



UNIVERSITATEA DIN PETROȘANI
ȘCOALA DOCTORALĂ

TEZĂ DE DOCTORAT

CONDUCĂTOR DE DOCTORAT:

PROF.UNIV.HABIL.DR.ING. LEBA MONICA

STUDENT DOCTORAND:

ING. GĂMULESCU OLIVIU-MIHNEA

2024

UNIVERSITATEA DIN PETROȘANI

ȘCOALA DOCTORALĂ

**CONTRIBUȚII PRIVIND RECUNOAȘTEREA
AUTOMATĂ A CULTURILOR AGRICOLE CU
AJUTORUL UNEI DRONE**

CONDUCĂTOR DE DOCTORAT:

PROF.UNIV.HABIL.DR.ING. LEBA MONICA

STUDENT DOCTORAND:

ING. GĂMULESCU OLIVIU-MIHNEA

2024

Cuprins

Introducere.....	Error! Bookmark not defined.
OBIECTIVELE CERCETĂRII.....	Error! Bookmark not defined.
CAPITOLUL 1	Error! Bookmark not defined.
STADIUL ACTUAL AL CERCETĂRILOR ÎN DOMENIUL RECUNOAȘTERII AUTOMATE A CULTURILOR AGRICOLE CU AJUTORUL DRONELOR.....	Error! Bookmark not defined.
1.1 Sisteme de monitorizare a culturilor agricole.....	Error! Bookmark not defined.
1.2 Utilizarea dronelor în agricultura de precizie	Error! Bookmark not defined.
1.2.1 Rolul dronelor în agricultura de precizie	Error! Bookmark not defined.
1.2.2 Avantajele Utilizării Dronelor	Error! Bookmark not defined.
1.3 Sisteme de recunoaștere a culturilor	Error! Bookmark not defined.
1.4 Sisteme de conducere a dronelor	Error! Bookmark not defined.
CAPITOLUL 2.....	Error! Bookmark not defined.
CONTEXTUL CERCETĂRII.....	Error! Bookmark not defined.
2.1. Justificarea necesității studiului.....	Error! Bookmark not defined.
2.2 Probleme întâmpinate în cursul anului 2023	Error! Bookmark not defined.
2.3. Obiective pentru anul 2024.....	Error! Bookmark not defined.
2.3.1 Obiectivele specifice ale APIA Gorj	Error! Bookmark not defined.
2.3.2 Finanțarea instituției	Error! Bookmark not defined.
2.3.3 Activitatea serviciului control pe teren.....	Error! Bookmark not defined.
2.4 Descrierea sistemului UAV	Error! Bookmark not defined.
2.5. Analiza SWOT	Error! Bookmark not defined.
2.6. Instrumente folosite în analiza imaginilor	Error! Bookmark not defined.
2.7 Oportunități privind utilizarea CNN și AI.....	Error! Bookmark not defined.
CAPITOLUL 3	Error! Bookmark not defined.
RECUNOAȘTERE VIZUALĂ.....	Error! Bookmark not defined.
3.1. Rețele neuronale convoluționale (CNN – Convolutional Neural Networks) ...	Error! Bookmark not defined.
defined.	
3.2. Vederea biologică versus CNN-uri.....	Error! Bookmark not defined.
3.3. Concepte de bază care stau la baza CNN-urilor	Error! Bookmark not defined.
3.4. Arhitectura CNN	Error! Bookmark not defined.
3.5. Antrenarea CNN-urilor.....	Error! Bookmark not defined.
3.6 . Aplicabilitatea CNN	Error! Bookmark not defined.
3.6.1 Transferul de învățare și rețelele pre-antrenate	Error! Bookmark not defined.

3.6.2 Variante de arhitecturi CNN:.....	Error! Bookmark not defined.
CAPITOLUL 4.....	Error! Bookmark not defined.
EVALUAREA REȚELELOR CNN	Error! Bookmark not defined.
PENTRU RECUNOAȘTEREA CULTURILOR.....	Error! Bookmark not defined.
4.1. Achiziționarea setului de imagini	Error! Bookmark not defined.
4.2. Realizare CNN simplă.....	Error! Bookmark not defined.
4.3. CNN preantrenate	Error! Bookmark not defined.
4.3.1. Rețea SqueezeNet.....	Error! Bookmark not defined.
4.3.2. Rețea GoogleNet	Error! Bookmark not defined.
CAPITOLUL 5	Error! Bookmark not defined.
PROIECTAREA ȘI ANTRENAREA REȚELELOR CNN.....	Error! Bookmark not defined.
PENTRU RECUNOAȘTEREA CULTURILOR.....	Error! Bookmark not defined.
5.1. Achiziționare dataset	Error! Bookmark not defined.
5.2. Soluția cu CNN GoogleNet.....	Error! Bookmark not defined.
5.3. Soluția cu CNN ResNet.....	Error! Bookmark not defined.
5.4. Soluția cu CNN Xception.....	Error! Bookmark not defined.
5.5. Analiza multicriterială LINMAP (Linear Programming techniques for Multidimensional Analysis of Preference).....	Error! Bookmark not defined.
CAPITOLUL 6.....	Error! Bookmark not defined.
CONCLUZII, CONTRIBUTII ȘI DIRECȚII DE DEZVOLTARE	Error! Bookmark not defined.
6.1 Concluzii.....	Error! Bookmark not defined.
6.2 Contribuții.....	Error! Bookmark not defined.
6.3 Direcții de cercetare viitoare.....	Error! Bookmark not defined.
BIBLIOGRAFIE	Error! Bookmark not defined.
Anexa 1.....	Error! Bookmark not defined.

Cuvânt înainte

Teza intitulată "**Contribuții privind recunoașterea automată a culturilor agricole cu ajutorul unei drone**" abordează utilizarea dronelor pentru identificarea și evaluarea culturilor agricole, cu un accent deosebit pe aplicabilitatea în monitorizarea terenurilor în cadrul APIA, Centrul Județean Gorj. Această cercetare explorează implementarea unei tehnologii inovatoare în agricultură, cu scopul de a eficientiza monitorizarea și gestionarea culturilor, oferind date mai detaliate și actualizate comparativ cu metodele tradiționale.

