă. Cea mai apropiată încorporare de centrul hipersferei corespunde eşantionului cel mai relevant pentru interogare. Modificăm funcția obiectivă a rețelei pentru a profita de informațiile statistice ale datelor. Folosim regularizarea covarianței în [156] pentru a preveni un colaps informațional în care codificatorul produce vectori constanți sau neinformativi. Penalizează redundanța inutilă a înglobării în spațiul latent. În plus, propunem o nouă funcție de cost pentru a minimiza volumul hipersferei prin deblocarea centrului predefinit al hipersferei, prevenind în același timp divergența rețelei în timpul antrenamentului. Acesta permite centrului hipersferei să fie liber să comprime eşantioanele relevante cât mai mult posibil, în timp ce le alungă pe cele irelevante.

Principalele noastre contribuții sunt următoarele:

- Din câte cunoștințele noastre, această lucrare este prima care a studiat SVDD profund (sau orice metodă de clasificare cu o singură clasă) pentru CBIR. Datorită faptului că nu este o abordare complet supravegheată, sunt necesare mai puține date etichetate (doar mostre dintr-o clasă) pentru instruire, iar eşantioanele din alte clase pot fi necunoscute.
- Îmbunătățirea funcției de cost cu un termen suplimentar de covarianță pentru a minimiza corelația dintre dimensiunile din spațiul latent devine deosebit de relevantă atunci când se lucrează cu date cu dimensiuni mari.
- Furnizarea unei noi funcții de cost prin deblocarea centrului predefinit al hipersferei și luarea în considerare a mediei înglobărilor pe un lot în fiecare iterație ca un centru în mișcare, prevenind în același timp divergența rețelei în timpul antrenamentului.
- Mai mult, investigăm relația dintre entropia imaginilor și performanța de regăsire a imaginilor a metodelor îmbunătățite.

3.1 Rezultate

Cele mai relevante 60 de eşantioane corespunzătoare diferitelor interogări sunt prezentate în Figura 3.2. Eşantionul din stânga sus este cel mai relevant şi scorul creşte de la stânga la dreapta. Primele două rânduri arată rezultatele deep SVDD pentru $d=128$. Putem vedea că regăsirea imaginii funcţionează bine doar pentru clasa See/Lake, care are distribuţie uniformă şi cea mai scăzută medie a entropiei. Privind cele mai relevante mostre pentru alte clase, recunoaştem că toate eşantioanele sunt uniforme şi fără textură. Aceasta înseamnă că reţeaua este capabilă să înveţe doar mostre uniforme şi demonstrează necesitatea unei funcţii de cost mai elaborate pentru a învăţa caracteristici mai complexe.

În schimb, majoritatea eşantioanelor extrase folosind un termen suplimentar de covarianţă sunt eşantioane mai complexe mult mai apropiate de aşteptările umane pentru fiecare clasă. Rezultatele pentru $\nu = 1024$ sunt prezentate în cele două rânduri din mijloc din Figura 3.2. Performanţa modelului pentru interogări industriale şi rezidenţiale s-a îmbunătăţit mai mult decât pentru alte clase. De asemenea, cele mai relevante mostre din aceste două clase sunt total corecte. În plus, mostrele extrase de pădure şi păşune sunt mult mai precise decât utilizarea SVDD profundă. Cu toate acestea, unele mostre de Pădure sunt preluate pentru o interogare a Pășunilor, ceea ce ar putea fi din cauza structurii spaţiale similare. Ultimele două rânduri indică rezultatele DC-SVDD când $a=0.001$ şi $b=1$. Ei arată că termenul suplimentar al centrului în derivă îmbunătăţeşte regăsirea imaginii pentru aproape toate clasele. Eşantioanele culturilor anuale, culturilor permanente şi râului sunt preluate mai fiabil decât cu metodele anterioare. De asemenea, cele mai relevante mostre de clase industriale şi rezidenţiale sunt încă total corecte. În plus, recuperarea imaginilor pentru interogările pe autostradă s-a îmbunătăţit, în ciuda faptului că există unele mostre de Rivers în primele 60 de eşantioane cele mai relevante. Textura spaţială similară a acestor două clase determină reţeaua să le considere aceeaşi clasă. Este demn de menţionat că există câteva mostre recuperate incorect. Mai precis, se pot observa câteva mostre de pădure extrase pentru interogarea Mare şi Culturi anuale pentru interogarea Culturi permanente. Din păcate, nicio metodă nu poate prelua corect mostre de interogare de vegetaţie erbacee.

3.2 Concluzie

În acest capitol, am introdus două metode noi pentru a ghida DNN prin luarea în considerare a informaţiilor statistice ale datelor. Prima metodă propusă penalizează redundanţa inutilă şi minimizează corelaţia dintre diferitele dimensiuni ale înglobării. A doua metodă încearcă să minimizeze volumul hipersferei având în vedere deblocarea centrului hipersferei. Această relaxare facilitează gruparea datelor pentru DNN. Ambele metode propuse depăşesc limitările Deep SVDD, în special atunci când interogarea aparţine unei clase complexe. Am subliniat că acestea sunt avantaje

foarte importante deoarece obiectivul principal al CBIR este optimizarea căutării cu un număr minim de imagini adnotate pentru a găsi cele mai asemănătoare mostre din arhivă.

