

ȘCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea de Inginerie Electrică și Știința Calculatoarelor

Kamal MARANDSKIY

Analiza Datelor de Teledetecție pentru Aplicații de Observarea Terrei

Remote Sensing Data Analysis for Earth Observation Applications

REZUMAT

Conducători științifici

Prof. Dr. Mihai IVANOVICI și Prof. Dr. Fabio DEL FRATE

BRAȘOV, 2025

Cuprins

1	Intr	oducere	3
•	1 1	Teledetectie	3
	1.1	A gricultura de Precizie	4
	1.2		т 4
	1.5		4
	1.4		4
	1.5		2
	1.6	Schemele Plantelor	6
	1.7	Vizualizarea și Compresia Imaginilor Hiperspectrale	6
	1.8	Detectarea Timpurie a Câmpurilor de Cultură	6
2	Rug	ozitatea Solului	8
	2.1	Metoda Lantului	8
	2.2	, Metoda Panoului cu Tije	8
	2.3	Experimente Preliminare	8
	2.3	Imagini Digitale ale Motivelor Laser Reliefate pentru Estimarea Rugozității Suprafatei	0
	2.1	Solului	9
		2.4.1 Colectarea si Procesarea Datelor Imagistice	10
		242 Rezultate Experimentale	11
	25	Estimarea Rugozității Suprafatei Solului din Imagini Digitale Folosind Analiza Fractală	11
	2.5	2.5.1 Achizitia și Prenrocesarea Imaginilor	11
		2.5.1 Rezultate Experimentale	12
	26	Analiza Fractală a Imaginilor Multisnectrale ale Sunrafetei Solului de la Diferite Altitudini	12
	2.0	2.6.1 Achizitia si Productarea Datelor	13
		2.6.1 Achiziția și l'icluciarea Datelor	17
			17
3	Umi	ditatea Solului	16
	3.1	Metodologie	16
		3.1.1 MEI Simplificat	17
		3.1.2 Generarea Numerică a Suprafeței	17
		3.1.3 Conținutul de Umiditate al Solului	17
		3.1.4 Date MEI și RNC	18
	3.2	Rezultate și Discuții	18
4	Sahi	tala Diantalan	20
4		Vete delegie și Dete	20
	4.1		20
	4.2	Rezultate	LL
5	Ima	gistică Hiperpectrală: Vizualizare, Clasificare și Compresie	23
	5.1	Vizualizarea Imaginilor Hiperspectrale	23
		5.1.1 Rezultate Experimentale	23
	5.2	Extragerea Caracteristicilor Exponențiale și Învățarea pentru Compresia per Pixel a	
		Imaginilor Hiperspectrale	25
		5.2.1 Rezultate Experimentale	26
6	Idon	tificarea Tinului de Cultură	28
U	6 1	Identificarea Timpurie a Câmpurilor de Cartof Folosind Fuziunea Datelor si DNA	20 28
	0.1	6.1.1 Rezultate Experimentale	20 20
			29
7	Con	cluzie	30

Mulțumiri

În primul rând, îi mulțumesc conducătorului meu prof. Mihai Ivanovici pentru contribuția sa științifică la doctoratul meu, precum și sprijinul său pentru a-mi oferi oportunitatea de a fi parte a proiectului AI4AGRI. Încurajarea lui continuă de a participa la ateliere, școli de vară, conferințe, mobilități științifice și multe altele, mi-a îmbunătățit considerabil abilitățile și mi-a lărgit cunoștințele. A înființat Centrul Român de Excelență pentru AI pentru Agricultură și am devenit unul dintre primii oameni care au contribuit la el. Îi mulțumesc co-supervizorului meu prof. Fabio Del Frate pentru îndrumarea și sfaturile științifice. M-a invitat să mă alătur prin programele de mobilitate la EO Lab de la Universitatea Tor Vergata din Roma și m-a ajutat să avansez în studii. Sperăm că cercetarea noastră va îmbunătăți în continuare această inițiativă și va pune bazele viitorilor cercetători.

Mulțumesc membrilor comisiei de îndrumare, prof. Corneliu Florea, conf. Angel Cataron, conf. Radu-Mihai Coliban și șef lucr. Șerban Oprisescu pentru contribuția intelectuală și îndrumarea lor. De asemenea, îi mulțumesc colegului meu dr. ing. Ștefan Popa pentru ajutorul acordat în diferite etape ale cercetării, în principal, la culegerea datelor, sfaturi tehnice și cunoștințe practice pentru redactarea tezei. Mulțumesc Universității Transilvania din Brașov și rectorului acesteia, prof. Ioan Vasile Abrudan, pentru că au oferit burse și au creat oportunități de cercetare și studiu în timpul doctoratului. Mulțumesc tuturor profesorilor care mi-au predat materii importante la începutul programului de doctorat.

Le mulțumesc părinților și familiei mele pentru încurajări, sprijin nesfârșit și înțelegere, deși fusesem departe de ei. Îi mulțumesc în mod deosebit iubitei mele Nemuutsetseg pentru că a fost alături de mine tot timpul, oferindu-mi sprijin și grijă.

Această lucrare este finanțată de Uniunea Europeană. Proiectul AI4AGRI intitulat "Centrul de excelență român pentru inteligența artificială privind datele de observare a Pământului pentru agricultură" a primit finanțare din programul de cercetare și inovare Orizont Europa al Uniunii Europene în baza acordului de grant nr. 101079136.



Introducere

1.1 Teledetecție

Teledetecția este procesul de obținere a informațiilor despre un obiect sau fenomen fără un contact fizic, de obicei prin măsurarea radiației reflectate și emise, folosind senzori specializați de pe sateliți sau avioane. Teledetectia este un set de instrumente si tehnici care permit analiza caracteristicilor fizice ale Pământului sau ale altor corpuri planetare. Instrumentele care sunt utilizate în teledetecție pot fi împărțite în două categorii: senzori activi și pasivi. Senzorii activi se bazează pe emiterea de semnale electromagnetice și primirea fracțiunii reflectate de la obiecte. Pe baza timpului în care semnalul durează pentru a călători si/sau a caracteristicilor semnalului returnat, pot fi evaluate anumite informatii despre obiect si mediu. Exemple obisnuite de tehnologie pentru acest principiu sunt instrumentele radar cu emisie de microunde (detecție și măsurare radio) și lidar emițător de lumină în infraroșu (detecție și măsurare a luminii). Forma principală a unui sistem radar este Radarul cu apertură sintetică (RAS) care utilizează miscarea platformei atașate pentru a extinde sintetic deschiderea radarului. RAS are o capacitate unică, și anume penetrarea, care îi permite să vadă prin nori și să captureze imagini. Intervalul de cu microunde al spectrului electromagnetic este afectat de constanta dielectrică (care este corelată cu continutul de apă al plantelor si solului), de rugozitatea suprafetei, de unghiul de incidentă al senzorului si de structura fizică a obiectelor. Copernicus este componenta de Observare a Pământului a programului spatial al Uniunii Europene, iar în cadrul acestuia, misiunea Sentinel-1 este un satelit echipat cu RAS, care asigură acoperirea globală a Pământului, iar datele sunt disponibile gratuit.

Imaginile multispectrale și hiperspectrale sunt principalele exemple semnale achiziționate de instrumente optice pasive. Instrumentele multispectrale captează mai puțin de 30 de benzi, acoperind porțiunea vizibilă până la cea în infraroșu a spectrului electromagnetic, prin tehnici de filtrare optică. Ansamblul optic direcționează lumina incidentă prin oglinzi dicroice sau filtre cu bandă fixă, care separă lumina într-un număr limitat de canale spectrale. Lumina este apoi detectată de matrici de senzori specializate, cum ar fi CCD-urile sau detectoarele CMOS, care convertesc semnalul optic într-un semnal electric cu un grad înalt de acuratețe radiometrică. Datele procesate rezultă în straturi de imagine separate pentru fiecare bandă spectrală. Misiunea Copernicus Sentinel-2 furnizează imagini optice de înaltă rezoluție pentru monitorizarea terestră. Instrumentatul multispectral captează date pe 13 benzi spectrale, de la vizibil la infraroșu-îndepărtat. Aceasta este eficientă în analiza vegetației, a corpurilor de apă, a caracteristicilor solului și a dinamicii acoperirii terestre.

Imaginile hiperspectrale încep cu captarea luminii pe o gamă continuă de lungimi de undă; sistemul utilizează elemente de dispersie optică, cum ar fi prismele sau grilele de difracție, pentru a separa lumina incidentă în lungimile sale de undă componente. Dispersia spectrală rezultată este înregistrată de matrici de plan focal de înaltă densitate, care utilizează, de obicei, tehnici de scanare *push broom* pentru a captura o linie spațială la un moment dat, împreună cu spectrul complet pentru fiecare pixel. Acest lucru permite crearea unei structuri de date tridimensionale, cunoscută sub numele de *hipercub*. Atât datele multispectrale, cât și cele hiperspectrale joacă un rol important în evaluarea stratului de vegetație în mediile agricole.

1.2 Agricultura de Precizie

Agricultura este principala sursă de hrană pentru majoritatea populației, prin urmare, o astfel de cerere creează stres asupra terenurilor agricole. Are ca rezultat folosirea excesivă a terenurilor, astfel, degradarea calității solului, culturi mai slabe, randament redus etc. Pe lângă activitatea umană, clima afectează și creșterea culturilor în principal secetă, inundații etc. Cele mai multe influențe negative asupra culturilor pot fi prevenite dacă sunt detectate în stadii incipiente. Astfel de preveniri sunt posibile dacă câmpurile sunt monitorizate în mod constant. Teledetecția este o tehnologie de bază în agricultura de precizie, RAS este utilizat în mod activ în analiza umidității solului (US), estimarea biomasei, predicția randamentului etc. Un alt pilon important al agriculturii moderne este durabilitatea și eficiența. Gestionarea apei este esențială, deoarece sistemele de irigare de precizie utilizează date spațiale și temporale pentru a aplica cantitatea potrivită de apă în diferite zone de câmp, în funcție de condițiile de US și de cerințele culturii. Acest lucru maximizează utilizarea eficientă a apei și îmbunătățește deficitul de apă în zonele mai uscate. În mod similar, îngrășămintele și pesticidele pot fi aplicate variabil în funcție de nevoile specifice ale diferitelor secțiuni de câmp, reducând atât costurile, cât și potențialele daune asupra mediului. Pe de altă parte, datele multispectrale și hiperspectrale sunt utilizate pentru monitorizarea sănătății culturilor, detectarea bolilor etc. Exemplul principal este Indexul de vegetație a diferențelor normalizate (NDVI) care cuantifică starea de vegetație și se bazează pe benzile roșii și infra-roșu apropiat. În cazuri complexe, datele satelitare sunt integrate cu senzori de la sol și chiar cu aeronave fără pilot (AFP) pentru luarea deciziilor. Dincolo de acestea, consumul de energie si forta de muncă pot fi, de asemenea, optimizate cu mașini automate și programare inteligentă.

1.3 Învățare Automată

O cantitate imensă de date este generată zilnic de sateliții misiunii Sentinel în cadrul programului Copernicus. Informațiile utile pot fi extrase și utilizate în diverse aplicații, inclusiv în agricultură. Învățarea automată (ÎA), în special sub-ramura, învățarea profundă (ÎP), este un domeniu important de cercetare în ultimul deceniu și poate fi aplicat în diverse industrii. Acest lucru a devenit posibil datorită îmbunătățirilor aduse calculului paralel și a unităților hardware mai eficiente și puternice. Această lucrare se va concentra pe metode și tehnici în ÎA pentru a clasifica câmpurile de cultură folosind datele teledetecție. Algoritmii de ÎA pot fi clasificați în învățare supravegheată, învățare nesupravegheată, învățare semi-supravegheată și învățare prin întărire. Studiile noastre utilizează în mod extensiv metode ÎP - în special, rețea neuronală convoluțională (RNC) și rețea neuronală artificială (RNA) complet conectate pentru a extrage modele semnificative din cantitățile mari de date Sentinel. Aceste tehnici sunt deosebit de potrivit pentru manipularea naturii complexe și cu dimensiuni mari a imaginilor de observare a Pământului. O trecere în revistă detaliată a algoritmilor și aplicațiilor ÎA în agricultură este realizată în capitolul dedicat.