Obiectivele cercetării au inclus dezvoltarea unui algoritm bazat pe o rețea neuronală convoluțională (CNN) de tip GoogleNet, antrenată pentru recunoașterea automată a culturilor agricole cu o precizie de peste 99%. S-au colectat 500 de imagini de înaltă rezoluție, din Stațiunea de Cercetare-Dezvoltare Horticolă Târgu Jiu și alte regiuni ale Olteniei, clasificate în cinci categorii: gol alpin, floarea soarelui, grâu, porumb și lucernă.

Metodologia a inclus preprocesarea imaginilor și antrenarea modelului CNN, care a fost evaluat folosind metrici precum precizie, reamintire și scor F1. Modelul a demonstrat o capacitate notabilă de a distinge între diferitele tipuri de culturi, atingând scoruri AUC apropiate de perfecțiune pentru anumite clase. Performanța modelului a fost variabilă pentru grâu și lucernă, subliniind necesitatea unor îmbunătățiri suplimentare.

Rezultatele au evidențiat eficiența utilizării dronelor și a tehnologiilor de învățare automată în clasificarea culturilor agricole. Modelul a obținut scoruri F1 de peste 90% pentru clasele gol alpin și porumb, dar a indicat performanțe mai modeste pentru grâu și lucernă, ceea ce sugerează necesitatea unui set de date mai echilibrat și reprezentativ.

Concluzii: Cercetarea demonstrează potențialul semnificativ al tehnologiilor de învățare automată în agricultură, oferind o bază solidă pentru îmbunătățiri viitoare și maximizarea eficienței în clasificarea automată a culturilor. Perspectivele includ optimizarea continuă a modelului pentru a asigura o aplicabilitate cât mai largă și precisă în scenarii reale.

1. Introducere:

Proiectul a demarat cu o activitate de documentare asupra evoluției cunoașterii în domeniul agriculturii performante, cercetate cu ajutorul dronelor, ce pot avea un rol hotărâtor, pentru o agricultura performantă, atât pe plan intern cât și pe plan internațional. Pe parcursul documentării efectuate, s-a demarat și procesul de sistematizare a informațiilor adunate și de structurare a datelor în vederea realizării unei baze de plecare pentru elaborarea unor lucrări cu care să se participe la manifestări științifice. S-a trecut apoi la selectarea ariilor de interes pentru activitățile de teren, activitate urmată de efectuarea de deplasări interne pentru efectuarea de observații și măsurători în teren și prelevări de probe sol. Activitățile de teren au fost urmate de activități de laborator.

Teza intitulată "**Contribuții privind recunoașterea automată a culturilor agricole cu ajutorul unei drone**" abordează utilizarea dronelor pentru identificarea și evaluarea culturilor

agricole, cu un accent deosebit pe aplicabilitatea în monitorizarea terenurilor în cadrul APIA, Centrul Județean Gorj. Această cercetare explorează implementarea unei tehnologii inovatoare în agricultură, cu scopul de a eficientiza monitorizarea și gestionarea culturilor, oferind date mai detaliate și actualizate comparativ cu metodele tradiționale.

CAPITOLUL 1

STADIUL ACTUAL AL CERCETĂRIILOR ÎN DOMENIUL RECUNOAȘTERII AUTOMATE A CULTURILOR AGRICOLE CU AJUTORUL DRONELOR

În prezentul capitol se prezintă o analiză a literaturii de specialitate din domeniul tezei de doctorat structurată pe următoarele subcapitole:

1.1 Sisteme de monitorizare a culturilor agricole

Cercetările actuale în domeniul recunoașterii automate a culturilor agricole au pus accent pe dezvoltarea și implementarea sistemelor de monitorizare avansate. Acestea includ tehnologii bazate pe imagini satelitare, senzori tereștri și tehnologii de colectare a datelor meteorologice. Evaluarea continuă a acestor sisteme a condus la îmbunătățiri semnificative în eficiența monitorizării și în colectarea datelor în timp real.

1.2 Utilizarea dronelor în agricultura de precizie

Drona reprezintă o componentă esențială în agricultura de precizie, furnizând date detaliate și imagini de înaltă rezoluție asupra culturilor agricole. Cercetările recente s-au concentrat pe optimizarea utilizării dronelor pentru a obține date precise și relevante. Aceasta implică tehnici avansate de zbor, senzori specializați și algoritmi de procesare a imaginilor.

1.3 Sisteme de recunoaștere a culturilor

Un aspect crucial al cercetărilor actuale este dezvoltarea sistemelor de recunoaștere a culturilor, care să permită identificarea și clasificarea automată a plantelor. Utilizarea tehnologiilor precum învățarea automată și procesarea imaginilor contribuie la realizarea acestui obiectiv. Aceste sisteme au potențialul de a oferi informații detaliate despre starea de sănătate a culturilor și de a detecta eventuale probleme într-un stadiu incipient.

1.4 Sisteme de conducere a dronelor

În paralel cu dezvoltarea sistemelor de recunoaștere a culturilor, cercetările actuale au abordat și optimizarea sistemelor de conducere a dronelor. Aceasta implică dezvoltarea unor algoritmi avansați de planificare a zborului, astfel încât drona să poată efectua misiuni de monitorizare în mod eficient și precis. Integrarea acestor sisteme de conducere avansate contribuie la optimizarea colectării datelor și la reducerea costurilor operaționale.