Mai mult, am introdus utilizarea SVDD profundă pentru problemele CBIR (în special în contextul interogării prin exemplu) în RS. Performanțele experimentale ale sistemului propus au fost evaluate pe o arhivă de 5400 de imagini care descriu 10 categorii diferite pentru setul de date EuroSAT și, de asemenea, un alt set de date binecunoscut, UCM cu 21 de clase este folosit pentru a evalua eficacitatea și robustețea metodelor propuse. Rezultatele arată că metodele propuse oferă o performanță eficientă de regăsire a imaginii, depășind cu mult metoda de referință considerată (SVDD). În plus, am evaluat performanța datelor multispectrale, obținând rezultate superioare în comparație cu datele RGB. De asemenea, este de remarcat faptul că metodele propuse sunt independente de DNN-ul considerat și, prin urmare, pot fi utilizate pentru orice funcție de cost pentru a ghida DNN-ul pentru a obține o reprezentare superioară a datelor..

Capitolul 4

DNN-uri fizice

În această secțiune, propunem DNN-uri ghidate de wavelet, profitând de proprietățile WST pentru a extrage caracteristici invariante pentru clustering robust. În metoda propusă, rețeaua este antrenată pe eșantioane dintr-o singură clasă din setul de antrenament și este evaluată pe setul de testare incluzând toate clasele. Această strategie are avantajul de a nu necesita etichetare pentru fiecare clasă din setul de date care abordează deficitul de date etichetate de instruire. Ne concentrăm pe sarcina de clasificare cu o singură clasă și discutăm despre provocările și beneficiile unor metode utilizate în studiile recente. Metodele de clasificare cu o singură clasă urmăresc să învețe direct o limită de decizie cu o eroare redusă atunci când sunt aplicate datelor nevăzute.

Autorii au propus o metodă nouă, numită învățare prin transfer cu o clasă. Ei au ținut cont de faptul că, în domeniul viziunii computerizate, se pot accesa date etichetate din diferite domenii care nu sunt legate de seturi de date de clasificare de o singură clasă și beneficiază de utilizarea datelor dintr-un domeniu diferit. În mod similar, autorii utilizează funcția obiectivă inspirată de teoria informației, care maximizează distanța dintre datele normale și cele anormale în ceea ce privește distribuția comună a imaginilor și reprezentarea lor.

Exploatăm o rețea WST pentru a ghida DNN-urile pentru clasificarea într-o singură clasă. WST oferă reprezentarea invariantă care este informativă datorită păstrării unei frecvențe ridicate a datelor. Folosind aceste proprietăți, puteți grupa eșantioanele normale și pot distinge valorile aberante. La început, WST extrage coeficienții de împrăștiere din imaginile date, iar apoi li se aplică rețeaua. Acest lucru duce la obținerea unor rezultate mai solide și mai precise. Mai mult, pentru a aborda problema cantității insuficiente de set de antrenament pentru DNN-uri, este esențială o extragere adecvată a caracteristicilor inițiale pentru a ușura sarcina de antrenament. O evaluare amănunțită a confirmat performanța și robustețea superioare atât la valorile aberante (nu eșantioanele normale) din setul de antrenament, cât și la translația și rotația setului de testare. Mai mult, investigăm relația dintre entropia imaginilor și ghidarea WST pentru imagini cu textura ridicată.

4.1 GAN conștient de fizică pentru eliminarea în cloud

Datele imaginilor RS oferă un mijloc valoros pentru EO de a analiza și extrage informații, oferind perspective asupra resurselor Pământului și a diferiților parametri ai fenomenelor fizice. Odată cu progresele în tehnologia senzorilor pentru imaginile prin satelit, accesul la imagini de înaltă calitate cu rezoluție spațială ridicată a devenit fezabil. Această capacitate permite capturarea de informații detaliate în imagini, ceea ce duce la creșterea aplicațiilor precum clasificarea acoperirii terenului, cartografierea tematică, monitorizarea mediului și managementul resurselor naturale. În ciuda acestor progrese, merită remarcat faptul că statisticile arată că acoperirea norilor ascunde mai mult de jumătate din Pământ. Aceasta este o problemă obișnuită cu imaginile optice RS care determină ca informațiile să fie ascunse de nori și de umbrele asociate acestora. Ca urmare, nu putem captura informații de încredere din imaginile corupte decât dacă folosim imagini cu cer senin în același timp în care acestea nu sunt disponibile. Prin urmare, o soluție rezonabilă este îmbunătățirea rețelelor prin valorificarea proprietăților fizice de încredere și transparente. Metoda noastră propusă exploatează distanța unghiulară spectrală (SAD) pentru a antrena rețele adverse consistente cu ciclul cu caracteristici invariante de iluminare.