1.4 Rugozitatea Suprafeței Solului

Rugozitatea suprafeței solului (RSS) este o caracteristică fizică critică care descrie neregularitățile prezente pe suprafața solului. Aceste neregularități rezultă din proprietățile inerente ale solului — inclusiv textura, mărimea agregatelor și prezența fragmentelor de rocă sau nisip, precum și din activități antropice, cum ar fi lucrările de cultivare și alte practici de gestionare a terenului. Astfel, rugozitatea solului este modelată atât de micro-topografia naturală a solului, cât și de modificările impuse de intervențiile agricole sau mecanice [1]. În literatura de specialitate, RSS este adesea cuantificată prin măsuri statistice, cum ar fi captată prin cartografiere topografică sau modele digitale de elevație, motiv pentru care este cunoscută și sub numele de micro-topografie a solului. RSS afectează semnificativ retro-împrăștierea RAS prin modularea mecanismelor de împrăștiere. Suprafețele rugoase, în general, cresc retro-împrăștierea, ceea ce poate masca efectele dielectrice ale US. Prin urmare, cuantificarea precisă a rugozității suprafeței este esențială pentru a izola și extrage semnalele US din datele RAS în aplicațiile de teledetecție. Au

fost dezvoltați diverși indici pentru a descrie tipurile de RSS formate de diferite fenomene naturale sau activități umane: (1) variațiile micro-reliefate sau rugozitatea granulelor, influențate în principal de tipul de sol; (2) rugozitatea aleatorie (RA), asociată cu agregatele solului; (3) rugozitatea orientată, reprezentând variațiile topografice sistematice cauzate de factori precum lucrările de cultivare; și (4) rugozitatea de ordin superior, care ține cont de schimbările de elevație din cadrul câmpului și marginile acestuia. În studiile noastre, ne-am concentrat pe RA și am efectuat experimente în jurul acesteia. Două metode clasice au fost utilizate pentru estimarea RSS: metoda lanțului și metoda cu panou cu pini. Am testat eficiența acestora atât în laborator, cât și în măsurători in situ. Imagini ale suprafețelor proiectate cu laser, realizate cu Canon 5D Mark II de la o anumită distanță, au fost utilizate pentru a estima RSS folosind un tip de rețea neuronală artificială, numită RNC, mai exact ResNet-18 [2]. Avantajul acestei abordări constă în simplitatea și costul redus. Experimentele au fost efectuate pe patru suprafețe artificiale diferite și pe sol real în laborator, evaluând potențialul acestei metode față de metodele clasice.

Am propus metoda de analiză fractală (AF) pentru a cuantifica dimensiunea fractală (DF) a imaginilor digitale ale suprafeței solului. Metodele clasice se limitează la măsurători 1D, în timp ce analiza fractală permite o analiză a complexității în spațiu bidimensional. Am dezvoltat propria noastră configurație de lucru, care blochează iluminarea și creează un mediu controlat de achiziție. Datele au fost colectate de pe solul unui câmp agricol, în colaborare cu Institutul Național de Cercetare-Dezvoltare pentru Cartof și Sfeclă de Zahăr, Brașov (INCDCSZ). Dincolo de RA și de mici variații ale solului, care sunt importante pentru interpretarea retro-împrăștieri RAS, am experimentat și cu imagini obținute de drone ale suprafețelor solului gol, realizate cu o cameră multispectrală ce dispune de cinci benzi. Experimentele au fost efectuate la altitudini de 60 m și 80 m și am analizat modul în care complexitatea se dezvoltă odată cu creșterea numărului de benzi și a altitudinii. Vederea de tip "bird-eye" a câmpurilor agricole și analiza fractală a imaginilor multispectrale au potențialul de a cuantifica global RSS.

1.5 Umiditatea Solului

US reprezintă conținutul de apă al solului. Distribuția spațială și temporală a apei stocate pe uscat reprezintă un parametru cheie ce controlează diverse procese și influențează alte fenomene din sistemul climatic. Interacțiunile dintre US și atmosferă au un impact semnificativ asupra ciclului apei și energiei, precum și asupra gazelor cu efect de seră, inclusiv dioxidul de carbon, în special atunci când se iau în considerare straturile de vegetație [3], [4]. Apa are o circulație naturală: se evaporă, trece din formă lichidă în formă gazoasă, apoi se recondensează în lichid. Apa absorbită de plante în timpul fotosintezei devine parte integrantă a carbohidraților, care, prin descompunere, se transformă din nou în apă. Interacțiunea complexă dintre apă și atmosferă, împreună cu diversele compoziții de vegetație și de sol, face ca US să fie un factor critic în înțelegerea și modelarea sistemului climatic al Pământului, a productivității agricole și a sănătății ecosistemelor. Influența sa se extinde de la creșterea locală a plantelor până la modelele climatice globale. Predicția US utilizând tehnologii de teledetecție a fost un domeniu activ de cercetare în ultimele decenii.

Modelele electromagnetice, în special modelele de retro-împrăștiere a semnalului radar de pe suprafața solului, sunt concepute pentru a simula interacțiunile dintre semnalul radar și țintă și, prin inversare, este posibilă estimarea unor parametri precum US și RSS. Am utilizat model de ecuații integrale (MEI) pentru a genera un set de date împreună cu profile de suprafață simulate cu corelație gaussiană, care includ valori variabile ale parametrilor RSS și US, și le-am codificat în imagini color generate de calculator, care reprezintă intrările pentru modelul RNC. Estimările de retro-împrăștiere pentru canalele de polarizare vertical-vertical (VV, co-polarizate) și vertical-horizontal (VH, cross-polarizate) obținute din simularea MEI au fost utilizate ca variabile țintă în modelul RNC. Mai mult, pe baza acestei cercetări intenționăm să integrăm scene mai complexe și, în cele din urmă, să înlocuim imaginile sintetice generate de calculator cu unele reale.

1.6 Schemele Plantelor

În contextul RAS, al interacțiunii dintre sol și plante, am desfășurat multiple campanii de măsurători în teren și am colectat date privind caracteristicile fizice ale culturilor de grâu, cum ar fi dimensiunile frunzelor și numărul acestora. Datele au fost ulterior folosite pentru a crea scheme generate de calculator ale grâului și solului. Am utilizat schemele generate de calculator pentru a clasifica stadiile de creștere ale culturii și valorile de retro-împrăștiere RAS asociate.

1.7 Vizualizarea și Compresia Imaginilor Hiperspectrale

Una dintre principalele provocări în imaginile hiperspectrale (IHS) este vizualizarea acestora, deoarece IHS contin de la zeci până la sute de benzi, iar ecranele pe care le utilizăm afisează doar trei benzi, si anume: rosu, verde si albastru. Există diverse moduri de a vizualiza IHS si s-a efectuat un număr semnificativ de cercetări în domeniu. În funcție de scopul aplicației, se poate alege metoda de vizualizare: în timp ce unele metode se concentrează pe selecția cea mai naturală a benzilor de roșu, verde și albastru (RGB), altele se axează pe evidențierea diferitelor materiale din scenă. În plus, aceste metode pot fi clasificate în funcție de tehnica generală implicată. În literatura de specialitate, acestea au fost clasificate în cinci categorii, și anume: metode bazate pe selecția benzilor, metode bazate pe analiza componentelor principale (PCA), metode liniare, metode bazate pe tehnici de procesare digitală a imaginilor și metode bazate pe învățarea automată/învățarea profundă [5]. Propunem o metodă de a mapa lungimea de undă dominantă (λ) a fiecărui pixel la un triplet RGB și utilizăm un tabel al valorilor RGB pentru fiecare lungime de undă între 380 și 781 nm. Fiecare suprafață, cum ar fi corpurile de apă, vegetația și solul expus, are o semnătură unică a luminii reflectate; astfel, presupunem că anumite benzi din radiația reflectată au una dominantă care poate dezvălui informații despre scenă atunci când este afișată. Metoda, aplicată la nivel de pixel, are avantajul simplității prin evidențierea benzii cele mai reflectorizante, dar, din acelasi motiv, dezavantajul constă în faptul că utilizează doar o singură bandă și ignoră restul.

Informațiile spectrale detaliate din IHS le fac versatile și utile, însă conduc, de asemenea, la un volum mare de date. Una dintre provocările în imagistica hiperspectrală este transferul și stocarea eficientă a datelor, păstrând în același timp informațiile spectrale și spațiale. Au fost propuse diverse metode de compresie a IHS, care pot fi clasificate în metode bazate pe transformare, predicție, învățare și cuantizare vectorială [6]. De asemenea, este obișnuit să le împărțim în două clase: compresie fără pierderi și compresie cu pierderi. Am propus o tehnică de compresie cu pierderi, care se bazează pe două ipoteze fundamentale: prima, că funcțiile exponențiale negative aproximează adecvat spectrele Fourier ale profilurilor de reflectanță ale pixelilor hiperspectrali; a doua, că RNA pot învăța eficient mapări între aceste reprezentări exponențiale negative și curbele reale de reflectanță spectrală. Această formulare exponențială negativă capturează caracteristicile spectrale esențiale, eliminând informațiile redundante, rezultând o reducere substanțială a volumului de date. A doua ipoteză valorifică progresele recente din ÎA care demonstrează capacitatea RNA de a recunoaște și modela relații complexe între date.

1.8 Detectarea Timpurie a Câmpurilor de Cultură

Identificarea tipurilor de culturi în mediul agricol reprezintă un domeniu activ de cercetare și abordează provocări precum lipsurile culturii, prognoza producției, evaluarea și deciziile de adaptare [7]. Având în vedere natura intensă a datelor provenite din imaginile satelitare, una dintre modalitățile eficiente de extragere a informațiilor utile este utilizarea ÎA și, în mod particular, a modelelor ÎP. Aceste modele, în special cele complexe (rețele neuronale mai profunde), sunt capabile să exploreze și să extragă informații relevante din surse de date multimodale, folosind caracteristici spațiale, spectrale și temporale, fiind totodată adaptabile la schimbările din mediu [8]. Procesul de bilonare pe câmpurile de cartofi, în special, generează motive distincte. Multe studii s-au concentrat pe identificarea câmpurilor în timpul sezonului de creștere, unde caracteristicile culturilor contribuie direct la NDVI, care poate fi detectat cu ajutorul

camerelor multispectrale [9]. Totuși, doar câteva studii au considerat aceste motive rezultate din bilonare utile. Într-un astfel de studiu, a fost utilizată o AFP pentru colectarea datelor, iar matricea de co-ocurență a nivelurilor de gri a fost folosită ca o caracteristică de textură, ceea ce a îmbunătățit semnificativ acuratețea clasificării [10]. Unele studii au folosit aspectul temporal al rotației culturilor din ultimii cinci sau mai mulți ani pentru a prezice harta culturilor din anul următor, bazându-se pe modelele anterioare de rotație în locul caracteristicilor reale ale câmpului [11]. Noi propunem o abordare bazată pe utilizarea combinată a datelor multispectrale și RAS pentru a identifica câmpurile de cartof după bilonare și înainte de creșterea culturii.

Rugozitatea Solului

2.1 Metoda Lanțului

Această metodă oferă o măsurare unidimensională a profilului solului și reprezintă o soluție economică pentru determinarea RSS. Rugozitatea lanțului (Cr) este raportul dintre distanța parcursă pe suprafață $(L_1 = 1m)$ și distanța euclidiană (L_2) măsurată cu rigla. Cr se calculează astfel [12]: $Cr = \left(1 - \frac{L_2}{L_1}\right) \times 100$ Figura 2.1 a) ilustrează utilizarea lanțului cu riglă într-una dintre campaniile de teren.

2.2 Metoda Panoului cu Tije

Metoda panoului cu tije este utilizată frecvent pentru determinarea indicelui de RA. În formularea lui Allmaras (1966) [13], rugozitatea este cuantificată ca logaritmul natural al SD calculată din multiple măsurători ale înălțimii — după eliminarea erorilor precum panta, rugozitatea direcțională sau cele 10% superioare și inferioare ale datelor. Ulterior, Cremers et al. (1996) [14] au sugerat că corectarea exclusiv pentru efectele pantei este suficientă, definiție pe care am adoptat-o aici. Panoul nostru construit are un cadru de 73 cm lățime și dispune de 53 de tije din aluminiu, ulterior înlocuite cu tije de lemn negri, fiecare având 33 cm înălțime, spațiați la 12.5 mm și cu diametrul de 3 mm. Datele au fost capturate utilizând un Canon 5D Mark II, așa cum se arată în Figura 2.1.



a) Lant in situ

b) Panou cu tije în laborator

c) Panou cu tije in situ

Figura 2.1: Aplicarea configurațiilor de lanț și panou cu tije.