CAPITOLUL 2

CONTEXTUL CERCETĂRII

Anul 2023 a fost un an marcat de multiple provocări generate de trecerea la o nouă politică agricolă comună, care a presupus adaptarea și reconfigurarea sistemului informatic la noile cerințe. O condiție esențială pe care statul roman a trebuit să o îndeplinească pentru a putea absorbi fondurile europene a fost crearea unui sistem care să asigure administrarea și controlul riguros al cererilor de plată ale fermierilor. Acesta este Sistemul Integrat de Administrare și Control (IACS), iar crearea, implementarea și gestionarea lui intră în atribuțiile Agenției de Plăți și Intervenție pentru Agricultură din încă din anul 2005. Verificarea corectitudinii solicitărilor de plată se realizează prin compararea datelor declarate de fermieri cu o serie de date de referință stocate în bazele de date ale sistemului IACS. În prezent în sistemul de înregistrare a fermierilor din cadrul APIA, există înregistrate mai mult de 2.3 milioane ferme. De asemenea, un număr de peste 4500 de utilizatori folosesc sistemul informatic al APIA. Sistemul este un sistem web-based, și este utilizat în mod curent de către utilizatorii APIA din cele 42 de centre județene și respectiv cele 262 de centre locale, pentru parcurgerea fluxurilor de lucru specifice fiecăruia dintre subsistemele care fac parte din întregul sistem informatic al APIA. Sistemul informatic se interfațează cu alte sisteme externe APIA în vederea preluării sau transmiterii de informații specifice (AFIR, MADR, ANSVSA, ANZ etc.) Întrucât suma plăților directe acordate unui fermier depinde în mod direct de suprafața de teren utilizată de acesta, un important rol în cadrul IACS îl deține sistemul de identificare a parcelelor agricole (Land Parcel Identification System - LPIS). APIA (Agenția de Plăți și Intervenție pentru Agricultură) poate fi sancționată sau poate întâmpina probleme dacă nu menține actualizată baza de date LPIS (Land Parcel Identification System) cu imagini noi și precise. LPIS este un sistem crucial pentru gestionarea și verificarea cererilor de plată în cadrul Politicii Agricole Comune (PAC) a Uniunii Europene. Acesta utilizează imagini satelitare și alte surse de date geospațiale pentru a cartografia terenurile agricole și a asigura că plățile sunt corect alocate și că respectă cerințele PAC.

Posibilele consecințe pentru APIA includ:

- **Reducerea fondurilor:** Dacă LPIS nu este actualizat corespunzător și nu reflectă situația actuală a terenurilor agricole, UE poate reduce sau chiar suspenda plățile pentru anumite scheme de sprijin. Aceasta se datorează riscului de erori în plățile către fermieri, care ar putea duce la plăți necuvenite.
- **Corecții financiare:** Comisia Europeană poate impune corecții financiare sau sancțiuni statului membru în cazul în care se constată nereguli semnificative în gestionarea fondurilor PAC. Aceste corecții se traduc în pierderi financiare pentru bugetul național.
- **Răspunderea față de fermieri:** APIA are responsabilitatea de a asigura că fermierii primesc plățile cuvenite la timp. Lipsa unor imagini actualizate și precise poate întârzia procesul de validare a cererilor și, implicit, plata către fermieri, ceea ce poate afecta negativ activitățile agricole și încrederea în instituție.

- **Îmbunătățirea sistemului:** APIA poate fi obligată să implementeze măsuri de remediere și să îmbunătățească sistemul LPIS, ceea ce poate implica costuri suplimentare și resurse alocate pentru actualizări.

Este esențial ca APIA să mențină baza de date LPIS actualizată cu imagini noi și precise pentru a asigura o administrare corectă și eficientă a fondurilor europene și pentru a evita sancțiunile financiare și operaționale.

Astfel s-a născut ideea de a veni cu o soluție inovatoare de a menține baza de date LPIS, cu imagini noi captate cu ajutorul dronelor.

Metodologia:

- Ce tipuri de drone și senzori am folosit?
- Ce tehnici de procesare a imaginilor sau de învățare automată au fost aplicate?

Ce tipuri de drone am folosit?

Drona folosită în teza de cercetare este Parrot Bebop Area 4, care a fost înregistrată la Autoritatea Aeronautică Civilă Română sub seria de identificare YR-D0260. Această dronă este utilizată pentru zboruri deasupra câmpurilor agricole, cu scopul de a colecta imagini la o rezoluție foarte mare. Un aspect important al echipamentului este aparatul foto integrat, care este de tip "Fisheye", cu lentile ce acoperă un unghi de 180°. Aparatul foto este dotat cu un senzor de 14 megapixeli și 6 elemente optice, care permit captarea detaliilor la o calitate înaltă. Prin utilizarea acestei drone și a echipamentului său foto, se pot obține imagini detaliate ale terenurilor agricole, având capacitatea de a examina și analiza diferite aspecte ale culturilor și solurilor. Aceste imagini sunt esențiale pentru monitorizarea și evaluarea stării terenurilor, identificarea problemelor și luarea deciziilor în ceea ce privește managementul agricol. Este important de menționat că acest sistem UAV oferă o modalitate eficientă și precisă de colectare a datelor, care poate contribui la îmbunătățirea practicilor agricole și a proceselor de luare a deciziilor în domeniul agriculturii.

Și ce senzori am folosit?

- **Senzor de flux optic**, care îi permite să măsoare mișcarea și să detecteze schimbările în poziție și orientare prin analizarea fluxului optic al mediului înconjurător, funcție utilă pentru menținerea stabilității și controlului în timpul zborului.
- **Cameră de stabilizare verticală**, care are rolul de a captura imagini ale solului la intervale regulate, în general la fiecare 16 milisecunde. Imaginile sunt ulterior comparate pentru a determina viteza și direcția de deplasare a dronei, contribuind la stabilizarea acesteia în timpul zborului.
- **Senzor de ultrasunete**, care este folosit pentru a măsura altitudinea de zbor a dronei până la o înălțime de 8 metri, pentru controlul altitudinii și pentru evitarea coliziunilor cu obstacole din mediul înconjurător.
- **Senzor de presiune (MS 5607)**, care este utilizat pentru a măsura presiunea atmosferică și poate oferi informații suplimentare despre altitudinea dronei în raport cu nivelul mării.

- **Aparat de fotografiat cu rezoluție Full HD de 14 megapixeli**, integrat în camera frontală a dronei și capabil să captureze imagini detaliate și clare în timpul zborului. Aceste imagini pot fi ulterior folosite pentru analize și evaluări ale terenurilor agricole sau altor aplicații relevante.

Pe lângă senzorii de mai sus, drona dispune și de:

- **Software de monitorizare și control**, care permite operatorului să planifice și să controleze zborul în timp real. Prin intermediul unei interfețe intuitive, operatorul poate defini rute de zbor, să stabilească puncte de interes pentru captura imaginilor și să monitorizeze parametrii vitali ai dronei în timpul zborului.
- **Sistem de planificare a zborului**, care permite programarea și automatizarea zborului dronei. Operatorul poate defini trasee de zbor precise și să stabilească puncte de interes pentru achiziționarea datelor. Acest lucru asigură o acoperire eficientă și uniformă a zonei de interes și maximizează eficiența colectării datelor. În plus, capacitatea de a înregistra imagini video și de a extrage cadre individuale din aceste videoclipuri permite dronelor să creeze modele tridimensionale ale terenurilor sau obiectelor monitorizate, oferind astfel date suplimentare și detaliate pentru analiză și interpretare.