Deoarece avem nevoie de imagini fără nor, sunt propuse multe metode pentru a detecta și elimina norii din imaginile RS. Prin revizuirea studiilor privind eliminarea norului, am grupat metodele în trei categorii. O categorie este bazată pe multitemporal în care sunt utilizate imagini multitemporale ale aceleiași zone. Dezavantajul acestei categorii este că, pe de o parte, intervalul de timp al imaginilor multitemporale este lung, pe de altă parte, zona se schimbă rapid. Din acest motiv, de obicei, acuratețea zonei reconstruite este scăzută. Un studiu cuprinzător din această categorie propune fuziunea spațio-temporală folosind o metodă de ajustare Poisson pentru îndepărtarea norilor în imagini multi-senzor și multi-temporale. Abordarea folosește o strategie de corecție reziduală bazată pe Poisson pentru a îmbunătăți coerența spectrală între regiunile recuperate și cele afectate de nor.

În ultimul deceniu, DL a jucat un rol și mai semnificativ în RS, cu accent pe abordările bazate pe DL. GAN-urile, un model de rețea neuronală notabilă, utilizează două rețele într-o manieră contradictorie pentru a genera imagini mai clare și mai clare. În prezent, au fost create diferite tipuri de GAN-uri pentru diferite aplicații. Prin urmare, experții RS nu au trecut cu vederea și multe studii au fost publicate pentru eliminarea cloudului folosind GAN-uri.

A treia categorie se bazează pe fuziunea datelor multisenzoriale care este utilizată în modalități de penetrare auxiliare. Datele auxiliare utile în acest domeniu sunt imaginile SAR. Datorită lungimii de undă SAR, poate pătrunde prin nori în vreme diferită, cu diferite tipuri de nori. A făcut ca acesta să fie folosit foarte mult prin diferite metode în zona RS, cum ar fi fuziunea datelor și traducerea imaginilor pentru a obține și reconstrui informațiile din imaginile optice contaminate. Fuziunea datelor SAR-optice a fost propusă pentru a elimina norii folosind ciclul GAN. De

asemenea, au calculat măști de probabilitate cloud pentru a modela în mod explicit acoperirea norului în timp ce reconstruiau informațiile acoperite de nor.

Spre deosebire de majoritatea algoritmilor de viziune computerizată pentru dezaburire, care se bazează pe îmbunătățirea imaginii, injectăm proprietăți fizice în DNN-uri pentru a reconstrui regiunile contaminate. Prin urmare, folosim 12 benzi Sentinel-2 pentru a beneficia de reflectanța spectrală a imaginilor multispectrale. În acest capitol, extindem modelul propus în [3] bazat pe GAN consecvent în ciclu pentru a elimina norii din imaginile multispectrale corupte. Cele mai semnificative avantaje ale acestei metode sunt eliminarea nevoii de imagini pereche (cloud/cloudless) și utilizarea unei modalități auxiliare care pătrunde în nori. Spre deosebire de [3], exploatăm informații transparente din setul de date prin traducerea valorilor pixelilor în coordonate polare și apoi antrenăm rețeaua cu caracteristici invariante de iluminare pentru a reduce impactul norilor și al umbrelor. Metoda propusă, Hybrid GAN-SAD nu numai că obține rezultate notabile, dar crește și încrederea rețelei prin utilizarea proprietăților fizice de încredere.

4.2 Rezultate

Pentru o comparație cuprinzătoare a rezultatelor, am folosit trei strategii de formare distincte pentru rețeaua noastră. În configurația experimentală inițială, rețeaua a fost antrenată exclusiv folosind benzile vizibile RGB (B2, B3, B4) din setul de date de antrenament. În cea de-a doua configurație, rețeaua a fost antrenată folosind Near-Infrared (B8) în plus față de RGB (4 benzi), iar în ultima configurație, a fost utilizată întreaga gamă de benzi (12 benzi). Rezultatele fiecărei metode sunt prezentate în Figura 4.8. În scopuri de vizualizare, au fost folosite doar imagini B4, B3 și B2, iar luminozitatea figurii a fost ajustată pentru claritate.

Primul rând al figurii afișează mostre de imagini de testare, în timp ce al doilea rând prezintă ieșirea rețelei folosind numai benzi vizibile, așa cum a fost implementat de Singh și colab. [3]. Ulterior, al treilea rând prezintă rezultate care încorporează benzi de infraroșu apropiat, iar al patrulea rând prezintă rezultatele utilizând spectrul complet de benzi ale setului de date. În plus, al cincilea rând ilustrează rezultatele rețelei antrenate pe imagini convertite în coordonate polare, reprezentând metoda propusă de noi. În cele din urmă, al șaselea rând afișează patch-uri fără nor cu un interval de 16 zile, servind drept adevăr de bază. În special, neclaritatea a fost eliminată în mod eficient în toate metodele (coloanele 5-7). Infraroșul apropiat, beneficiind de capacitatea sa de a pătrunde în norii subțiri, depășește alte metode la dezaburire (coloanele 2-4). Modelul nostru propus nu numai că prezintă un impact notabil asupra eliminării norilor, dar demonstrează și o eficacitate considerabilă în eliminarea umbrelor și recuperarea informațiilor sub umbră, o capacitate neobservată în alte metode (coloanele 2-4). O inspecție mai atentă arată că gestionarea patch-urilor corupte cauzate de norii denși reprezintă o provocare, iar recuperarea completă a informațiilor din fundal fără a utiliza date auxiliare, cum ar fi SAR, se dovedește a fi imposibilă.