2.3 Experimente Preliminare

Experimentele preliminare au fost efectuate în laborator cu suprafețele sintetice (a) suprafață plană, (b) regulată, (c) cvasi-regulată și (d) neregulată (Figura 2.2). Suprafața plană a fost utilizată pentru a măsura eroarea panoului cu tije, care este rezultatul inegalității în înălțimile tijelor, fiind de aproximativ 1mm pentru tijele metalice și mai puțin pentru cele de lemn. Acest lucru se datorează faptului că tijele metalice

au fost tăiate manual, iar procesul a introdus imperfecțiuni. Am măsurat rugozitatea suprafeței suprafețelor artificiale folosind metoda panoului cu tije și metoda lanțului. Tabelul 2.1 prezintă rezultatul în care deviația standard a înălțimilor tijelor din panou și *Cr* reprezintă o măsură directă a RSS. * indică faptul că măsurătorile au fost efectuate exact pe aceeași linie, adică tijele din panou au fost plasate exact deasupra lanțului. Am efectuat, de asemenea, măsurători fără a plasa tijele deasupra lanțului, ci folosind pur și simplu aceeași linie de pe suprafață și am obținut o corelație de peste 90%. Pentru a calcula coeficientul de corelație (CC) Pearson, este necesar să avem mai multe puncte de măsurare pentru fiecare metodă și acestea trebuie obținute de pe aceeași linie a suprafeței. Cu toate acestea, suprafața reală a solului este mai puțin deterministă, în special la scară mică, unde interacțiunea dintre tije și lanțuri are loc. Aceasta este una dintre principalele dezavantaje ale acestor metode; celălalt este faptul că captăm doar o dimensiune (1D). Chiar dacă măsurătorile au fost efectuate la mai multe locații pe câmpul dat, valorile pot varia considerabil, astfel că am explorat potențialul AF și DF ca măsură a RSS.



(a) plană

(b) regulată (c) cvasi-regulată (d) neregulată

Figura 2.2: Suprafețe de sol artificiale [15].

Nume	Probă A	Probă B	Probă C	Probă D
C_r	0	6.57	25.29 (16.52)	2.44
$C_r *$	0	7.5	15.03 (13.91)	2.1
SD	0.094	0.27	1.01 (0.92)	0.35
SD*	0.094	0.31	0.52 (0.58)	0.29

Tabela 2.1: SD și Cr probelor de suprafață de sol artificial [15].

2.4 Imagini Digitale ale Motivelor Laser Reliefate pentru Estimarea Rugozității Suprafaței Solului

Similar principiilor de funcționare ale RAS, scanare laser terestră se bazează pe un senzor activ care emite milioane de impulsuri luminoase în loc de microunde, apoi primește punctele discrete de date reflectate. Măsurând timpul de zbor pentru fiecare punct de date, acesta determină coordonatele X, Y și Z ale fiecăruia. O altă metodă ce se bazează pe fasciculele de lumină este profilometria cu laser, care nu utilizează timpul de zbor, ci folosește o cameră și metode de triangulație optică pentru a extrage un profil 3D al suprafeței. Aceasta are o rezoluție spațială înaltă, analizând suprafețele în detalii fine, însă este de obicei limitată la zone restrânse. Inspirându-ne din profilometria cu laser, propunem o abordare care utilizează un laser simplu, ce emite lumină roșie, poziționat orizontal deasupra suprafețelor de probă, permițând astfel o profilare detaliată a suprafețelor. Această abordare este mai apropiată ca principiu de profilometria cu laser, însă îi lipsește rezoluția spațială și nu folosește metode de triangulație pentru a realiza o hartă 3D detaliată a suprafeței. În plus, imaginile suprafețelor reliefate cu laser sunt capturate de la distanță cu Canon 5D Mark II, dar pot fi obținute și cu orice cameră suficient de capabilă pentru a surprinde clar motivul laser. Pentru a estima rugozitatea solului, am utilizat un tip de RNA numită RNC,

mai exact ResNet-18 [2]. Avantajul acestei abordări este simplitatea și costul redus.

2.4.1 Colectarea și Procesarea Datelor Imagistice

Am proiectat laserul pe suprafețe artificiale (Figura 2.2) și pe o suprafață reală de sol în interiorul laboratorului. Figura 2.3 prezintă imaginile de probă; este important de menționat că am capturat mai multe profiluri pentru fiecare suprafață, cu excepția celei plane. Începând cu primul rând, care reprezintă o versiune decupată a scenei reale (deoarece camera îndreptată la 30° captura o zonă mai largă), al doilea rând arată o versiune în tonuri de gri a imaginilor, în timp ce al treilea rând prezintă o formă binarizată ce evidențiază motivul laser de fundal. Tabelul 2.2 prezintă valorile RSS pentru suprafețele artificiale și solul real. În total, avem cinci suprafețe, dar șase clase, deoarece, în cazul suprafeței aproape regulate, am obținut valori RSS diferite atunci când acele au fost plasate pe turnuri și pe suporturi din coșuri de ouă, rezultând astfel două clase pentru suprafața aproape regulată. Deși celelalte suprafețe, cu excepția celei plane, au fost glisate sub panoul cu tije și linia laser, nu am obținut o diferență semnificativă a valorii RSS.

plan	regulat	cvasi-regulat	neregulat	sol real
0.094	0.271	1.011, 0.922	0.347	0.826

Tabela 2.2: Valori RRS ale solului artificial și real, măsurate cu panoul de tije.



Figura 2.3: Exemple decupate din imaginile RGB ale proiecțiilor unei linii laser roșii peste suprafețe (rândul 1), în tonuri de gri (rândul 2), alb-negru—binarizate (rândul 3) [16].

Pentru a crește robustetea rețelei neuronale artificiale, am adoptat multiple tehnici de augmentare a datelor de antrenare. În general, acestea pot fi împărțite în două proceduri: i) augmentarea prin adaugarea de zgomot; ii) transformarea imaginilor. Deși imaginile inițiale erau binare, pentru a efectua augmentarea prin adaugarea de zgomot, imaginile trebuie să aibă valori continue. Mărirea numărului de imagini este, de asemenea, o abordare eficientă pentru a crește numărul de eșantioane, în cazul nostru, de la 27 la 972.

ResNet-18 RNC

Rețeaua ResNet-18 RNC rezolvă problema gradientului care se estompează a rețelelor neuronale profunde prin utilizarea conexiunilor reziduale (skip). Gradientul calculat în timpul propagării inverse poate deveni foarte mic ("se estompează") pe măsură ce se deplasează înapoi prin fiecare strat. Ca rezultat, actualizările ponderilor în straturile timpurii devin foarte mini sau chiar se opresc. Blocurile reziduale din ResNet creează o cale scurtă, astfel încât, în loc de o mapare directă a intrării x la ieșire cu funcția H(x), fiecare bloc învață funcția reziduală F(x), iar ieșirea finală devine H(x) = x + F(x). Acest proces permite gradientelor să curgă mai ușor către straturile inițiale, permițând rețelei să performeze bine chiar și în straturi mai adânci. Am utilizat biblioteca Pytorch pentru a folosi ResNet-18, care are 18 straturi, preantrenată pe setul de date ImageNet, și am modificat ultimul strat pentru a clasifica imaginile profilului laser în șase clase. În experimentele noastre, am antrenat rețeaua folosind optimizatorul Adam [17] și funcția de pierdere cross-entropy.

2.4.2 Rezultate Experimentale

Rezultatele antrenării și validării indică faptul că modelul poate învăța cu ușurință din motivele laser și le poate asocia cu valorile RSS. Având în vedere numărul limitat de eșantioane de suprafețe, am abordat problema ca pe una de clasificare, dar, în cazul disponibilității de date, problema poate fi formulată ca o problemă de regresie, iar modelul se poate aștepta să prezică valori continue de RSS. Două tipuri de grafice au fost luate în considerare pentru interpretarea rezultatelor: graficele de progres și matricile de confuzie. Graficele de progres afișează pierderea și acuratețea în funcție de epoci, atât pentru antrenament, cât și pentru validare, în timp ce matricile de confuzie arată numărul de eșantioane clasificate corect și incorect, indicând cât de bun este modelul în termeni de acuratețe per clasă. Setul nostru de date prezintă un dezechilibru între clase, dar nu am folosit explicit nicio tehnică pentru a compensa acest aspect. În cele cinci experimente, modelul a obținut o acuratețe de antrenare de până la 99,74% (cu o pierdere de 0,0160 într-un caz), menținând în mod constant o acuratețe de validare perfectă de 100% (cu o pierdere de validare de până la 0,0037).

2.5 Estimarea Rugozității Suprafaței Solului din Imagini Digitale Folosind Analiza Fractală

În 1983, Mandelbrot a introdus conceptul de geometrie fractală ca mijloc de a descrie mulțimile autosimilare, cunoscute astăzi sub numele de fractali [18]. Un parametru central în acest cadru este DF, care cuantifică complexitatea și gradul de ocupare a spațiului al acestor structuri neregulate. Deși dimensiunea fractală Hausdorff oferă un fundament teoretic riguros pentru obiectele continue, aplicarea sa practică este limitată de formularea sa abstractă.

Metoda descrisă în [19] a fost folosită ca bază, iar noi am adaptat-o pentru a funcționa cu imagini bidimensionale în tonuri de gri și semnale unidimensionale. Imaginile 2D ale suprafeței solului au fost decupate și redimensionate din imaginile mult mai mari ale suprafețelor reale de sol din câmpurile agricole, la o zonă de interes de dimensiuni 256×256 pixeli. De asemenea, am extras linii 1D de dimensiune 1×256 pixeli din imaginea dată și le-am mediat, calculând profilul mediu (AP). Acesta poate fi formulat după cum urmează:

$$AP = \frac{1}{N} \sum_{i=1}^{N} l_i$$

unde l_i reprezintă linia i a fiecărei imagini. În experimentele din [20], cercetătorii au folosit un panou cu tije glisant și au mediat măsurătorile pentru a crește precizia achiziției 1D, astfel încât am adoptat o abordare similară în analiza fractală și am estimat dimensiunea fractală a profilului mediu 1D al imaginilor digitale ale suprafeței solului.

2.5.1 Achiziția și Preprocesarea Imaginilor

Iluminarea naturală are efecte semnificative asupra achiziției imaginilor in situ; poziția soarelui pe parcursul zilei poate crea umbre sau variații de luminozitate în funcție de unghiul azimutal și de prezența norilor. Este importantă menținerea unor condiții de iluminare constante pentru a obține măsurători fiabile. Am dezvoltat o configurație de lucru de tip "cutie neagră", așa cum este descrisă în Figura 2.4, care izolează zona de interes (ZdI) de lumina exterioară, oferind în același timp iluminare artificială din interior, folosind benzi LED controlate. Orificiul pentru obiectivul aparatului foto este proiectat astfel încât acesta să poată intra complet, menținând în același timp intervenția minimă. Am folosit aceeași

cameră digitală Canon 5D Mark II pentru experimentele cu profilul laser, care dispune de 21 megapixeli, oferind o rezoluție suficientă. Am achiziționat un total de 12 imagini în diferite locații dintr-un câmp agricol extins.

Imaginile trebuie preprocesate înainte de aplicarea Analizei Fractale, iar pașii sunt următorii: imaginile RGB au fost convertite în tonuri de gri, eliminând informația de culoare; fiecare imagine a fost decupată de 7 ori, în mod suprapus, pentru a crește numărul de eșantioane pentru analiza de corelație, și redimensionată la 256×256 . Luminozitatea pixelilor a fost, de asemenea, ajustată pentru fiecare imagine, asigurând o consistență și mai mare între imagini. În urma pașilor de preprocesare, am obținut un total de 84 de imagete.



Figura 2.4: Diagramă bloc care descrie configurarea cutiei utilizate pentru achiziția imaginilor [15].



Figura 2.5: Imagete preprocesate ale suprafețelor solului, preluate din 12 locații diferite și utilizate pentru AF [15].

2.5.2 Rezultate Experimentale

S-a efectuat o analiză de tip regresie, în paralel cu determinarea coeficientului de corelație Pearson (CC), pentru trei seturi distincte de date: măsurători in situ, metode de referință (lanț și panou cu tije) și analiza fractală a decupajelor de imagini. Deși rezultatele de laborator obținute prin metodele de referință au fost

puternic corelate, aplicarea practică nu a evidențiat o corelație între metodele lanț și panou cu tije, fapt ce se datorează probabil discrepanțelor în liniile de măsurare la sol. Corelația maximă între metodele de referință și analiza fractală a fost de 0.34. În Figura 2.6 se prezintă datele și linia de regresie pentru măsurătorile cu panou cu tije și DF ale celor 84 de imagete reprezentând imagini digitale ale suprafeței solului (stânga) și măsurătorile cu lanț și DF al AP al celor 12 de imagini corespunzătoare celor 12 locații de măsurare (dreapta).