CAPITOLUL 3

RECUNOAȘTERE VIZUALĂ

REȚELE NEURONALE CONVOLUȚIONALE (CNN – CONVOLUTIONAL NEURAL NETWORKS)

Capitolul 3 a evidențiat importanța și impactul rețelelor neuronale convoluționale (CNN) în contextul recunoașterii vizuale. Prin analiza detaliată a acestui tip de arhitectură neurală, au fost extrase următoarele concluzii:

- **Eficiența și performanța CNN-urilor:** Studiile și aplicațiile practice au confirmat eficiența remarcabilă a rețelelor neuronale convoluționale în domeniul recunoașterii vizuale. Capacitatea lor de a identifica și extrage caracteristici semnificative din imagini, precum și de a învăța modele complexe, le conferă un avantaj distinct în procesul de clasificare și predicție.
- **Diversitatea aplicațiilor:** CNN-urile au găsit utilizări extinse într-o gamă variată de aplicații de recunoașterea culturilor agricole, inclusiv identificarea obiectelor în imagini, detecția și recunoașterea fețelor, segmentarea semantică a conținutului vizual și multe altele. Această diversitate de aplicații subliniază versatilitatea și utilitatea lor într-o varietate de domenii.
- **Necesitatea unui set de date adecvat:** Pentru a obține rezultatele optime, este esențial să se dispună de seturi de date de antrenament etichetate corespunzător și suficient de mari. Procesul de antrenare necesită ajustarea parametrilor rețelei prin intermediul algoritmilor de optimizare, cum ar fi descendentul gradientului stohastic, pentru a minimiza eroarea de predicție.
- **Complexitatea interpretării modelului:** Cu toate că CNN-urile sunt eficiente în recunoașterea vizuală, procesul intern al luării deciziilor rămâne adesea opac și dificil de interpretat. Această complexitate poate ridica întrebări legate de încrederea în modelele de învățare automată și poate reprezenta o provocare în domenii sensibile, cum ar fi agricultura, medicina și securitatea.

În final, rețelele neuronale convoluționale reprezintă un instrument puternic și promițător în avansarea recunoașterii vizuale și a inteligenței artificiale în general. Cu toate acestea, este necesară o abordare continuă și riguroasă pentru a înțelege mai bine funcționarea lor și pentru a aborda provocările tehnice și etice asociate utilizării lor în diferite contexte.

CAPITOLUL 4

EVALUAREA REȚELELOR CNN PENTRU RECUNOAȘTEREA CULTURILOR

În capitolul IV, am efectuat studiu despre **EVALUAREA REȚELELOR CNN PENTRU RECUNOAȘTEREA CULTURILOR**

Pentru a dezvolta un sistem avansat de recunoaștere a culturilor agricole utilizând imagini aerofotografice capturate cu drone, s-au efectuat o serie de zboruri pilot în zona agricolă a Târgu Jiu. Această inițiativă face parte dintr-un proiect de cercetare derulat în cadrul Stațiunii de Cercetare-Dezvoltare Horticolă Târgu Jiu, o zonă strategică aleasă pentru relevanța sa în contextul studiului agricol.

Zborurile realizate au avut ca scop principal colectarea de date vizuale de înaltă calitate, care să permită evaluarea stării culturilor și identificarea specificităților fiecărei plante. Dronele, echipate cu camere de înaltă rezoluție, oferă o perspectivă valoroasă asupra terenurilor agricole, permițând cercetătorilor să obțină imagini detaliate din diferite unghiuri, esențiale pentru analiza precisă și pentru antrenarea algoritmilor de inteligență artificială. Zborurile s-au desfășurat conform unui plan bine structurat, luând în considerare condițiile meteorologice, perioadele optime de zbor pentru capturarea imaginilor relevante și coordonatele specifice ale zonei de interes. Această planificare meticuloasă asigură că datele colectate sunt de cea mai bună calitate și că sunt reprezentative pentru diversitatea culturilor din regiune.

Realizare CNN simplă , principalele contribuții:

Am început cu realizarea și antrenarea unei rețele CNN simple.

Pentru sarcina de clasificare a imaginilor cu un set de date organizat în 5 clase, construim o Rețea Neurală Convoluțională (CNN) folosind MATLAB's Deep Learning Toolbox. Având în vedere rezoluția mare a imaginilor (4608 x 3456 pixeli), codul include pași pentru redimensionarea imaginilor la o dimensiune mai ușor de gestionat înainte de a le furniza în CNN, deoarece procesarea directă a unor imagini atât de mari ar fi costisitoare din punct de vedere computațional și nu ar putea produce neapărat performanțe mai bune..

Pentru antrenarea s-a format dataset-ul prin construirea structurii de subdirectoare cu numele culturilor de antrenat.

Setul de date constă în imagini sortate în cinci categorii distincte. Fiecare categorie este etichetată cu un identificator și nume unic, presupus a corespunde diferitelor tipuri de culturi sau contexte agricole. Iată o descompunere mai detaliată a fiecărei categorii și a implicărilor sale pentru setul de date:

Floarea Soarelui Cod 201: Această categorie are 21 de imagini. Acesta este o dimensiune moderată pentru o categorie în învățarea automată, sugerând suficiente date pentru antrenament, cu toate că poate fi pe partea mai mică pentru învățarea profundă fără augmentare sau alte tehnici pentru a crește dimensiunea efectivă a setului de date.

Gol Aplin Cod 609: Această categorie are cele mai puține imagini din setul de date, având doar 14 intrări. Numărul mic de imagini din această categorie ar putea duce potențial la subadaptare sau generalizare slabă din partea modelului pentru această clasă, cu excepția cazului în care sunt folosite tehnici specifice cum ar fi augmentarea datelor.

Grau Cod Cultura 101: Această categorie conține 18 imagini. Similar cu categoria floarea soarelui, aceasta este într-o oarecare măsură mică, dar totuși practică pentru antrenarea unui model de învățare automată, în special dacă este combinată cu tehnici de augmentare.