4.3 Concluzie

În prima secțiune a acestui capitol, demonstrăm că WST ia în considerare proprietățile statistice ale datelor și extrage caracteristici invariante care pot ajuta DNN-urile pentru o clasificare mai precisă, în special pentru imagini mai complexe. Este de remarcat faptul că imaginile complexe RS au, de obicei, o mare diversitate intraclasă și caracteristici complexe, ceea ce face clasificarea mai dificilă și duce la clasificare greșită. Metoda propusă atenuază necesitatea unui set mare de antrenament pentru DNN-uri, deoarece folosește WST pentru a obține caracteristici mai stabile. Au fost discutate robustețea la poluare într-un set de antrenament normal și, de asemenea, robustețea la transformare. În plus, s-a observat că WST compensează performanța limitată a DNN-urilor pentru clasele cu entropie mare. Prin îmbunătățirea performanței clasificării DNN, modelul este mai robust împotriva artefactelor adverse sau de orice fel.

A doua secțiune abordează direct atacurile adverse fizice din imaginile RS. Adversaria naturală în EO, cum ar fi norii și umbrele, sunt artefacte comune în analiza imaginii RS. Prin injectarea de proprietăți fizice în GAN-ul consecvent ciclului, am reușit să convertim o imagine multispectrală tulbure într-o imagine fără nori. Pentru a recupera informațiile de sub nori și umbre, creăm un spațiu multispectral sintetic pentru a obține caracteristici invariante la iluminare și pentru a antrena GAN-ul în acest spațiu. Metoda propusă modifică DNN-urile prin injectarea de proprietăți fizice pentru a obține rezultate de încredere. Pe măsură ce recuperăm informații reale despre fundal folosind proprietățile fizice ale datelor, putem avea încredere în rezultatele modelului.

Capitolul 5

Generarea de imagini sintetice de către GAN

GAN-urile, un tip de rețea neuronală pentru generarea de imagini și sinteza datelor, abordează provocările adverse în RS prin stabilirea unei funcții obiective prin intermediul datelor de antrenament. Discriminatorul distinge imaginile reale și cele false, ghidând generatorul să-și îmbunătățească producția pe baza greutăților actuale ale rețelei. GAN-urile sunt utilizate pe scară largă pentru diverse sarcini de sinteză și manipulare a datelor, în special în domeniul vizual.

Oceanul, crucial pentru reglarea climei Pământului, este studiat folosind imagini SAR, oferind perspective asupra proceselor oceanice și a impactului acestora asupra schimbărilor climatice. Acest capitol prezintă o metodă bazată pe GAN pentru a crea imagini SAR realiste și diverse cu model oceanic. Folosind o rețea generatoare bazată pe stil și o rețea de discriminare adversară, abordarea recunoaște și generează modele complicate în imaginile SAR. Pentru a contracara supraadaptarea discriminatorului obișnuită în scenariile cu date de antrenament limitate, este folosit mecanismul ADA. Antrenarea GAN cu ADA ajută generatorul să captureze caracteristicile spațiale și statistice ale fenomenelor oceanice în condiții de date limitate. Cu toate acestea, utilizarea imaginilor generate de GAN pentru aplicațiile RS necesită o evaluare amănunțită a calității și autenticității acestora, precum și validarea performanței modelului pe datele din lumea reală. Examinăm fiabilitatea imaginilor generate pe bază de GAN și propunem două abordări care aproximează precizia și reamintirea performanței GAN. DL a devenit un instrument esențial în procesarea imaginilor RS, jucând un rol vital în tehnologia EO. Eficiența sa în extragerea informațiilor semantice și clasificarea imaginilor satelitare de înaltă rezoluție a dat rezultate promițătoare, demonstrând acuratețe, reamintire, precizie și alte valori de evaluare ridicate. Entuziasmul din ce în ce mai mare în cadrul comunității RS pentru metodele DL a stimulat crearea a numeroase arhitecturi special concepute pentru a rezolva problemele RS, oferind frecvent performanțe remarcabile. Aceste progrese au îmbunătățit considerabil analiza imaginii RS, stabilind DL ca o componentă indispensabilă în domeniu.

5.1 De ce date sintetice?

Implementarea modelelor DL pentru procesarea imaginilor RS reprezintă o provocare din cauza cererii pentru cantități substanțiale de date de antrenament. Datele de antrenament adecvate sunt esențiale pentru a obține performanțe optime în modelele de învățare automată, permițându-le să discerne modelele și relațiile subiacente în cadrul datelor. Cu toate acestea, obținerea unui volum semnificativ de date de antrenament poate fi atât costisitoare, cât și consumatoare de timp și, în unele cazuri, obținerea unui eșantion reprezentativ pentru o anumită problemă se poate dovedi o provocare.