Figura 2.6: Analiza corelației pentru panou cu tije și DF ale celor 84 de decupaje de imagini digitale ale suprafeței solului (CC=0.34) și pentru lanț și DF a celor 12 AP de imagini (CC=0.33) [15].

2.6 Analiza Fractală a Imaginilor Multispectrale ale Suprafeței Solului de la Diferite Altitudini

Vom explora în continuare AF a suprafețelor solului expuse pentru a cuantifica RSS. În timp ce în secțiunea anterioară am utilizat o metodă invazivă prin plasarea unei cutii peste suprafața solului, în această secțiune ne concentrăm pe o vedere "de sus" (bird-eye view) a câmpurilor agricole în cazul solului expus. RSS este un parametru complex și, în funcție de rezoluția spațială, poate oferi diverse perspective. În funcție de aplicație, rezoluția și acoperirea areală pot varia. Metoda anterioară viza RA și reprezenta o abordare alternativă la metodele tradiționale, cum ar fi panoul cu tije și lanțul, care relevează variații mai fine ale suprafeței solului și ajută la înțelegerea interacțiunii microundelor (achiziții RAS) cu suprafața. Pe de altă parte, este important să se înțeleagă complexitatea suprafeței solului dintr-o perspectivă mult mai largă, în special pentru aplicații bazate pe instrumente RAS spațiale cu rezoluție mai joasă. Pentru a aborda acest aspect, am utilizat o cameră multispectrală montată pe AFP care capturează un total de cinci benzi în spectrul vizibil și în infraroșu apropiat. AF are o gamă largă de aplicații, cum ar fi în semnale, imagini, texturi, structuri etc. [21]. În această secțiune, metoda estimatorului DF multispectral din [22] a fost adoptată și adaptată pentru analiza imaginilor multispectrale cu cinci benzi.

2.6.1 Achiziția și Prelucrarea Datelor

Drona Trinity F90+ echipată cu camera multispectrală MicaSense RedEdge-MX a fost folosită pentru achiziția datelor. Această dronă de înaltă performanță se remarcă prin construcția din fibră de carbon, oferind un raport excelent durabilitate-greutate, integrând sisteme de propulsie fără perii împreună cu componente de navigație precum GPS, giroscoape și accelerometre. Este autonomă și execută trasee de zbor prestabilite, menținând un control precis al altitudinii și realizând modele complexe cu supraveghere minimă datorită capacităților sale avansate de navigație. Platforma suportă multiple protocoale de comunicație—permițând operarea de la distanță. Rezistența la condiții meteorologice nefavorabile și autonomia extinsă a zborului o fac potrivită pentru aplicații de teledetecție agricolă în condiții de câmp variabile.

Camera integrată MicaSense RedEdge-MX reprezintă o tehnologie avansată de imagistică multispectrală, proiectată special pentru analiza agricolă de precizie și evaluarea mediului. Senzorul oferă date spectrale de înaltă rezoluție, critice pentru monitorizarea sănătății vegetației, identificarea stresului și evaluarea biomasei în diverse ecosisteme. Sistemul său optic încorporează cinci senzori de bandă îngustă, calibrați cu precizie, care captează intervale discrete de lungimi de undă: benzi albastre, verzi, roșii, red-edge și în infraroșu apropiat. Fiecare bandă furnizează informații distincte și detaliate privind starea fiziologică a plantei, având o sensibilitate deosebită la conținutul de clorofilă, structura celulară și variațiile conținutului de apă în vegetație. Calibrarea radiometrică a sistemului asigură măsurători consistente în condiții variate de iluminare.

Înainte de aplicarea AF, imaginile au necesitat preprocesare, începând cu normalizarea valorilor de intensitate a pixelilor între 0 - 255. Ulterior, cele cinci imagini ale benzilor spectrale (în tonuri de gri) au fost aliniate folosind algoritmul de detecție a trăsăturilor SURF [23], unde imaginea red-edge a fost utilizată ca referință, deoarece senzorul acesteia este situat în centrul camerei. Având în vedere că algoritmul AF funcționează eficient cu imagini de dimensiuni 256×256 , am extras un total de 12 decupaje non-suprapuse din fiecare imagine, iar Matlab a fost folosit pentru a efectua toți pașii de preprocesare. AF a fost aplicată pe imagini în tonuri de gri (pentru benzile individuale), imagini RGB, imagini în tonuri de gri convertite din RGB și pe imagini multispectrale complete cu cinci benzi.

2.6.2 Rezultate Experimentale

Smart Intuitive Drones SRL a desfășurat campania de achiziție peste un câmp agricol situat la Institutul de Cercetare și Dezvoltare al Universității Transilvania din Brașov (coordonate: 45.669340, 25.550753). Rândul superior al Figuri 2.7 prezintă trei imagini RGB decupate, achiziționate la o altitudine de 60m, în timp ce rândul inferior arată imagini RGB obținute la o altitudine de 80m. Figura 2.8 (a) prezintă distribuția valorilor DF pentru imaginile în tonuri de gri, convertite din imagini color RGB. Se poate observa că distribuția FD a imaginilor în tonuri de gri, achiziționate la altitudini diferite, prezintă o ușoară diferență, în timp ce pentru imaginile RGB (Figura 2.8 (b)) diferența este mai pronunțată, așa cum era de așteptat, deoarece imaginile RGB au o complexitate mai ridicată comparativ cu cele în tonuri de gri. Figura 2.9 arată, în final, că distribuția DF a imaginilor multispectrale la 60m și 80m evidențiază, din nou, o complexitate mai mare comparativ cu imaginile în tonuri de gri și RGB.



Figura 2.7: Imagini RGB decupate de la altitudini de 60 m (rândul de sus) și 80 m (rândul de jos) [24].

Tabelul 2.3 arată media și dispersia valorilor DF din histogramele din Figurile 2.8 (a) și (b), precum și 2.9. DF tinde să crească odată cu mărirea rezoluției spectrale și a altitudinii, iar media (μ) oferă o imagine rapidă a acestor schimbări. Observați că media pentru imaginile în tonuri de gri este aproape identică pentru altitudinile de 60m și 80m, sugerând că imaginile monocromatice ar putea să nu capteze toate detaliile suprafeței solului. Deoarece aceste imagini au fost preluate pe un câmp extins, din diferite



(a) Imagini în tonuri de gri (convertite din RGB)

(b) Imagini RGB

Figura 2.8: Distribuția valorilor DF pentru imaginile capturate la altitudini de 60 m și 80 m: (a) imagini în tonuri de gri (convertite din RGB) și (b) imagini RGB [24].



Figura 2.9: Distribuția valorilor FD ale imaginilor multispectrale de la 60m și 80m altitudine [24].

locații, media DF poate servi drept valoare reprezentativă pentru RA. În plus, deviația standard constant scăzută (σ) în toate setările sugerează că valorile DF sunt destul de uniforme.

	Tonuri de gri		Color		Multispectrale	
	μ	σ	μ	σ	μ	σ
60 m	2.83	0.06	3.48	0.16	3.82	0.23
80 m	2.81	0.056	3.62	0.16	4.07	0.17

Tabela 2.3: Media (μ) și abaterea standard (σ) ale valorilor DF ale imaginilor în tonuri de gri, culori și multispectrale de la 60m și 80m altitudini [24].

Două constatări cheie au reieșit din studiul nostru. În primul rând, adăugarea de benzi spectrale suplimentare crește complexitatea estimată a imaginii pentru o anumită scenă de teren. De fapt, în timp ce imaginile în tonuri de gri (pancromatice) nu au reușit să evidențieze vreo diferență între 60m și 80m, atât imaginile color, cât și cele multispectrale cu 5 benzi au relevat astfel de diferențe. În al doilea rând, am constatat că complexitatea solului și, prin extensie, estimarea RSS este mai mare la 80m, deși inițial se aștepta contrariul. Acest fenomen apare deoarece, la altitudini mai mari, detaliile terenului se micșorează, ceea ce crește numărul elementelor de frecvență înaltă în spectrul Fourier și, implicit, crește complexitatea. Pentru studiile viitoare, intenționăm să investigăm un interval mai larg de altitudini pentru a înțelege mai bine impactul acestora asupra complexității imaginii și a estimării RSS, să analizăm efectele amestecului spectral datorat integrării spațiale a senzorului și să evaluăm rolul benzii NIR în estimarea RSS.

Umiditatea Solului

Doi parametri principali influențează retro-împrăștierea semnalului radar: i) proprietățile geometrice ale scenei și ii) constanta dielectrică. În aplicațiile RAS pentru analiza solului, aceste proprietăți pot fi descrise prin parametrii RSS și US, deoarece RSS este legat de variabilitatea trăsăturilor geometrice ale suprafeței, iar US este strict legat de constanta dielectrică a solului [25].

Modelele electromagnetice, în special cele pentru retro-împrăștierea semnalului radar, sunt concepute pentru a simula interacțiunile dintre semnalul radar și țintă și, prin inversarea acestora, este posibilă estimarea unor parametri precum US și RSS. Aceste modele pot fi împărțite în trei categorii: empirice, semi-empirice și bazate pe fizică [26]. Abordările empirice, cum ar fi cea adoptată în modelul Dubois [27], și cele semi-empirice, precum modelul Oh [28], se bazează pe date extinse de teren pentru calibrare. Modelele bazate pe fizică sunt MEI [29] și versiunile derivate ale acestuia, cum ar fi *IEM_B* de Baghdadi [30], și Model Avansat de Ecuații Integrale [31].

În acest studiu, am generat profiluri de suprafață cu corelație gaussiană care includ valori variabile ale parametrilor RSS și US și le-am codificat în imagini color generate pe calculator, care servesc drept intrări pentru modelul RNC. Estimările de retro-împrăștieri pentru canalele de polarizare vertical-vertical (VV, co-polarizate) și vertical-orizontal (VH, cross-polarizate) provenite din simularea MEI au fost folosite ca variabile țintă în modelul RNC. Mai mult, pe baza acestei cercetări, intenționăm să integrăm scene mai complexe și, în final, să înlocuim imaginile sintetice generate pe calculator cu imagini reale.

3.1 Metodologie

Cercetarea este formulată în jurul a două întrebări: 1) putem dezvolta o abordare ÎA eficientă, menținând o acuratețe ridicată, pentru a înlocui modelul MEI, care este intensiv din punct de vedere computațional și complex, în predicția retro-împrăștieri RAS de pe suprafețele solului expus?; 2) cum afectează reprezentarea parametrilor RSS și US ca date de imagine, în loc de parametri scalari, capacitatea modelului ÎA de a capta retro-împrăștierea în diferite polarizări radar?

Raționamentul științific din spatele metodologiei este următorul: i) deși modelele bazate pe fizică, precum MEI, sunt precise în multe cazuri [32], acestea sunt complexe și dificil de ajustat și adaptat la diferite scenarii; ii) reprezentarea parametrilor RSS și US sub formă de imagini permite rețelelor RNC să capteze natura lor inerent spațială și modele complexe, păstrând relațiile spațiale; iii) reprezentările de tip imagine creează un cadru pentru cercetări viitoare, care să includă stratul de vegetație și modificările temporale, fiind în același timp intuitive și explicabile. Metodologia include generarea de scheme de imagini pentru sol, cu valori variabile de RSS și US, și predicția valorilor de retro-împrăștiere prin simularea MEI. Ulterior, imaginile sunt utilizate ca intrări pentru RNC, iar valorile de retro-împrăștiere provenite din simularea MEI sunt folosite ca variabile țintă (vezi Figura 3.1).



Figura 3.1: Diagramă bloc a abordării propuse.