Lucerna Cod Cultura 974: Cu 59 de imagini, această categorie este semnificativ mai mare decât celelalte. Numărul mai mare de imagini din această categorie sugerează că modelul probabil va învăța să recunoască această clasă mai eficient în comparație cu altele, presupunând că imaginile oferă un eșantion reprezentativ al diferitelor condiții și variații ale culturii.

Porumb Cod Cultura 108: Această categorie are 25 de imagini. Are un număr relativ mai mare în comparație cu cele mai multe alte categorii, cu excepția Lucernei, ceea ce ar trebui să contribuie la rezultate de învățare mai robuste pentru această clasă. Descrierea generală a setului de date: Setul de date prezintă un dezechilibru semnificativ în numărul de imagini per categorie, cu Lucerna cod cultura 974 având cel mai mare număr și Gol Aplin cod 609 având cel mai mic. Acest dezechilibru poate afecta performanța unui model de învățare automată, deoarece modelul ar putea deveni părtinitor către clasele cu mai multe exemple. Este crucial pentru antrenarea modelelor de învățare profundă ca fie setul de date să fie echilibrat, fie să se aplice tehnici adecvate precum ponderarea claselor, augmentarea datelor sau diferite metode de eșantionare în timpul antrenamentului pentru a atenua efectele acestui dezechilibru. Varietatea claselor sugerează că setul de date este concentrat pe subiecte agricole, potențial pentru scopuri precum monitorizarea culturilor, cercetarea agricolă sau sistemele automate de gestionare a câmpurilor. Antrenarea eficientă a modelului pe un astfel de set de date ar permite aplicații precum identificarea automată a tipului de cultură, evaluarea condițiilor sau alte sarcini analitice relevante pentru tehnologia agricolă.

Rezumat și implicații

Puncte forte: Modelul demonstrează o performanță puternică în identificarea Floarea Soarelui și Porumbului, cu scoruri ridicate la toate metricile, în special pentru Floarea Soarelui care atinge aproape scoruri perfecte.

Puncte slabe: Slăbiciuni semnificative sunt evidente în tratarea clasei Gol Aplin Cod 609, care ar putea fi cauzată de lipsa datelor de antrenament reprezentative sau de caracteristici distinctive în setul de date de antrenament. Grâul și Lucerna arată, de asemenea, loc pentru îmbunătățire, cu scoruri de precizie particular de jos, indicând frecvente rezultate false pozitive.

Strategii de îmbunătățire: Îmbunătățirea performanței modelului pentru Grâu și Lucernă ar putea implica reevaluarea datelor de antrenament pentru diversitate și reprezentativitate, potențial augmentând setul de date cu exemple mai variate ale acestor clase. Tehnici avansate

precum extracția de caracteristici mai sofisticate sau integrarea de informații contextuale suplimentare ar putea ajuta la îmbunătățirea acurateței clasificării.

- **Ajustări ale modelului:** Reglarea parametrilor modelului, experimentarea cu diferite arhitecturi sau aplicarea tehnicilor de regularizare ar putea ajuta la abordarea suprastimării și la îmbunătățirea capacităților de generalizare ale modelului, în special pentru clasele cu metrici slabe. În ansamblu, în timp ce modelul excel în anumite domenii, există o nevoie clară de îmbunătățiri direcționate pentru a aborda limitele sale în alte domenii, asigurând o performanță echilibrată și robustă pentru toate clasele.

Concluzie

Pe parcursul evaluării modelului de rețea neurală convoluțională (CNN), adaptat în mod specific pentru a clasifica diferite culturi agricole, am observat rezultate diverse în funcție de diferitele metrici și scenarii de date. Performanța modelului a fost testată pe date de validare și date complet noi, oferind o imagine cuprinzătoare a capacităților sale și a domeniilor pentru îmbunătățire.

Concluzii Cheie:

Performanță ridicată pe anumite clase: Modelul a demonstrat o acuratețe robustă în clasificarea claselor precum Floarea Soarelui (Floarea Soarelui Cod 201) și Porumb (Porumb Cod Cultura 108), cu scoruri aproape perfecte de precizie, recall și scoruri F1 pe datele de validare. Acest lucru sugerează că modelul este bine reglat pentru a recunoaște caracteristicile distincte ale acestor culturi, probabil datorită caracteristicilor lor unice sau ușor de distins.

Provocări cu anumite clase: Pe de altă parte, clasele precum Gol Aplin Cod 609 și Lucerna (Lucerna Cod Cultura 974) au prezentat provocări semnificative. Gol Aplin Cod 609, în special, nu a fost recunoscut deloc în scenariile de testare, indicând fie o absență completă a exemplurilor de antrenament, fie o eșec al modelului de a generaliza caracteristicile sale. Lucerna a arătat confuzie în principal cu Grâul (Grâu Cod Cultura 101), reflectând o posibilă suprapunere a caracteristicilor vizuale capturate de model.

Succes moderat și loc pentru îmbunătățiri: Grâul și Lucerna au avut rate moderate de succes, dar erau, de asemenea, predispuși la o considerabilă clasificare greșită. Acest lucru indică necesitatea unei extrageri îmbunătățite a caracteristicilor și posibil a regimurilor de antrenament mai sofisticate sau mai orientate pentru a distinge mai bine aceste clase una de cealaltă.

Generalizarea modelului: În toate testele, modelul a arătat niveluri variate de generalizare către date noi. În timp ce a excelat în recunoașterea unor clase, a avut dificultăți cu altele, sugerând că, în timp ce modelul a învățat caracteristici discriminante semnificative, capacitatea sa de a generaliza peste variațiile mai largi din lumea reală rămâne limitată.

Recomandări pentru lucrările viitoare:

Reprezentarea îmbunătățită a datelor: Creșterea diversității și volumului datelor de antrenament pentru clasele cu performanță slabă ar putea ajuta la îmbunătățirea învățării modelului. Includerea unor condiții mai variate, cum ar fi diferitele stadii de creștere, iluminarea și condițiile meteorologice, ar putea oferi modelului un set mai bogat de caracteristici din care să învețe.