Au fost propuse diverse soluții pentru a aborda problema cerințelor de date în instruirea modelelor DL pentru procesarea imaginilor RS. Tehnicile de creștere a datelor, cum ar fi inversarea, rotația și scalarea, servesc la amplificarea datelor de antrenament prin generarea de noi mostre din setul de date existent. O altă strategie este învățarea prin transfer, care implică utilizarea modelelor pre-antrenate pe seturi extinse de date pentru a extrage caracteristici și a ajusta modelul pentru problema specifică RS. Învățarea activă, dimpotrivă, presupune selecția iterativă a celor mai informative eșantioane din setul de date pentru a antrena modelul, minimizând nevoia unei cantități mari de date etichetate.

O soluție deosebit de promițătoare pentru creșterea datelor implică generarea de date sintetice prin GAN-uri. GAN-urile, cuprinzând un generator și un discriminator, se angajează într-un proces competitiv pentru a produce date sintetice realiste. Generatorul fabrică mostre sintetice, iar discriminatorul evaluează calitatea acestora, oferind feedback pentru a îmbunătăți datele generate. Utilizarea GAN-urilor pentru generarea de date sintetice oferă eșantioane mai diverse și mai realiste în comparație cu tehnicile convenționale de creștere a datelor, care se bazează pe transformări liniare. Datele sintetice generate de GAN se dovedesc valoroase în creșterea setului de date de antrenament, atenuarea limitărilor deficitului de date și îmbunătățirea performanței generale a modelelor DL în procesarea imaginilor RS.

Evaluarea imaginilor generate pe baza GAN pentru aplicațiile RS necesită o evaluare cuprinzătoare a calității, autenticității și validării performanței modelului în lumea reală. Selectarea valorilor de evaluare adecvate joacă un rol esențial în măsurarea cu precizie a performanței GAN. Cu toate acestea, identificarea valorilor adecvate pentru imaginile generate de GAN se dovedește o provocare, având în vedere că valorile tradiționale pot să nu capteze în totalitate calitatea și diversitatea imaginilor. În mod obișnuit, cercetătorii se bazează pe valori precum Scorul inițial (IS), Distanța inițială Frechet (FID) și Distanța inițială a nucleului (KID) pentru a evalua performanța GAN. Deși aceste valori oferă informații despre progresul instruirii, ele nu se corelează neapărat cu sarcinile din lumea reală.

5.2 De ce analiza imaginilor oceanice?

Oceanul își asumă un rol vital în reglarea climei Pământului, influențând dinamica complicată dintre ocean, atmosferă și alte elemente climatice. Observarea oceanului

oferă informații valoroase asupra diverselor procese, în special cu ajutorul imaginilor SAR. SAR oferă informații detaliate despre activitățile oceanice și de coastă, favorizând o înțelegere îmbunătățită a dinamicii climatice. Această înțelegere îmbunătățită, la rândul său, ajută la perfecționarea modelelor climatice și la sprijinirea eforturilor de cercetare, monitorizare și atenuare legate de schimbările climatice. În plus, măsurătorile și observațiile precise ale suprafeței oceanului sunt esențiale pentru înțelegerea interacțiunilor aer-mare și dezvoltarea modelelor climatice de înaltă rezoluție.

SAR joacă un rol esențial în dezvoltarea înțelegerii noastre asupra oceanelor lumii. Unul dintre cele mai semnificative avantaje ale sale în oceanografie este capacitatea sa pentru orice vreme. Spre deosebire de senzorii optici, care sunt împiedicați de acoperirea norilor și întuneric, SAR poate funcționa eficient indiferent de condițiile meteorologice, oferind un flux continuu de date esențial pentru studierea proceselor oceanice dinamice. Acest lucru este deosebit de important pentru monitorizarea și analizarea fenomenelor precum curenții oceanici, modelele valurilor și comportamentul vântului, care sunt componente vitale ale circulației oceanice și ale sistemelor climatice. În plus, capacitatea SAR de a funcționa zi și noapte permite cercetătorilor să surprindă evenimente critice pe timp de noapte și să urmărească schimbările în condițiile oceanice non-stop, contribuind la o înțelegere mai cuprinzătoare a mediului marin.

În acest capitol, ne concentrăm pe analiza imaginilor SAR oceanice. Vă prezentăm o nouă măsurătoare de evaluare creată special pentru a măsura diversitatea imaginilor generate de GAN. Metodologia noastră implică antrenarea unei rețele de clasificare folosind imagini generate de un GAN și, ulterior, evaluarea performanței acesteia pe un set de testare care cuprinde imagini din lumea reală. Această măsurătoare de evaluare cuantifică diferența dintre distribuțiile de date achiziționate (imaginile generate) și cele dorite (imaginile reale). Evaluând acuratețea rețelei de clasificare în categorizarea imaginilor reale, putem deduce similaritatea dintre imaginile generate și cele reale, oferind o măsură robustă a asemănării acestora. Pentru a evalua fiabilitatea imaginilor generate, utilizăm ResNet18 ca clasificator și efectuăm antrenament și testare în două configurații experimentale distincte. În fiecare configurație, creăm două seturi de date echilibrate, unul cuprinzând imagini reale, iar celălalt imagini generate. Prima configurație implică antrenarea clasificatorului pe imagini reale și testarea imaginilor generate, în timp ce a doua configurație funcționează invers. Comparând precizia clasificării în fiecare configurație, aproximăm precizia și rechemarea performanței GAN-urilor.