3.1.1 MEI Simplificat

MEI se bazează pe ecuațiile lui Maxwell care iau în considerare condițiile la interfața dintre două medii; în cazul agricol, acestea sunt adesea solul și stratul de vegetație. Când RSS este relativ mic în comparație cu lungimea de undă, se utilizează expansiunea în perturbări, unde câmpul împrăștiat este exprimat ca o serie. MEI este un model bazat pe fizică și respectă principii fundamentale, cum ar fi conservarea energiei și reciprocitatea. Mai jos este prezentat MEI simplificat pentru cazul co-polarizat, bazat pe capitolul de carte al lui A. K. Fung și K. S. Chen (2010) [32]. Alte cazuri de polarizare și detalii pentru scenarii diferite pot fi găsite în referință. Formele generale ale coeficienților de retro-împrăștiere pentru polarizarea verticală, σ_{vv}^0 , pentru polarizarea orizontală, σ_{hh}^0 , și pentru polarizarea încrucișată, σ_{vh}^0 , sunt prezentate mai jos.

$$\sigma_{pp}^{0} = \frac{k^{2}}{4\pi} \exp\left[-2k^{2}\sigma^{2}\cos^{2}\theta\right] \sum_{n=1}^{\infty} |I_{pp}^{n}|^{2} \frac{w^{(n)}(2k\sin\theta, 0)}{n!}$$
(3.1)

3.1.2 Generarea Numerică a Suprafeței

Simularea MEI presupune suprafețe cu proprietăți statistice bine cunoscute, cum ar fi suprafețele cu corelație gaussiană sau exponențială, care, de obicei, seamănă îndeaproape cu suprafețele naturale. În acest studiu, am utilizat o suprafață cu corelație gaussiană, deoarece funcția sa de autocorelație (ACF) este corelată cu profilurile suprafeței solului măsurate cu panoul cu tije, colectate în campania de teren anterioară, având un coeficient de corelație de $R^2 = 0.88$. Doi parametri importanți sunt folosiți pentru a descrie RSS în simulările de suprafață: abaterea medie pătratică a înălțimilor suprafeței (σ) și lungimea de corelație (l). Parametrul σ descrie variațiile verticale ale înălțimii suprafeței, în timp ce l captează profilul orizontal al suprafeței. Am urmat îndeaproape tehnica descrisă în [33] pentru a genera o suprafață de tip gaussian. Valoarea l se poate calcula în punctul în care funcția de autocorelație scade la 1/e (aproximativ 0.368) din valoarea sa maximă, punct în care înălțimile suprafeței devin decorrelate. Distanța de decalaj în autocorelația spațială se referă la separarea fizică dintre perechile de observații în spațiu. Figura 3.2 ilustrează cele două profiluri de suprafață pe o distanță de (L = 200), unde suprafața A reprezintă o suprafață mai rugoasă ($\sigma = 2$) decât suprafața B ($\sigma = 0.7$), iar l = 4 în ambele cazuri. Toți parametrii suprafeței sunt exprimați în centimetri (cm).

3.1.3 Conținutul de Umiditate al Solului

Permitivitatea dielectrică a solului este un parametru esențial în simularea RAS, deoarece este direct corelată cu conținutul de US [34], [35]. În simularea noastră MEI și ca intrare pentru modelul RNC, am variat US de la 1% la 50% cu increment de 1%. Când caracteristicile solului sunt reprezentate sub formă de imagini, conținutul de umiditate este codificat prin culoare: maro deschis indică sol uscat, iar maro închis indică sol umed (vezi Figura 3.3).



Figura 3.2: Două probe de profil de suprafață cu $\sigma = 2$ și $\sigma = 0.7$.



Figura 3.3: Conținutul de US este codificat folosind un gradient de culoare de la maro deschis la maro intens, reprezentând rezoluția umidității solului de la 0% la 50% saturație.

3.1.4 Date MEI și RNC

Datele MEI au fost generate folosind simularea MEI și conțin 50 de valori de umiditate, de la 1% la 50%, pentru fiecare valoare RSS de la 0.1 la 2, totalizând 1000 de valori estimate de retro-împrăștiere VV și VH fiecare. Aceste valori au fost ulterior folosite ca variabile țintă în modelul RNC. Am utilizat un model RNC, în special o rețea de învățare reziduală profundă, ResNet-18, care depășește problema dispoziției gradientului și este proiectată în principal pentru sarcini de clasificare a imaginilor [2]. Totuși, prin modificarea stratului final, modelul a fost adaptat pentru o sarcină de regresie. Este important de menționat că au fost folosite două modele ResNet-18 independente pentru a prezice câte o ieșire specifică (VV și VH), deoarece un singur model a prezentat performanțe mai reduse atunci când încerca să prezică ambele ieșiri simultan. Mai mult, după codificarea valorilor RSS și US în imagini, acestea au fost redimensionate la $224 \times 224 \times 3$ și împărțite în seturi de antrenament și testare în proporții de 80% și, respectiv, 20%. Modelul utilizează funcția de pierdere eroarea pătratică medie (MSE - Mean Squared Error), optimizatorul Adam cu o rată de învățare de 0.001, iar antrenarea s-a desfășurat timp de 50 de epoci.

3.2 Rezultate și Discuții

Figura 3.4. arată imaginile sintetice generate de sol gol cu diverse RSS și US. Figura 3.5 arată modul în care procesul de antrenare și pierderea testului progresează în 50 de epoci. Pierderea MSE scade brusc în primele epoci, iar apropierea strânsă dintre pierderile de antrenare și teste sugerează că modelul converge bine fără a se supraadapta. Table 3.1 arată valoarea scorului compus la cel mai bun model, împreună cu antrenarea și pierderile de test.



(a) RSS = 0.5, US = 50% (b) RSS = 1.1, US = 5% (c) RSS = 1.5, US = 41% (d) RSS = 1.8, US = 18%

Figura 3.4: Imagini sintetice generate de sol cu diferite niveluri de RSS și US.



Figura 3.5: Antrenează și testează grafice de pierderi pentru canalele de polarizare (a) VV și (b) VH.

Metric (MSE)	VV (dB)	VH (dB)
Pierdere, finală de antrenare	1.3195	3.3288
Pierdere finală pe test	0.9240	0.9298
Pierdere min. de antrenare	1.0194	2.1891
Pierdere min. pe test	0.2740	0.3544
Pierdere de antrenare la cel mai bun model	1.0983	2.1891
Pierdere pe test la cel mai bun model	0.6596	1.3439
Scorul compus la cel mai bun model	0.7431	1.3378
Epoca celui mai bun model	48/50	41/50

Tabela 3.1: Valori de performanță de antrenare și testare pentru canalele VV și VH.

Estimarea precisă a US și RSS prin retro-împrăștierea RAS este importantă pentru monitorizarea mediului și managementul agricol. În timp ce MEI a fost utilizat pe scară largă pentru simularea semnalelor radar pe baza teoriei transferului radiativ, complexitatea sa computațională și adaptabilitatea limitată restricționează aplicabilitatea acestuia. Am prezentat un nou cadru de învățare profundă care emulează MEI, menținând o acuratețe acceptabilă atât pentru coeficienții de retro-împrăștiere polarizați VV, cât și VH.

Schițele Plantelor

4.1 Metodologie și Date

Parametrii specifici culturilor și solului au fost colectați prin cinci campanii de teren, iar un număr egal de clase a fost creat, incluzând solul expus și patru stadii de creștere a culturilor. Colectările de date de teren au fost realizate în aceeași zi cu achiziția RAS Sentinel-1 peste câmpul de grâu aparținând INCDCSZ, situat la următoarea locație GPS: 45°40'22.2"N, 25°32'28.1"E. Pentru clasificare, a fost utilizat modelul RNC ResNet-18, care a diferențiat cele cinci stadii (sol expus și patru stadii de creștere a culturilor) și valorile medii ale retro-împrăștierii RAS din ZdI. Fiecare campanie de teren conținea 10 puncte de măsurare în interiorul unui câmp mare de grâu, pentru a acoperi varietatea profilurilor suprafeței solului și a dimensiunilor plantelor de grâu. La fiecare punct de măsurare, s-au colectat înălțimea plantei și lungimea frunzei de la două plante de grâu, totalizând 20 de înregistrări per stadiu de creștere, detaliate în Tabelul 4.1. Doar campania de măsurare pentru stadiul de creștere 3 a fost efectuată cu o zi după trecerea satelitului, în timp ce în toate celelalte cazuri Sentinel-1 a trecut peste zona de interes în aceeași zi. Înălțimea medie a plantei crește până la coacere (stadiile 1 până la 3). Cazul solului expus reprezintă prima măsurare de teren, unde s-a folosit un panou cu tije [13] pentru măsurarea RSS. Tipul de RSS utilizat în acest studiu este RA, care este legat de stabilitatea agregatelor de sol [36].

Data	S0(24/03)	S1(25/05)	S2(09/06)	S3(30/06)	S4(27/07)
Înălțime min.	-	12.5	38.8	55.2	47.6
Înălțime max.	-	26	63.9	80.2	84.3
Înălțime med.	-	19.8	52.3	69.2	64.4
# min. de frunze	-	4	4	3	3
# max. de frunze	-	7	7	4	4
# med. de frunze	-	5	5	4	4
Lung. min. a frunzei	-	13.5	5	7	6.2
Lung. max. a frunzei	-	26.1	25.1	26.1	31
Lung. med. a frunzei	-	19.2	16.8	18.1	16.8

Tabela 4.1: Date (toate din 2023) și caracteristicile plantelor [cm] pentru cele cinci campanii de măsurare in situ [37].

Figura 4.1 ilustrează imagini reale ale culturii de grâu pentru fiecare stadiu și formele lor schematice generate de calculator. Parametrul de înălțime al culturii include tulpina și partea superioară, fiecare măsurate separat, iar în generarea imaginilor acestea fiind diferențiate. Parametrii culturilor din fiecare stadiu au fost utilizați pentru a crea o gamă și s-a aplicat o randomizare controlată pentru a genera un număr de imagini mai mare decât eșantioanele de bază per stadiu. Plantele de grâu sunt dispuse la o distanță de aproximativ 12.5 cm între ele (privire laterală perpendiculară direcției de semănat) iar imaginile sintetice au fost calibrate pentru a reflecta distanța corectă dintre plante, împreună cu profilul RSS. Pentru

a reda frunzele curbate ale grâului, s-a utilizat funcția curbă Bezier.



Figura 4.1: Stadiile de creștere a plantelor [37].

Pentru fiecare stadiu, inclusiv cazul solului expus, au fost generate 1000 de imagini, totalizând 5000 de imagini. Din aceste imagini, 80% au fost utilizate pentru antrenarea modelului și 20% pentru testare. Totuși, stratul de intrare a fost modificat pentru a primi imagini binare cu un singur canal, în loc de cele trei canale implicite, iar stratul de ieșire a fost adaptat pentru a clasifica imaginile în cinci clase. Modelul a fost antrenat și testat pe parcursul a 20 de epoci, cu o rată de învățare de 0.0001, fără scădere a ratei de învățare. Pentru sarcina de clasificare, s-a utilizat funcția de pierdere Cross-Entropy datorită eficienței sale în scenarii multi-clasă, împreună cu optimizer-ul Adam, care dispune de caracteristici adaptive pentru rata de învățare. Valorile medii ale coeficienților de retro-împrăștiere, obținute din cele cinci campanii, au fost folosite ca etichete, fiecare grupate la cele 1000 de imagini. Aceste etichete (valori țintă) pot fi interpretate diferit; interpretarea principală fiind clasificarea stadiilor de creștere ale plantelor, obținută prin asocierea coeficienților de retro-împrăștiere Sentinel-1 cu diferitele stadii de creștere identificate prin intermediul RNC. Această abordare diferă de estimarea directă a retro-împrăștierii, utilizând clasificarea schițelor generate pentru a deduce valorile de răspândire. Tabelul 4.2 prezintă valorile minime, maxime și medii ale răspândirii înapoi Sentinel-1 pentru fiecare stadiu.

Tabela 4.2: Sol expus, patru etape diferite ale plantelor de grâu și coeficienții de retro-împrăștiere (BS) minim și maxim [37].

Stadiu	BS minim (dB)	BS maxim (dB)	BS mediu (dB)
Sol dezgolit	-15.21	-11.79	-13.13
Stadiul plantei 1	-14.73	-11.14	-13.49
Stadiul plantei 2	-18.66	-13.09	-17.24
Stadiul plantei 3	-13.46	-10.72	-11.91
Stadiul plantei 4	-8.36	-5.87	-7.42

Pentru a obține valorile de retro-împrăștiere, datele RAS au fost prelucrate folosind software-ul SNAP, iar generarea imaginilor și antrenarea modelului au fost implementate în Python. Prelucrarea datelor RAS Sentinel-1 implică următorii pași: calibrare, filtrare a granulației, corecție a terenului Range-Doppler și conversia valorilor de la scală liniară la logaritmică (dB). Figura 4.2 ilustrează fluxul de lucru de la

colectarea datelor la clasificare.



Figura 4.2: Diagrama bloc a fluxului de lucru [37].

4.2 Rezultate

Distribuția densității K a coeficienților de retro-împrăștiere este prezentată în Figura 4.3, indicând o semnătură radar mai slabă pentru stadiul 2 (când culturile sunt în stadiul incipient de dezvoltare), în timp ce valorile de răspândire pentru celelalte stadii cresc pe măsură ce culturile se dezvoltă. Stadiul 2 prezintă un comportament de suprapunere în semnătura radar cu stadiul 1, sugerând caracteristici similare ale plantelor de grâu, însă distribuția generală a valorilor indică totuși un model de separare.