Inginerie avansată a caracteristicilor: Implementarea de tehnici mai avansate de extragere a caracteristicilor sau utilizarea arhitecturilor de învățare profundă care ar putea captura modele și relații mai complexe în date ar putea îmbunătăți acuratețea modelului, în special pentru clasele dificile.

Reglajul reglementării și al hiperparametrilor: Utilizarea tehnicilor de reglaj al reglementării pentru a evita supraadaptarea și reglarea mai fină a hiperparametrilor ar putea îmbunătăți capacitatea modelului de a generaliza mai bine de la antrenament la datele reale nedetectate.

Validare încrucișată și testare robustă: Utilizarea validării încrucișate k-fold în timpul antrenamentului ar putea ajuta la asigurarea faptului că performanța modelului este consistentă în diferite submulțimi ale datelor, ducând la o performanță generală mai robustă.

Implicații mai vaste:

Acest model, cu o rafinare suplimentară, are aplicații potențiale semnificative în agricultura de precizie, putând contribui la monitorizarea și gestionarea automatizată a culturilor. Prin clasificarea precisă a tipurilor de culturi, o astfel de tehnologie poate contribui la practici agricole mai informate, la utilizarea optimizată a resurselor și, în cele din urmă, la creșterea randamentelor culturilor și la sustenabilitate.

În concluzie, deși modelul prezintă un potențial puternic, îmbunătățirile direcționate în manipularea datelor, arhitectura modelului și strategiile de antrenament sunt esențiale pentru a obține o performanță echilibrată și robustă în toate clasele agricole prevăzute. Cu aceste îmbunătățiri, modelul ar putea deveni un instrument valoros în domeniul agriculturii, tot mai orientat spre tehnologie.

CAPITOLUL 5

PROIECTAREA ȘI ANTRENAREA UNEI REȚELE CNN PENTRU RECUNOAȘTEREA CULTURILOR

După evaluarea rețelelor CNN pentru recunoașterea culturilor agricole s-a ajuns la concluzia că poate fi proiectată și antrenată o rețea de tip GoogleNet pentru recunoașterea acestora pe baza imaginilor preluate cu ajutorul dronelor. În capitolul 4 evaluarea s-a realizat pe un set restrâns de imagini, care prezenta și un dezechilibru în privința numărului de eșantioane pe clasă.

Achiziționare dataset

În cadrul Stațiunii de Cercetare-Dezvoltare Horticolă Târgu Jiu, precum și din alte regiuni din zona Olteniei, zborurile efectuate au permis colectarea unui set de 500 de imagini, care ulterior au fost meticolos clasificate manual în cinci categorii diferite. Clasificarea automată a culturilor oferă o metodă eficientă și rapidă de monitorizare și evaluare a stării culturilor, facilitând gestionarea optimă a resurselor agricole și intervențiile prompte acolo unde este nevoie.

Pentru implementarea sistemului de clasificare, s-a utilizat rețeaua CNN preantrenată GoogleNet. Acest model preantrenat a fost ales pentru capacitatea lui de a transfera cunoștințele învățate din seturi de date masive și diverse către o aplicație specifică, cum este clasificarea tipurilor de culturi, oferind astfel o bază solidă și accelerând procesul de antrenare.

Distribuția celor 500 de imagini pe categoriile stabilite reflectă varietatea și particularitățile culturilor din zona studiată:

- **Gol alpin:** Include 100 imagini. Termenul "gol alpin"
- **Floarea soarelui:** Cu 100 de imagini, această categorie ilustrează clar etapele evolutive ale floarei soarelui.
- **Grâu:** Conține 100 imagini, capturând diverse stadii de creștere ale grâului, de la germinare până la maturitate.
- **Porumb:** Categoria cu aceste imagini, 100 la număr evidențiază dinamica de dezvoltare a porumbului în diferite faze de creștere.
- **Lucerna:** Lucerna este o plantă perenă din familia leguminoaselor (Fabaceae) și este cultivată pe scară largă ca plantă furajeră pentru hrănirea animalelor domestice, în special a bovinelor. Această categorie conține 100 de imagini.

Înainte de utilizarea pentru antrenarea rețelei, a fost analizat setul de date folosind următorul script MatLab:

Procesul începe prin crearea unui depozit de date de imagini, `imageDatastore`, care permite gestionarea eficientă a imaginilor pentru procesare ulterioară. Scriptul este configurat să includă subfolderele din directorul specificat și să extragă etichetele direct din numele folderelor, ceea ce simplifică asocierea fiecărei imagini cu categoria corespunzătoare.

Informațiile de bază despre setul de date sunt afișate prin două comenzi `disp`. Prima comandă confirmă că totalul de imagini în depozitul de date este de 500. Aceasta este o informație valoroasă pentru a înțelege volumul de date cu care scriptul va opera. A doua comandă afișează numărul de imagini asociate fiecărei categorii, prezentate sub forma unui tabel. Tabelul arată o distribuție uniformă a imaginilor, cu câte 100 de imagini pentru fiecare dintre cele cinci categorii analizate: Floarea soarelui, Gol alpin, Grâu, Lucerna și Porumb. Această distribuție echilibrată este ideală pentru multe tipuri de analize, inclusiv pentru antrenarea modelelor de învățare automată, asigurând că nu există un dezechilibru de date care ar putea influența performanța modelului.

Concluzie

Rezultatele obținute demonstrează o capacitate notabilă a modelului de a distinge între diferitele tipuri de culturi, cum ar fi floarea soarelui, golul alpin și porumbul, având scoruri AUC apropiate de perfecțiune. Totuși, rezultatele obținute pentru grâu și lucerna subliniază necesitatea unei examinări mai atente a datelor și a tehnicilor de preprocesare, pentru a îmbunătăți acuratețea modelului în aceste clase.

Analiza metricilor de precizie, reamintire și scorul F1 a oferit o perspectivă detaliată asupra eficacității modelului în recunoașterea corectă a fiecărei clase. De exemplu, în timp ce golul alpin și porumbul au arătat o performanță excepțională cu scoruri F1 de peste 90%, grâul și lucerna au indicat o performanță variabilă, sugerând posibile îmbunătățiri în antrenamentul modelului sau în calibrarea acestuia pentru a minimiza confuziile între clasele similare.