5.3 StyleGAN2 cu ADA

În această secțiune, prezentăm metodologia StyleGAN cu ADA [211], care extinde cadrul original StyleGAN [212] cu o strategie de augmentare dinamică pentru discriminator în timpul antrenamentului. Arhitectura StyleGAN2-ADA constă dintr-

un generator și o rețea discriminatoare, ambele fiind compuse din straturi convoluționale. Arhitectura este similară cu StyleGAN2, diferența principală fiind introducerea mecanismului de mărire a discriminatorului adaptiv pentru a stabiliza antrenamentul atunci când se utilizează date limitate. Metodologia cuprinde următorii pași și componente:

{Mapping Network}

Rețeaua de cartografiere este o rețea complet conectată care mapează punctele din spațiul latent către un spațiu latent intermediar. Această rețea este responsabilă pentru controlul stilului imaginilor generate.

{Spațiu latent intermediar}

Spațiul latent intermediar, denumit și spațiul de stil, servește ca un mecanism pentru a influența stilul imaginilor generate la diferite niveluri de detaliu. Acest spațiu de stil este încorporat în modelul generator în mai multe etape, permițând controlul precis asupra caracteristicilor imaginilor generate.

{Demodularea greutateii}

Weight Demodulation, o tehnică introdusă în StyleGAN2, reconstruiește operația de mărire din StyleGAN original. Această metodă este folosită pentru a regla stilul imaginilor generate la diferite niveluri de detaliu.

{Injectie de zgomot}

Zgomotul este introdus în mod deliberat în fiecare punct din modelul generatorului, funcționând ca o sursă de variație. Acest zgomot contribuie la crearea unor variații stocastice în imaginile generate, introducând textura și detalii fine.

{Adaptive Discriminator Augmentation (ADA)}

Mecanismul de mărire a discriminatorului adaptiv din StyleGAN2-ADA aplică măririi aleatorii imaginilor de intrare în timpul antrenamentului, ceea ce ajută la prevenirea supraajustării și stabilizează antrenamentul atunci când se utilizează date limitate. Rețelele generatoare și discriminatoare sunt antrenate folosind un proces de optimizare care minimizează funcțiile de pierdere respective, cum ar fi pierderea Wasserstein cu penalizare de gradient.

Capitolul 6

Concluzii

Putem trage concluzia că problema eşantioanelor adverse în clasificarea imaginilor RS este o problemă serioasă care trebuie abordată pe baza metodelor propuse și a rezultatelor experimentale ale tezei. Eşantioanele adverse pot determina ca modelele de învățare profundă să producă predicții incorecte, ceea ce duce la o clasificare greșită. Această problemă este deosebit de dificilă pentru aplicațiile RS, deoarece poate fi cauzată de fenomene naturale, cum ar fi norii, umbrele sau artefactele din imaginile din satelit.

Pentru a aborda această problemă, am propus patru soluții în această teză, inclusiv AL, interogare după exemplu, modele profunde conștiente de fizică și GAN. AL poate îmbunătăți performanța modelului prin selectarea iterativă a celor mai informative mostre pentru a înțelege mai bine structura și proprietățile de bază ale datelor, făcându-l mai rezistent la atacurile adverse. Query-by-Example urmărește să găsească cea mai asemănătoare imagine cu interogarea și să optimizeze ponderile rețelei, astfel încât eşantioanele adverse să fie departe de imaginea interogării în spațiul latent. Modelele profunde conștiente de fizică pot aborda problema eşantioanelor adverse în clasificarea imaginilor RS prin încorporarea cunoștințelor specifice domeniului și proprietăților fizice ale datelor în procesul de învățare. GAN-urile pot fi utilizate pentru a genera mostre adverse pentru analiza imaginilor RS, care pot fi apoi utilizate pentru a îmbunătăți robustețea modelului de clasificare împotriva atacurilor adverse.

În general, această teză contribuie la dezvoltarea unor algoritmi mai precisi, robusti și eficienți pentru analiza imaginilor satelitare și înțelegerea diferitelor fenomene de mediu și geografice. Prin investigarea acestor subiecte, am propus soluții noi pentru a aborda problema eşantioanelor adverse în clasificarea imaginilor RS, care pot ajuta la îmbunătățirea fiabilității și securității modelelor de învățare profundă în aplicațiile RS.

6.1 Contribuții originale

În fața provocărilor adverse inerente clasificării imaginilor RS, această teză se adâncește în strategii inovatoare pentru a îmbunătăți robustețea și fiabilitatea modelelor DL pentru imagini multispectrale EO. Eşantioanele adverse, care decurg

din modificări intenționate sau perturbări naturale, reprezintă o amenințare semnificativă pentru clasificarea corectă a imaginilor în aplicațiile RS.