Figura 4.3: Estimarea densității K a coeficienților de retrodifuzare [37].

Modelul atinge un maxim de 100% acuratețe pe setul de antrenament și 96,4% acuratețe pe setul de testare. Experimentul demonstrează potențialul utilizării modelelor RNC pentru a prezice stadiile de creștere ale plantelor și semnătura acestora pe Sentinel-1 RAS. În viitor, prin extinderea datelor și generarea unor schițe grafice mai detaliate, modelele RNC au potențialul de a prezice o gamă mai largă de parametri.

Imagistică Hiperpectrală: Vizualizare, Clasificare și Compresie

5.1 Vizualizarea Imaginilor Hiperspectrale

Una dintre principalele provocări este vizualizarea IHS, având în vedere că imaginile hiper-spectrale conțin de la zeci până la sute de benzi, în timp ce ecranele pe care le folosim afișează doar trei benzi, și anume: roșu, verde și albastru. Există diverse modalități de a vizualiza IHS și s-a efectuat un volum semnificativ de cercetări pe această temă. În funcție de focusul aplicației, se poate alege metoda de vizualizare: unele metode se axează pe o selecție cât mai naturală a canalelor RGB, în timp ce altele pun accentul pe evidențierea diferitelor materiale din scenă.

Metoda propusă include doi pași: (i) identificarea benzii și a valorii lungimii de undă la care apare reflectanța maximă. Aceasta presupune selectarea unei singure benzi din zeci sau sute; (ii) atribuirea valorilor pentru canalele roșu, verde și albastru fiecărei lungimi de undă identificate per pixel. Implementarea se face în Matlab, iar pașii descriși au fost ilustrați și explicați în detaliu în secțiunile următoare.

Identificarea lungimii de undă (λ) a benzii cu reflectanță maximă: Această abordare se efectuează pe bază pixel cu pixel, prin determinarea inițială a benzii care are valoarea maximă a reflectanței (în nm). Figura 5.1(a) ilustrează acest pas, prezentând un grafic care arată valoarea maximă a reflectanței unui pixel ca fiind 734 nm.

Conversia, per pixel, a unei lungimi de undă dominante în valorile din spațiul de culori RGB: Am adoptat abordarea descrisă în [38] pentru a mapa valoarea lungimii de undă în spațiul de culori RGB, calculând componentele RGB ca funcții liniare pe porțiuni ale lungimii de undă λ . Figura 5.1(b) prezintă funcțiile utilizate pentru atribuirea valorilor RGB fiecărei lungimi de undă selectate. Pentru pasul de conversie de la RGB la lungimea de undă, am utilizat tabele de căutare pentru a obține o execuție mai rapidă a metodei propuse. Culorile rezultate ca funcție de lungimea de undă (λ) sunt reprezentate în Figura 5.1.

5.1.1 Rezultate Experimentale

Am folosit cubul de date hiper-spectrale al Universității din Pavia pentru a experimenta și testa metoda noastră. Această imagine a fost achiziționată cu un senzor Reflective Optics System Imaging Spectrometer (ROSIS) și are o rezoluție spațială de 610×340 pixeli și 103 benzi spectrale, rezultând un cub de date de dimensiuni $610 \times 340 \times 103$. Acoperirea spectrală a senzorului variază de la 430 la 860 nm cu un pas de 4 nm. Am eliminat benzile din partea superioară a lungimii de undă, care reprezentau porțiunea infraroșie a spectrului, folosind doar partea vizibilă, astfel încât cubul final de date are dimensiunile $610 \times 340 \times 84$. Rezultatele experimentale ale metodei propuse sunt prezentate în Figura 5.3, unde am decupat imaginea Universității din Pavia în două părți, superioară și inferioară, pentru a observa îndeaproape rezultatul vizualizării. Imaginea pseudo λ , reprezintă valoarea benzii cu reflectanță maximă. Din rezultatele vizualizării se poate observa că scena include multe nuanțe de roșu, fapt ce se datorează prezenței materialelor naturale, cum ar fi solul expus, pajiștile, pietrișul și arborii. Suprafațele artificiale, cum ar fi asfaltul și plăcile metalice vopsite, apar într-o nuanță de albastru (Figura 5.3(a) și (b)). În plus, umbrele sunt accentuate prin culoarea violet.



Figura 5.1: (a) O semnătură spectrală a unui pixel al imaginii hiperspectrale de la Universitatea Pavia și reflectanța maximă a acesteia [39]. (b) Descrierea vizuală a funcțiilor pentru conversia lungimii de undă în RGB [39].



Figura 5.2: Culorile din spectrul vizibil în funcție de lungimea de undă (λ).



Figura 5.3: Rezultatele experimentale ale abordării propuse asupra imagini Universității Pavia [39].

Chiar dacă scopul principal al acestei abordări este vizualizarea IHS, se arată clar că aceasta are potențial și pentru realizarea clasificării pe bază de pixel și segmentarea datelor hiper-spectrale. Am utilizat setul de date al Universității din Pavia cu adnotările sale de referință. Evaluarea noastră s-a concentrat pe cinci clase distincte: pajiști, arbori și sol expus (categorii denumite suprafețe naturale); plăci metalice vopsite (reprezentând suprafețe artificiale); și umbre (tratată ca o categorie separată). Tabelul 5.1 prezintă intervalele de lungimi de undă, împreună cu procentajul de pixeli corect clasificați (PCCP) pentru fiecare tip de material. Rezultatele demonstrează capacitatea metodei propuse de a distinge cu acuratețe între diferitele materiale prezente în scenă.

Mostre	Plăci metalice vopsite	Umbre	Suprafețe naturale
Interval (λ)	$470 - 550 \ nm$	$430 - 470 \ nm$	$620 - 780 \ nm$
РССР	99.5 %	94.2 %	99.8 %

Tabela 5.1: Evaluare cantitativă a pixelilor clasificați corect [39].

5.2 Extragerea Caracteristicilor Exponențiale și Învățarea pentru Compresia per Pixel a Imaginilor Hiperspectrale

Metodologia de compresie propusă se bazează pe două ipoteze fundamentale: aproximarea adecvată a spectrelor Fourier ale profilurilor hiperspectrale ale pixelilor și ajustarea curbei exponențiale negative la spectrele transformate; în al doilea rând, faptul că RNA pot învăta efectiv corespondentele între aceste reprezentări exponențiale negative și curbele de reflexie spectrală reale. Funcția exponențială negativă, ae^{-bx} captează caracteristicile spectrale esențiale și generează parametrii a și b care reprezintă datele comprimate, rezultând o reducere semnificativă a volumului de date. A doua ipoteză beneficiază de progresele recente în domeniul învătării automate, care arată capacitatea modelului RNA de a modela relații complexe în date. Modelul RNA învață să asocieze conexiunile funcționale dintre reprezentările exponențiale negative comprimate și profilele complete de reflexie spectrală. Metoda atinge o compresie eficientă a imaginilor hiperspectrale, menținând integritatea informației. Cadrul nostru de compresiedecompresie transformă datele de reflexie hiperspectrală ale fiecărui pixel $R(\lambda)$ folosind Transformata Fourier Rapidă (FFT). Datorită proprietătilor de simetrie, retinem doar jumătate din spectrul FFT si modelăm amplitudinea prin ajustarea unei funcții exponențiale negative (vezi Figura 5.5 (a)). Parametrii rezultanti (a, b) servesc drept reprezentare comprimată a pixelului. Pentru decompresie, antrenăm o retea neuronală pentru a reconstrui semnătura hiperspectrală originală din acesti parametri exponentiali. Pentru a optimiza procesul, eliminăm valorile apropiate de zero din a doua jumătate a vectorului înainte de procesarea de către rețeaua neuronală. Această secvență de compresie-decompresie este reprezentată vizual în Figura 5.4.



Figura 5.4: Diagrama bloc a abordării propuse de compresie-decompresie per pixel [40].

Am proiectat și implementat o rețea neuronală artificială clasică cu un singur strat ascuns, în etapa de decompresie, care prezice curba de reflectanță spectrală reală a fiecărui pixel. Antrenamentul se efectuează utilizând un algoritm de retro-propagare cu optimizatorul Adam, iar neuronii ascunși sunt activați prin funcția ReLU. Arhitectura rețelei este modificată pentru a se potrivi caracteristicilor imaginii

hiperspectrale. De exemplu, IHS-ul din scena Universității din Pavia conține 103 benzi spectrale. Inițial, se aplică FFT-ul, iar numărul benzilor este redus la 51 datorită simetriei; funcția exponențială negativă a fost ajustată la FFT și doi coeficienți (*a* și *b*) au fost extrași, reprezentând datele comprimate. În faza de decompresie, cei doi coeficienți au fost folosiți pentru a recupera cele 51 de valori, după care cealaltă jumătate a fost ignorată datorită valorilor foarte mici prezente. Ultimele 25 de valori au fost folosite ca intrare pentru RNA. Stratului de ieșire i s-au configurat 103 neuroni, corespunzători numărului original de benzi spectrale, în timp ce stratul ascuns are o dimensiune egală cu media dintre straturile de intrare și de ieșire.



Figura 5.5: (a) Curba exponențială negativă ajustată la jumătatea FFT; (b) Semnătura spectrală a pixelilor: originală și reconstruită [40].

5.2.1 Rezultate Experimentale

Caracteristicile negative exponențiale extrase din imaginile hiperspectrale ale scenei Universității Pavia prezintă o reprezentare puternică a datelor originale, așa cum este ilustrat de elementele vizuale prezentate în Figura 5.5 (b) și Figura 5.6. La examinarea corelației dintre aceste caracteristici extrase și datele originale, redarea în nuanțe de gri din Figura 5.6 (a) arată asemănări vizuale clare atât cu log(a), cât și cu pseudo imaginile parametrului *b* din Figura 5.6 (b) și (c), respectiv. Validarea cantitativă a acestor relații vizuale este prezentată în Tabelul 5.2, unde coeficienții Pearson CC între caracteristicile extrase și informația spectrală originală sunt afișați. Analiza relevă valori de corelație ridicate: parametrul log(a)menține coeficienți de peste 0.7 pe toate benzile spectrale, în timp ce parametrul *b* arată relații moderat puternice în jurul valorii de 0.6. Aceste relații statistice confirmă ceea ce indică inițial inspecția vizuală: parametrizarea exponențială negativă captează caracteristicile esențiale ale datelor hiperspectrale.

Band	b_3	b_5	b_{21}	b_{25}	b_{50}	b_{60}
log(a)	0.7	0.72	0.73	0.72	0.78	0.77
b	-0.58	-0.59	-0.58	-0.55	-0.59	-0.59

Tabela 5.2: CC Pearson între banda IHS și log(a), b matrici [40].

Spectral Angle Mapper (SAM) din [41] măsoară similaritatea spectrală pixel-cu-pixel între datele hiperspectrale reconstruite și cele originale. Valorile SAM se grupează predominant la capătul inferior al scalei, aproximativ 93% situându-se în intervalul [0-0.2], prezentând un model de distribuție exponențial negativ cu o valoare medie de 0.0817 și o valoare maximă de 1.2. Aceste măsurători oferă două constatări critice în metodologia noastră: în primul rând, caracteristicile exponențiale negative capturează cu succes caracteristicile reprezentărilor FFT ale curbelor de reflexie ale pixelilor; în al doilea rând, rețeaua neuronală artificială atinge o performanță înaltă în maparea relației dintre caracteristici (*a* și *b*) și semnătura spectrală



Figura 5.6: Rezultatele experimentale ale extragerii caracteristicilor de scădere exponențială pentru setul de date al scenei Universității din Pavia [40].

corespunzătoare. Concentrarea valorilor scăzute SAM indică faptul că reconstrucția spectrală păstrează conținutul informațional esențial al imaginilor hiperspectrale originale cu o distorsiune minimă.

Pentru a evalua vizual calitatea reconstrucției, am generat compozite imagini color RGB ale imaginilor hiperspectrale originale și reconstruite, folosind benzile 53, 21 și 7 mapate la canalele roșu, verde și albastru, respectiv (Figura 5.7 (a), (b)). După linearizare pentru o vizualizare îmbunătățită, imaginea reconstruită seamănă îndeaproape cu cea originală, cu discrepanțe minore de culoare, în principal în zonele cu acoperișuri metalice. Evaluarea cantitativă a utilizat trei metrici: Eroarea Medie Absolută (MAE) [42], diferența de culoare ΔE [43] și Indicele de Similaritate Structurală (SSIM) [44]. Pentru setul de date Pavia University, am obținut MAE = 3.71, $\Delta E = 4.2$ și SSIM = 0.97, indicând o similaritate ridicată. Figura 5.7 (c) afișează distribuția spațială a diferențelor de culoare ΔE , relevând că majoritatea pixelilor prezintă $\Delta E < 20$, iar 30% sub pragul diferenței perceptibile de $\Delta E < 3$. Abordarea noastră de compresie per pixel a atins un raport de compresie de 10.9967, reducând setul de date Pavia University de 33.1 MB la 3.01 MB de caracteristici extrase.