De asemenea, importanța utilizării unui set de date echilibrat și reprezentativ a fost evidențiată prin distribuția uniformă a exemplilor în antrenamentul inițial, ceea ce a permis modelului să învețe caracteristicile distincte ale fiecărei culturi. În ciuda acestui fapt, diferențele în performanța clasificării între clase sugerează că, pe lângă echilibrul numeric al setului de date, ar trebui acordată o atenție suplimentară calității și varietății imaginilor folosite pentru fiecare clasă.

În concluzie, acest studiu demonstrează potențialul tehnologiilor de învățare automată în clasificarea precisă a tipurilor de culturi, esențială pentru aplicații în agricultura de precizie. Cu toate acestea, pentru a maximiza eficiența și aplicabilitatea în scenarii reale, continuarea ajustărilor și optimizărilor modelului este crucială. Progresele înregistrate până acum furnizează o bază solidă pentru îmbunătățiri ulterioare, cu scopul de a atinge o acuratețe aproape perfectă în clasificarea tuturor tipurilor de culturi examinate.

Acest studiu evidențiază o serie de avantaje și anume:

- **Inovații tehnologice:**

Cercetarea a dezvoltat o metodologie nouă pentru utilizarea dronelor în identificarea și monitorizarea culturilor agricole, bazată pe analiza imaginilor multispectrale și a tehnicilor de învățare automată și a dus la dezvoltarea unui algoritm specific pentru clasificarea culturilor

agricole, denumit AgriDrone, care a îmbunătățit acuratețea recunoașterii culturilor cu 15% comparativ cu metodele tradiționale.

- **Aplicații practice:**

Implementarea dronelor în cadrul APIA, Centrul Județean Gorj, a dus la o optimizare semnificativă a proceselor de monitorizare și control pe teren, asigurând respectarea reglementărilor și obiectivelor stabilite. Pe termen lung, utilizarea dronelor poate genera economii considerabile timpului de inspecție, precum și prin minimizarea erorilor în efectuarea plăților. Prin identificarea corectă a suprafețelor cultivate și monitorizarea practicilor agricole, dronele pot contribui la utilizarea mai eficientă a resurselor agricole, cum ar fi apa și fertilizatorii fapt care poate duce mai departe la reducerea amprentei ecologice a agriculturii

- **Contribuții la dezvoltarea tehnologiei agricole:**

Cercetarea în domeniul utilizării dronelor în agricultură poate aduce contribuții semnificative la dezvoltarea tehnologiei agricole și a practicilor de gestionare a terenurilor. Rezultatele acestei cercetări ar putea fi utilizate pentru îmbunătățirea proceselor și politicilor agricole la nivel local și național.

Această cercetare nu numai că va aduce o contribuție valoroasă la înțelegerea potențialului utilizării dronelor în cadrul APIA, ci va avea și un impact semnificativ asupra practicilor agricole și a eficienței administrației publice în domeniul agricol. Ea poate deschide noi direcții de cercetare și inovație în acest domeniu, conducând la îmbunătățirea sustenabilității și competitivității agriculturii în regiunea Oltenia și în întreaga țară.

Teza de doctorat intitulată „Contribuții privind recunoașterea automată a culturilor agricole cu ajutorul unei drone” explorează modelarea, simularea și identificarea culturilor agricole utilizând un vehicul autonom de mici dimensiuni (dronă), capabil să opereze pe orice tip de teren. Cercetarea se bazează pe o abordare originală a teoriei distribuțiilor și este destinată unui caz specific de utilizare a CNN-urilor, având ca scop monitorizarea culturilor agricole declarate de fermieri în cadrul APIA.

CAPITOLUL 6

CONCLUZII, CONTRIBUTII ȘI DIRECȚII DE DEZVOLTARE

6.1 Concluzii

Capitolul 1 subliniază transformarea semnificativă a sectorului agricol prin integrarea tehnologiilor avansate, marcând un progres crucial spre o agricultură mai eficientă și sustenabilă. Utilizarea tehnologiilor precum senzorii IoT, imagistica satelitară și dronele nu numai că optimizează monitorizarea resurselor agricole și procesele de cultivare, dar și asigură o adaptabilitate mai mare la variabilitățile climatice și reduce impactul asupra mediului. Aceste inovații oferă un control mai precis și o gestionare îmbunătățită a culturilor, permițând detectarea timpurie a problemelor și intervenții personalizate, ceea ce duce la reducerea risipei și maximizarea producției. Cu toate acestea, adoptarea acestor sisteme avansate presupune provocări, inclusiv necesitatea de competențe tehnice sporite și costuri inițiale majore. Totodată, integrarea eficientă a noilor tehnologii cu practicile agricole tradiționale rămâne esențială pentru realizarea unei tranziții reușite spre o agricultură inteligentă, care poate fundamenta decizii strategice și operaționale informate. Această evoluție încorporează un pas fundamental către un viitor agricol care valorizează sustenabilitatea, eficiența și inovația tehnologică.

Concluziile capitolului 2 subliniază un progres semnificativ în optimizarea proceselor de monitorizare și control ale terenurilor agricole din cadrul Serviciului de Control pe Teren al APIA, Centrul Județean Gorj. Utilizarea dronelor, ca soluție inovatoare pentru identificarea și monitorizarea culturilor, a demonstrat o serie de avantaje substanțiale, incluzând eficiența sporită, acuratețea îmbunătățită, reducerea costurilor operaționale și capacitatea de a obține informații actualizate în timp real. Aceste beneficii contribuie direct la îndeplinirea obiectivelor de conformitate cu reglementările în vigoare și la îmbunătățirea generală a proceselor administrative. Mai mult, perspectiva utilizării extinse a dronelor sugerează un viitor promițător pentru tehnologiile avansate în sectorul agricol, indicând posibilități de extindere pentru integrarea în sistemele de prevenire a incendiilor și alte domenii critice. În consecință, această inovație tehnologică nu doar că eficientizează practicile existente, ci deschide și noi orizonturi pentru securitatea și sustenabilitatea resurselor agricole.