În primul capitol, a fost efectuată o comparație meticuloasă a nouă strategii AL pe două seturi de date de imagini RS. Aducem sub același cadru și analizăm toate strategiile, printre care cele mai recente nu au fost încă testate pe datele RS. Evaluăm performanța tehnicilor AL în ceea ce privește o nouă măsurătoare numită LDN, aruncând lumină asupra eficienței diferitelor strategii în cadrul unor bugete limitate de etichetare. Această investigație nu numai că a prezentat aplicarea inedită a anumitor strategii la AL, dar a subliniat și importanța tot mai mare a abundenței de date, în special pentru DNN-uri. Evoluția istorică a AL în RS a fost, de asemenea, urmărită, subliniind progresele recente, provocările unice pentru DL și potențialul de proiectare a rețelei specializate pentru AL.

Trecând la al doilea capitol, accentul s-a mutat pe ghidarea DNN-urilor prin încorporarea informațiilor statistice. Au fost introduse două metode noi, abordând limitările Deep SVDD și demonstrând eficacitatea acestora în problemele CBIR. Versatilitatea acestor metode în diferite arhitecturi DNN a fost subliniată, arătându-și potențialul de a îmbunătăți reprezentarea datelor în diferite contexte. Acest capitol a demonstrat că împingerea eșantioanelor cu anomalii departe de eșantioanele normale într-un model spațial latent face ca modelul să fie robust împotriva valorii aberante și a oricărui tip de eșantioane adverse.

Al treilea capitol a extins importanța luării în considerare a proprietăților statistice și a exploatării WST pentru a extrage caracteristici invariante pentru o clasificare îmbunătățită a imaginilor complexe RS. Studiul a relevat eficacitatea metodei în atenuarea provocărilor, cum ar fi diversitatea intraclasă, poluarea în seturile de antrenament și robustețea la transformări. În plus, încorporarea proprietăților fizice într-un GAN consecvent în ciclu a abordat elementele adverse naturale, oferind o soluție de încredere pentru analiza imaginilor în prezența norilor și a umbrelor.

În al patrulea capitol, a fost explorată utilizarea StyleGAN2-ADA pentru generarea de imagini sintetice, concentrându-se pe modelele oceanului în imaginile Sentinel-1A WV SAR. Obiectivul este de a robust un clasificator și de a îmbunătăți acuratețea clasificării prin antrenarea modelului pe imagini generate pe baza GAN. Studiul a evidențiat dependența FID de dimensiunea antrenamentului, compromisul dintre calitatea imaginii și diversitate și importanța unui set de date divers pentru antrenamentul GAN eficient. Valorile de evaluare utilizate au oferit perspective nuanțate asupra preciziei, reamintirii și limitărilor imaginilor generate de GAN.

În rezumat, această teză navighează peisajul complex al analizei de imagini multispectrale EO, abordând provocarea persistentă a probelor adverse. Strategiile explorate, cuprinzând AL, modele conștiente de fizică, interogare după exemplu pentru regăsirea imaginilor și generarea de imagini sintetice de către GAN, contribuie în mod colectiv la dezvoltarea unor algoritmi mai preciși, robusti și eficienți pentru sarcina complicată de analiză a imaginilor satelitare. În diverse contexte de mediu și geografice. Pe măsură ce avansăm, aceste descoperiri deschid calea pentru progrese în

aplicațiile RS, favorizând o înțelegere mai profundă a dinamicii Pământului prin prisma tehnicilor avansate DL.

6.2 Lista lucrărilor originale

List of Journal papers

- I. Omid Ghozatlou, Miguel Heredia Conde, Mihai Datcu. A Review and Perspective of Active Learning for Remote Sensing Image Analysis. In IEEE Geoscience and Remote Sensing Magazine (GRSM), Under revision.
- II. Omid Ghozatlou, Miguel Heredia Conde, Mihai Datcu. Query by Example in Remote Sensing Image Archive Using Enhanced Deep Support Vector Data Description. In IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 16, pp. 1197-1210, 2023, DOI: 10.1109/JSTARS.2022.3233105.

List of Conference papers

- I. Omid Ghozatlou, Mihai Datcu, Bertrand Chapron, GAN-Based Ocean Pattern SAR Image Augmentation. In IEEE International Geoscience and Remote Sensing Symposium (IGARSS), pp. 4056-4059, Pasadena, CA, USA, 2023, DOI: 10.1109/IGARSS52108.2023.10283353.
- II. Omid Ghozatlou, Mihai Datcu. Comparative Studies on Similarity Distances for Remote Sensing Image Classification. In IEEE 5th International Conference on Image Processing Applications and Systems (IPAS), pp. 1-6, Genova, Italy, 2022, DOI: 10.1109/IPAS55744.2022.10052824.
- III. Omid Ghozatlou, Miguel Heredia Conde, Mihai Datcu. Wavelet-Guided Deep Neural Network For Robust One-Class Classification. In 12th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS), pp. 1-5, Rome, Italy, 2022, DOI: 10.1109/WHISPERS56178.2022.9955071.
- IV. Omid Ghozatlou, Mihai Datcu. Hybrid GAN and Spectral Angular Distance for Cloud Removal. In IEEE International Geoscience and Remote Sensing Symposium (IGARSS), pp. 2695-2698, Brussels, Belgium, 2021, DOI: 10.1109/IGARSS47720.2021.9554891.