Figura 5.7: Comparația dintre imaginea IHS RGB originală și cea reconstruită bazată pe selecția benzilor, împreună cu imaginea diferenței de culoare ΔE [40].

Identificarea Tipului de Cultură

6.1 Identificarea Timpurie a Câmpurilor de Cartof Folosind Fuziunea Datelor și RNA

Pentru a testa ipotezele, am folosit imaginile achiziționate în pe data de 23 mai 2023, deoarece în acea zi achiziția datelor Sentinel-1 și Sentinel-2 s-a suprapus. ZdI este Brașov, România, iar informațiile privind limitele câmpurilor au fost furnizate de INCDCSZ. În Figura 6.1 a) se poate observa ZdI sub formă de imagine RGB, în timp ce Figura 6.1 b) reprezintă imaginea NDVI calculată pe baza canalelor de infraroșu apropiat (bandă-8) și roșu (bandă-4) ale imaginii Sentinel-2 [45], iar Figura 6.1 c) ilustrează canalul VH al imaginii RAS. Poligoanele de culoare magenta reprezintă câmpurile de cartof, iar cele de culoare roșie reprezintă câmpurile non-cartof, mai exact, culturile de mazăre verde, sfeclă de zahăr și porumb, care sunt folosite pentru antrenarea și testarea RNA. Câmpurile de cartofi alese prezintă tipuri diferite de cartofi, dar au fost considerate omogene în studiul nostru, deoarece nu prezintă modele diferite în procesul de bilonare.



Figura 6.1: RGB și NDVI din imagine optică, și VH din imagine RAS a scenei cu poligoane care indică câmpuri de cartof (magenta) și non-cartof (roșu) [46].

Setul de date fuzionat include atât date multispectrale, cât și RAS. Din datele multispectrale se includ primele trei componente principale (PC1, PC2, PC3) și NDVI. Din datele RAS se includ coeficienții de retro-împrăștiere $\sigma^0(VH)$ și $\sigma^0(VV)$. Contribuția finală a datelor multispectrale în forma fuzionată conține PC1, PC2, PC3 și NDVI, iar din datele RAS, $\sigma^0(VH)$ și $\sigma^0(VV)$. Astfel, fiecare pixel poate fi descris ca vectorul: $[\sigma^0(VH), \sigma^0(VV), NDVI, PC1, PC2, PC3]$.

6.1.1 Rezultate Experimentale

Toate imaginile Sentinel-2 disponibile pentru anul 2023 au fost analizate; Figura 6.2 arată evoluția valorii medii a NDVI pe cinci câmpuri de cartof. Perioada evidențiată în roșu reprezintă momentul operației de bilonare, în timp ce verde indică creșterea culturii de cartofi. Am utilizat o RNA complet conectată, antrenată prin algoritmul de retro-propagare, cu două straturi ascunse de 128 și 64 de neuroni, iar funcția de activare pentru neuroni este ReLU. Funcția de activare sigmoidă este utilizată în neuronul final de ieșire pentru sarcinile de clasificare binară. Optimizatorul folosit a fost Adam, iar rata de învățare a fost setată la 0.001. Numărul de epoci a fost setat la 25, iar dimensiunea batch-ului la 64, folosindu-se pierderea de tip cross-entropy. Menționăm că un număr mai mare de epoci nu a condus la o acuratețe mai bună. În final, datele au fost amestecate și împărțite în 80% pentru antrenare și 20% pentru testare.

Forma finală a datelor conține un total de 5233 de vectori, din care 36.52% reprezintă câmpuri de cartofi, iar 63.48% câmpuri non-cartofi. Pentru procesarea datelor, am utilizat Python cu cadrul PyTorch pentru antrenarea și testarea rețelei neuronale, precum și pentru alinierea și fuziunea datelor. În plus, am folosit software-ul SNAP ESA pentru procesarea imaginilor multispectrale și RAS. Ca rezultat al antrenamentului și testării pe parcursul a 25 de epoci pe două seturi de date diferite, am obținut o acuratețe ridicată. Chiar dacă accentul principal al studiului este identificarea câmpurilor de cartof în stadiul de bilonare, am antrenat și testat suplimentar aceeași rețea pe setul de date din stadiul de cultură, care reprezintă fuziunea datelor Sentinel-2 de la data de 12/07/2023 și Sentinel-1 de la data de 11/07/2023. Tabelul 6.1 prezintă comparația rezultatelor de acuratețe între antrenament și testare pentru cele două date. Acuratețea mai ridicată pe al doilea set de date se poate explica prin faptul că una dintre caracteristici este NDVI, care este proeminent în prezența culturilor și mai puțin semnificativ în pre-sezon.



Figura 6.2: Media valorilor NDVI din cinci câmpuri de cartofi [46].

Date	Acuratețe Antrenament (%)	Acuratețe Test (%)
Bilonare (23/05/2023)	94.41	93.03
Prezență vegetație (12/07/2023)	98	96.88

Tabela 6.1: Rezultatele acurateței pentru două seturi de date diferite [46]..

Concluzie

Această teză este interdisciplinară, reunind teledetecția, învățarea automată și agricultura, abordând provocări și probleme din aceste domenii. În timp ce o parte semnificativă din continut se dedică aplicațiilor în agricultură, capitolul referitor la IHS are o abordare mai largă. Teledetecția reprezintă procesul de măsurare a caracteristicilor fizice, chimice și biologice ale obiectelor fără contact fizic. Instrumentele care măsoară caracteristicile unui obiect de la distanță pot fi montate în diverse moduri, precum atasarea simplă lângă câmp, pe vehicule aeriene sau pe platforme satelitare. Am utilizat date de la Sentinel-1 RAS și Sentinel-2 multispectrale în unele dintre experimentele noastre, desfășurând totodată multiple campanii de teren și măsurători de laborator pentru colectarea datelor. Colectarea datelor a inclus, în principal, profilarea suprafeței solului folosind metodele cu lanț și panou cu tije (cunoscute și ca metode clasice), metoda laser și analiza fractală. De asemenea, am achiziționat imagini multispectrale cu drone pentru analiza fractală, alături de imagini achiziționate la nivel de sol. Am colectat date privind parametrii fizici ai culturii de grâu pe parcursul sezonului de crestere, acoperind toate stadiile de dezvoltare. În plus, am generat imagini sintetice pe baza datelor de teren și am simulat suprafețe de sol pentru a estima retro-împrăstierea RAS. Colectarea datelor de la sol nu s-a realizat prin metode de teledetectie, ci prin metode de contact, cu scopul de a îmbunătăți și dezvolta tehnicile și instrumentele specifice teledetecției. În colaborare cu INCDCSZ, am avut oportunitatea de a efectua măsurători în teren si de a accesa etichetele de referință pentru limitele câmpurilor, conturarea solului și calendarul de dezvoltare a plantelor. Teza prezintă, de asemenea, experimente si rezultate referitoare la vizualizarea, clasificarea si comprimarea datelor hiperspectrale, provocări întâlnite nu doar în agricultură, ci și în alte domenii.

Finanțată de Uniunea Europeană, această teză a fost dezvoltată în cadrul proiectului AI4AGRI, în contextul Centrului Român de Excelență pentru Inteligență Artificială pe date de Observarea Terrei pentru Agricultură, care își propune să stimuleze productivitatea agricolă și sustenabilitatea în România prin valorificarea inteligenței artificiale și a datelor de observare a Pământului. Fiind prima teză de doctorat realizată în cadrul unui laborator relativ nou, aceasta pune bazele cercetărilor viitoare și formării următoarei generații de cercetători.

Contribuția Autorului

Contribuțiile principale sunt rezumate după cum urmează:

- Efectuarea unei evaluări a performanței metodelor clasice de evaluare RSS, și anume metodele lanț și panou cu tije, prin desfășurarea de experimente în laborator și pe terenul agricol.
- Achiziționarea datelor pe suprafețe artificiale și de sol cu ajutorul tehnologiei laser, preprocesarea și crearea setului de date. Antrenarea, testarea modelului ResNet-18 și evaluarea rezultatelor.
- Alinierea imaginilor și alte etape de preprocesare pentru imaginile multispectrale achiziționate din dronă, aplicarea analizei fractale și evaluarea rezultatelor.

- Proiectarea unei abordări pentru generarea suprafețelor sintetice de sol și a umidității solului folosind MEI. Crearea setului de date, proiectarea și implementarea modelului RNC și evaluarea rezultatelor.
- Proiectarea și implementarea determinării lungimii de undă cu reflectanța maximă și conversia acesteia în spațiul de culoare RGB pentru vizualizarea imaginilor IHS. Evaluarea metodei de vizualizare și a rezultatelor clasificării pixelilor.
- Implementarea unei abordări pentru compresia datelor IHS. Aplicarea FFT a supra spectrelor IHS, ajustarea curbelor, precum și proiectarea, implementarea RNA și evaluarea rezultatelor de antrenament și testare în compresia datelor IHS.
- Contribuții la realizarea unui set de date de la radar (Sentinel-1) și optic (Sentinel-2), georeferențiate, colectate pe parcursul a 5 ani, pentru aplicații de identificare a culturilor și identificare timpurie a culturilor.
- Proiectarea și implementarea unei tehnici de fuziune a datelor între cele radar și optice pentru detectarea bilonării în culturile de cartof.
- Proiectarea și implementarea unei abordări pentru generarea imaginilor cu schițe ale plantelor pentru stadiul de creștere al plantelor și clasificarea coeficienților de retro-împrăștiere RAS.

Lista Publicațiilor

- M. Ivanovici, S. Popa, K. Marandskiy, and C. Florea. 2024. "Deep Automatic Soil Roughness Estimation from Digital Images." European Journal of Remote Sensing 57 (1). doi: 10.1080/22797254.2024.2342955. Indexare, WOS:001208155100001, Q2, IF = 3.7
- M. Ivanovici, K. Marandskiy, G. Olteanu, A. Manea, and L. Dogar. 2024. "A Framework for Innovation in Earth Observation Applications for Agriculture." Bulletin of the Transilvania University of Brasov. Series I Engineering Sciences, November, 21–36. doi: 10.31926/but.ens.2023.16.65.1.3. Indexare, Scopus
- K. Marandskiy, M. Ivanovici and S. Popa, "Machine Learning-Based Classification of Sentinel-1 Backscattering Coefficients Using Generated Plant Schematics," IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece, 2024, pp. 1535-1539, doi: 10.1109/IGARSS53475.2024.10640653. Lucrare de conferință, IEEE Xplore, Indexare, WOS:001316158501216
- M. Ivanovici and K. Marandskiy, "Exponential Feature Extraction and Learning for Pixel-Wise Hyperspectral Image Compression," IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium, Pasadena, CA, USA, 2023, pp. 1775-1778, doi: 10.1109/IGARSS52108.2023.10282126. Lucrare de conferință, IEEE Xplore, Indexare, WOS:001098971602012
- M. Ivanovici, S. Oprisescu, R. M. Coliban and K. Marandskiy, "Exponential Features in the Fourier Domain for Prisma Hyperspectral Image Segmentation," IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium, Pasadena, CA, USA, 2023, pp. 6089-6092, doi: 10.1109/IGARSS52108.2023.10282239. Lucrare de conferință, IEEE Xplore, Indexare, WOS:001098971606048.
- K. Marandskiy and M. Ivanovici, "Hyperspectral Image Visualization Based on Maximum-Reflectance Wavelength Colorization," 2023 17th International Conference on Engineering of Modern Electric Systems (EMES), Oradea, Romania, 2023, pp. 1-4, doi: 10.1109/EMES58375.2023.10171717. Lucrare de conferință, IEEE Xplore