5.3 Perspective pentru evoluții ulterioare

Câteva perspective cheie pentru dezvoltarea ulterioară includ strategii avansate AL care integrează cunoștințele specifice domeniului. Folosiți strategii de interogare adaptive care iau în considerare în mod specific diversitatea spectrală și caracteristicile inerente imaginilor EO. O altă cale implică combinarea diverselor soluții pentru a aborda eșantioanele adverse în clasificarea imaginilor RS. De exemplu, fuzionarea AL cu GAN-urile pentru generarea de date sintetice. GAN-urile, în acest context, servesc nu numai la estimarea incertitudinii de predicție a modelului, ci și la prioritizarea eșantioanelor incerte pentru etichetare, sporind robustețea și încrederea modelului.

Accentul nostru principal pentru dezvoltarea viitoare se concentrează pe rafinarea generării de imagini sintetice folosind GAN-uri, luând în considerare proprietățile fizice ale datelor EO. După cum este detaliat în Capitolul 5, imaginile generate demonstrează realism, calitate înaltă și similitudine cu datele reale. Cu toate acestea, în domeniul frecvenței, este posibilă distingerea imaginilor generate de GAN de cele reale, indicând provocările GAN-urilor în învățarea distribuțiilor spectrale. Abordând acest lucru, ne propunem să atenuăm discrepanța spectrului prin antrenarea GAN-urilor în domeniul frecvenței și încorporarea proprietăților fizice în model. Această abordare își propune să îmbunătățească performanța GAN-urilor prin păstrarea mai bună a caracteristicilor fizice ale datelor.

Câteva perspective cheie pentru dezvoltarea ulterioară includ strategii avansate AL care integrează cunoștințele specifice domeniului. Folosiți strategii de interogare adaptive care iau în considerare în mod specific diversitatea spectrală și caracteristicile inerente imaginilor EO. O altă cale implică combinarea diverselor soluții pentru a aborda eșantioanele adverse în clasificarea imaginilor RS. De exemplu, fuzionarea AL cu GAN-urile pentru generarea de date sintetice. GAN-urile, în acest context, servesc nu numai la estimarea incertitudinii de predicție a modelului, ci și la prioritizarea eșantioanelor incerte pentru etichetare, sporind robustețea și încrederea modelului.

Accentul nostru principal pentru dezvoltarea viitoare se concentrează pe rafinarea generării de imagini sintetice folosind GAN-uri, luând în considerare proprietățile fizice ale datelor EO. După cum este detaliat în Capitolul 5, imaginile generate demonstrează realism, calitate înaltă și similitudine cu datele reale. Cu toate acestea, în domeniul frecvenței, este posibilă distingerea imaginilor generate de GAN de cele reale, indicând provocările GAN-urilor în învățarea distribuțiilor spectrale. Abordând acest lucru, ne propunem să atenuăm discrepanța spectrului prin antrenarea GAN-urilor în domeniul frecvenței și încorporarea proprietăților fizice în model. Această abordare își propune să îmbunătățească performanța GAN-urilor prin păstrarea mai bună a caracteristicilor fizice ale datelor.

Bibliografie

- [2] Lukas Ruff, Robert A. Vandermeulen, Nico Gornitz, Lucas Deecke, Shoaib A. Siddiqui, Alexander Binder, Emmanuel Muller, and Marius Kloft. Deep one-class classification. 35th International Conference on Machine Learning, ICML 2018, 10:6981–6996, 2018.
- [3] Praveer Singh and Nikos Komodakis. Cloud-GAN: Cloud removal for sentinel-2 imagery using a cyclic consistent generative adversarial networks. International Geoscience and Remote Sensing Symposium (IGARSS), 2018 July:1772–1775, 2018.
- [32] Xue Wang, Kun Tan, Cen Pan, Jianwei Ding, Zhaoxian Liu, and Bo Han. Active deep feature extraction for hyperspectral image classification based on adversarial learning. *IEEE Geoscience and Remote Sensing Letters*, 19:1–5, 2022.
- [51] Juan Mario Haut, Mercedes E. Paoletti, Javier Plaza, Jun Li, and Antonio Plaza. Active learning with convolutional neural networks for hyperspectral image classification using a new bayesian approach. *IEEE Transactions on Geoscience and Remote Sensing*, 56(11):6440–6461, 2018.
- [59] Guangxing Wang and Peng Ren. Hyperspectral image classification with feature-oriented adversarial active learning. *Remote Sensing*, 12(23), 2020.
- [139] Ushasi Chaudhuri, Biplab Banerjee, and Avik Bhattacharya. Siamese graph convolutional network for content based remote sensing image retrieval. *Computer Vision and Image Understanding*, 184:22–30, 2019.
- [156] Adrien Bardes, Jean Ponce, and Yann LeCun. VICReg: Variance invariancecovariance regularization for self-supervised learning. In *International Conference on Learning Representations*, 2022.
- [211] Tero Karras, Miika Aittala, Janne Hellsten, Samuli Laine, Jaakko Lehtinen, and Timo Aila. Training generative adversarial networks with limited data. In *Advances in Neural Information Processing Systems*, volume 33, pages 12104–12114. Curran Associates, Inc., 2020.
- [212] Tero Karras, Samuli Laine, and Timo Aila. A style-based generator architecture for generative adversarial networks. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 4401–4410, 2019.