- K. Marandskiy and M. Ivanovici, "Soil Roughness Estimation Using Fractal Analysis on Digital Images of Soil Surface," 2023 International Symposium on Signals, Circuits and Systems (ISSCS), Iasi, Romania, 2023, pp. 1-4, doi: 10.1109/ISSCS58449.2023.10190895. Lucrare de conferință, IEEE Xplore.
- 8. K. Marandskiy, M. Ivanovici, S. Corcodel and S. Costache, "Multispectral Fractal Image Analysis for Soil Roughness Estimation at Various Altitudes," 2023 13th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS), Athens, Greece, 2023, pp. 1-5, doi: 10.1109/WHISPERS61460.2023.10431360. Lucrare de conferință, IEEE Xplore.
- K. Marandskiy and M. Ivanovici, "Early Identification of Potato Fields using Data Fusion and Artificial Neural Network," 2024 International Symposium on Electronics and Telecommunications (ISETC), Timisoara, Romania, 2024, pp. 1-4, doi: 10.1109/ISETC63109.2024.10797316. Lucrare de conferință, IEEE Xplore.
- M. Ivanovici, G. Olteanu, C. FLorea, RM Coliban, M. Ștefan, K. Marandskiy (2024). Digital Transformation in Agriculture. In: Ivascu, L., Cioca, LI., Doina, B., Filip, F.G. (eds) Digital Transformation. Intelligent Systems Reference Library, vol 257. Springer, Cham. doi: 10.1007/978-3-031-63337-9 9. Capitol de carte, Springer.
- M. Ivanovici, C. Florea, A. Cațaron, R. Coliban, Ş. Popa, I. Plajer, M. Ștefan, A. Băicoianu, Ş. Oprișescu, A. Racovițeanu, Gh. Olteanu, K. Marandskiy, A. Ghinea, A. Kazak, M. Debu, L. Majercsik, A. Manea, and L. Dogar. 2024. "Teledetecție și inteligență artificială pentru agricultură." CARTOFUL în România, 33.
- 12. K. Marandskiy and M. Ivanovici, "Early Identification of Potato Fields using Data Fusion and Artificial Neural Network," *Sensors*, MDPI [Invited article]. Indexare, Q2, IF = 3.4
- 13. A. Băicoianu, I.C. Plajer, M. Debu, M. Ștefan, M. Ivanovici, C. Florea, A. Cațaron, R. M. Coliban, Ș. Popa, Ș. Oprișescu, A. Racovițeanu, Gh. Olteanua, K. Marandskiy, A. Ghinea, A. Kazak, L. Majercsik, A. Manea, L. Dogar, "DACIA5 – A Sentinel-1 and Sentinel-2 Dataset for Agricultural Crop Identification Applications," *Big Earth Data*, Taylor & Francis [În recenzie, retrimis]. Indexare, Q1, IF = 4.2
- K. Marandskiy, L. G. Papale, M. Ivanovici and F. D. Frate, "A CNN-Based Approach for Understanding SAR Backscattering of Bare Soil," IGARSS 2025 - 2025 IEEE International Geoscience and Remote Sensing Symposium, Brisbane, Australia [Acceptat]. Lucrare de conferință, IEEE Xplore, Indexare, WOS.

Bibliografie

- L. Thomsen, J. Baartman, R. Barneveld, T. Starkloff, and J. Stolte, "Soil surface roughness: comparing old and new measuring methods and application in a soil erosion model," *Soil*, vol. 1, no. 1, pp. 399–410, 2015.
- [2] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings* of the IEEE conference on computer vision and pattern recognition, pp. 770–778, 2016.
- [3] S. I. Seneviratne, T. Corti, E. L. Davin, M. Hirschi, E. B. Jaeger, I. Lehner, B. Orlowsky, and A. J. Teuling, "Investigating soil moisture–climate interactions in a changing climate: A review," *Earth-Science Reviews*, vol. 99, no. 3-4, pp. 125–161, 2010.
- [4] K. C. Kornelsen and P. Coulibaly, "Advances in soil moisture retrieval from synthetic aperture radar and hydrological applications," *Journal of Hydrology*, vol. 476, pp. 460–489, 2013.
- [5] R.-M. Coliban, M. Marincaş, C. Hatfaludi, and M. Ivanovici, "Linear and non-linear models for remotely-sensed hyperspectral image visualization," *Remote Sensing*, vol. 12, no. 15, p. 2479, 2020.
- [6] Y. Dua, V. Kumar, and R. S. Singh, "Comprehensive review of hyperspectral image compression algorithms," *Optical Engineering*, vol. 59, 2020.
- [7] I. Becker-Reshef, B. Barker, A. Whitcraft, P. Oliva, K. Mobley, C. Justice, and R. Sahajpal, "Crop type maps for operational global agricultural monitoring," *Scientific Data*, vol. 10, no. 1, p. 172, 2023.
- [8] M. Weiss, F. Jacob, and G. Duveiller, "Remote sensing for agricultural applications: A meta-review," *Remote sensing of environment*, vol. 236, p. 111402, 2020.
- [9] A. Orynbaikyzy, U. Gessner, and C. Conrad, "Crop type classification using a combination of optical and radar remote sensing data: A review," *international journal of remote sensing*, vol. 40, no. 17, pp. 6553–6595, 2019.
- [10] G.-H. Kwak and N.-W. Park, "Impact of texture information on crop classification with machine learning and uav images," *Applied Sciences*, vol. 9, no. 4, p. 643, 2019.
- [11] R. Yaramasu, V. Bandaru, and K. Pnvr, "Pre-season crop type mapping using deep neural networks," *Computers and Electronics in Agriculture*, vol. 176, p. 105664, 2020.
- [12] A. Saleh, "Soil roughness measurement: chain method," *Journal of soil and water conservation*, vol. 48, no. 6, pp. 527–529, 1993.
- [13] R. Allmaras, R. E. Burwell, W. E. Larson, R. F. Holt, *et al.*, "Total porosity and random roughness of the interrow zone as influenced by tillage," *USDA Conservation Reserve Program*, 1966.
- [14] N. Cremers, P. Van Dijk, A. De Roo, and M. Verzandvoort, "Spatial and temporal variability of soil surface roughness and the application in hydrological and soil erosion modelling," *Hydrological* processes, vol. 10, no. 8, pp. 1035–1047, 1996.

- [15] K. Marandskiy and M. Ivanovici, "Soil roughness estimation using fractal analysis on digital images of soil surface," in 2023 International Symposium on Signals, Circuits and Systems (ISSCS), pp. 1–4, IEEE, 2023.
- [16] M. Ivanovici, S. Popa, K. Marandskiy, and C. Florea, "Deep automatic soil roughness estimation from digital images," *European Journal of Remote Sensing*, vol. 57, no. 1, p. 2342955, 2024.
- [17] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," arXiv preprint ar-Xiv:1412.6980, 2014.
- [18] B. B. Mandelbrot and B. B. Mandelbrot, *The fractal geometry of nature*, vol. 1. WH freeman New York, 1982.
- [19] M. Ivanovici, "Fractal dimension of color fractal images with correlated color components," *IEEE Transactions on Image Processing*, vol. 29, pp. 8069–8082, 2020.
- [20] R. García Moreno, M. C. Diaz Alvarez, A. Tarquis, A. Paz González, and A. Saa Requejo, "Shadow analysis of soil surface roughness compared to the chain set method and direct measurement of micro-relief," *Biogeosciences*, vol. 7, no. 8, pp. 2477–2487, 2010.
- [21] W.-S. Chen, S.-Y. Yuan, H. Hsiao, and C.-M. Hsieh, "Algorithms to estimating fractal dimension of textured images," in 2001 IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings (Cat. No. 01CH37221), vol. 3, pp. 1541–1544, IEEE, 2001.
- [22] M. Ivanovici, "A multi-spectral fractal image model and its associated fractal dimension estimator," *Fractal and Fractional*, vol. 7, no. 3, p. 238, 2023.
- [23] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool, "Speeded-up robust features (surf)," *Computer Vision and Image Understanding*, vol. 110, no. 3, pp. 346–359, 2008. Similarity Matching in Computer Vision and Multimedia.
- [24] K. Marandskiy, M. Ivanovici, S. Corcodel, and S. Costache, "Multispectral fractal image analysis for soil roughness estimation at various altitudes," in 2023 13th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS), pp. 1–5, 2023.
- [25] J. R. Wang and T. J. Schmugge, "An empirical model for the complex dielectric permittivity of soils as a function of water content," *IEEE Transactions on Geoscience and remote sensing*, no. 4, pp. 288–295, 1980.
- [26] M. Choker, N. Baghdadi, M. Zribi, M. El Hajj, S. Paloscia, N. E. C. Verhoest, H. Lievens, and F. Mattia, "Evaluation of the oh, dubois and iem backscatter models using a large dataset of sar data and experimental soil measurements," *Water*, vol. 9, no. 1, 2017.
- [27] P. Dubois, J. van Zyl, and T. Engman, "Measuring soil moisture with imaging radars," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 33, no. 4, pp. 915–926, 1995.
- [28] Y. Oh, "Quantitative retrieval of soil moisture content and surface roughness from multipolarized radar observations of bare soil surfaces," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 3, pp. 596–601, 2004.
- [29] A. Fung, Z. Li, and K. Chen, "Backscattering from a randomly rough dielectric surface," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 30, no. 2, pp. 356–369, 1992.
- [30] N. Baghdadi, M. Zribi, S. Paloscia, N. E. C. Verhoest, H. Lievens, F. Baup, and F. Mattia, "Semiempirical calibration of the integral equation model for co-polarized l-band backscattering," *Remote Sensing*, vol. 7, no. 10, pp. 13626–13640, 2015.

- [31] K. Chen, T.-D. Wu, L. Tsang, Q. Li, J. Shi, and A. Fung, "Emission of rough surfaces calculated by the integral equation method with comparison to three-dimensional moment method simulations," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 41, no. 1, pp. 90–101, 2003.
- [32] A. K. Fung and K.-S. Chen, *Microwave scattering and emission models for users*. Artech house, 2010.
- [33] A. Fung and M. Chen, "Numerical simulation of scattering from simple and composite random surfaces," JOSA A, vol. 2, no. 12, pp. 2274–2284, 1985.
- [34] J. R. Birchak, C. G. Gardner, J. E. Hipp, and J. M. Victor, "High dielectric constant microwave probes for sensing soil moisture," *Proceedings of the IEEE*, vol. 62, no. 1, pp. 93–98, 1974.
- [35] C. Roth, M. Malicki, and R. Plagge, "Empirical evaluation of the relationship between soil dielectric constant and volumetric water content as the basis for calibrating soil moisture measurements by tdr," *Journal of Soil Science*, vol. 43, no. 1, pp. 1–13, 1992.
- [36] I. Takken, "Effects of soil roughness on overland flow and erosion," 2000.
- [37] K. Marandskiy, M. Ivanovici, and S. Popa, "Machine learning-based classification of sentinel-1 backscattering coefficients using generated plant schematics," in *IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium*, pp. 1535–1539, 2024.
- [38] D. Miha and E. Strajescu, "From wavelength to r g b filter," University" Politehnica" of Bucharest Scientific Bulletin, Series D: Mechanical Engineering, vol. 69, no. 2, pp. 77–84, 2007.
- [39] K. Marandskiy and M. Ivanovici, "Hyperspectral image visualization based on maximum-reflectance wavelength colorization," in 2023 17th International Conference on Engineering of Modern Electric Systems (EMES), pp. 1–4, 2023.
- [40] M. Ivanovici and K. Marandskiy, "Exponential feature extraction and learning for pixel-wise hyperspectral image compression," in *IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium*, pp. 1775–1778, 2023.
- [41] F. van der Meer, "The effectiveness of spectral similarity measures for the analysis of hyperspectral imagery," *International Journal of Applied Earth Observation and Geoinformation*, vol. 8, 2006.
- [42] Y. Hashidume and Y. Morikawa, "Lossless image coding based on minimum mean absolute error predictors," *Proceedings of the SICE Annual Conference*, pp. 2832–2836, 2007.
- [43] S. P. Farnand, "Using ΔE metrics for measuring color difference in hard copy pictorial images," in *Color Imaging VIII: Processing, Hardcopy, and Applications*, vol. 5008, pp. 109–118, International Society for Optics and Photonics, SPIE, 2003.
- [44] Z. Wang, A. Bovik, H. R. Sheikh, and E. P. Simoncelly, "Image quality assessment: from error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, pp. 600–612, 2004.
- [45] J. W. Rouse, R. H. Haas, J. A. Schell, D. W. Deering, et al., "Monitoring vegetation systems in the great plains with erts," NASA Spec. Publ, vol. 351, no. 1, p. 309, 1974.
- [46] K. Marandskiy and M. Ivanovici, "Early identification of potato fields using data fusion and artificial neural network," in 2024 International Symposium on Electronics and Telecommunications (ISETC), pp. 1–4, 2024.