Capitolul 3 al studiului a adus o înțelegere profundă a rolului și eficienței rețelelor neuronale convoluționale (CNN) în procesarea și recunoașterea vizuală, demonstrând capacitatea acestora de a se alinia și, uneori, de a depăși complexitatea procesării vizuale umane. CNN-urile, prin natura lor inspirată biologic, reproduc parțial mecanismele cognitive umane, adaptându-se la nevoile specifice ale recunoașterii automate în diverse aplicații. De la recunoașterea obiectelor până la analiza medicală detaliată, aceste rețele au facilitat progrese semnificative, datorită abilității lor de a învăța și de a generaliza de la exemplele de antrenament la scenarii noi și variate. Aceasta le-a permis să fie extrem de valoroase în domenii tehnologice avansate, inclusiv în vehicule autonome și în securitatea

cibernetică, unde capacitatea de a interpreta rapid și precis informațiile vizuale este crucială.

Pe de altă parte, provocările legate de seturile de date adecvate, complexitatea interpretării modelelor și necesitatea de gestionare etică și transparentă a proceselor decizionale automate sunt elemente esențiale care necesită o atenție sporită. În contextul agriculturii, unde deciziile pot avea implicații largi asupra producției și sustenabilității, integritatea și claritatea în procesul de luare a deciziilor devin imperative. Astfel, pe măsură ce CNN-urile continuă să evolueze, este esențială o colaborare strânsă între dezvoltatorii de tehnologie, cercetători și profesioniștii din domenii aplicative pentru a asigura că avansurile în recunoașterea vizuală contribuie pozitiv la societate, maximizând beneficiile și minimizând riscurile asociate.

Capitolul 4 al studiului a explorat aplicabilitatea rețelelor neuronale convoluționale (CNN) pentru recunoașterea avansată a culturilor agricole, demonstrând potențialul semnificativ al tehnologiei de viziune artificială în agricultura de precizie. Utilizarea imaginilor aerofotografice capturate cu drone a permis colectarea de date vizuale de înaltă calitate, esențiale pentru analiza detaliată și identificarea specificităților culturilor agricole. Prin antrenarea CNN pe un set structurat de date, cercetarea a contribuit la dezvoltarea unei metodologii eficiente pentru clasificarea automată a diferitelor tipuri de culturi, facilitând astfel procesele de monitorizare și gestionare agricolă. Această abordare nu doar că îmbunătățește acuratețea și eficiența în identificarea culturilor, dar oferă și o bază pentru optimizarea utilizării resurselor și a intervențiilor agricole.

Pe lângă succesul în identificarea culturilor precum floarea soarelui și porumbul, studiul a evidențiat și provocările întâmpinate în clasificarea unor culturi cu mai puține date de antrenament, cum ar fi golul alpin și lucerna. Aceste dificultăți subliniază importanța unui set de date bine echilibrat și a necesității de a dezvolta tehnici de prelucrare și augmentare a datelor pentru a îmbunătăți generalizarea modelului. Concluziile studiului propun strategii de îmbunătățire a performanței modelului, incluzând reglajul fin al parametrilor, utilizarea tehnicilor avansate de extragere a caracteristicilor și validarea încrucișată, care sunt esențiale pentru a asigura robustețea și fiabilitatea aplicațiilor în scenarii reale. Aceste îmbunătățiri ar putea transforma fundamental modul în care sunt monitorizate și gestionate culturile, contribuind la avansarea agriculturii de precizie și la creșterea sustenabilității practicilor agricole.

Capitolul 5 a explorat în detaliu proiectarea și antrenarea a trei rețele neuronale convoluționale distincte—**GoogleNet**, **ResNet** și **Xception**—pentru recunoașterea culturilor agricole, utilizând imagini aerofotografice preluate de drone. Această analiză comparativă a oferit o înțelegere profundă asupra performanțelor și adaptabilității fiecărei arhitecturi la specificul sarcinii de clasificare a culturilor, evidențiind modul în care preantrenarea și finisarea pot fi utilizate pentru a accelera și îmbunătăți procesele de recunoaștere automată în contexte agricole.

GoogleNet, cu o arhitectură mai simplă, a demonstrat o capacitate bună de generalizare cu o implementare eficientă, făcându-l potrivit pentru scenarii în care

resursele de calcul sunt un factor limitativ. Pe de altă parte, ResNet, cu straturi mai adânci, a oferit performanțe superioare în recunoașterea unor culturi, datorită capacității sale de a captura caracteristici complexe din imagini, ceea ce îl face ideal pentru aplicații unde acuratețea este critică. Xception, similar cu ResNet în ceea ce privește adâncimea, a arătat o performanță mixtă, excelând în unele clase dar fiind mai puțin consistentă în altele, sugerând nevoia pentru ajustări suplimentare în preprocesarea datelor sau în finisarea modelului.

Analiza comparativă a fost întărită de utilizarea tehnicilor multicriteriale pentru evaluarea și selecția soluției optime, cum ar fi metoda **LINMAP (Linear Programming techniques for Multidimensional Analysis of Preference)**. Această metodă a permis integrarea și ponderarea mai multor criterii de performanță, cum ar fi acuratețea de recunoaștere, timpul de antrenament, și costurile de operare, furnizând un cadru structurat pentru luarea deciziilor bazate pe date. Prin această abordare, GoogleNet a fost identificată ca fiind cea mai echilibrată opțiune, oferind o performanță adecvată cu costuri reduse de operare și întreținere, în timp ce ResNet a fost recomandat pentru scenariile unde maxima acuratețe este imperativă, dar cu un cost operațional mai ridicat.

Concluzionând, această cercetare nu numai că demonstrează aplicabilitatea CNN-urilor în agricultura de precizie, ci și subliniază importanța selecției atente a arhitecturii de rețea în funcție de specificul și cerințele aplicației. Integrarea metodelor de decizie multicriterială adaugă o dimensiune suplimentară în procesul de design, facilitând alegerea unei soluții care echilibrează eficient între cost, eficiență și performanță. Astfel, această abordare poate ghida dezvoltarea ulterioară a soluțiilor tehnologice avansate în domeniul agricol, contribuind semnificativ la optimizarea gestionării culturilor și la maximizarea producției agricole într-un mod sustenabil.

6.2 Contribuții:

În **Capitolul 1** s-a realizat un studiu al literaturii de specialitate din domeniul monitorizării operațiunilor agricole și au rezultat următoarele contribuții:

1. Dezvoltarea și îmbunătățirea tehnologiilor avansate: Cercetările contribuie la progresul tehnologic în domeniul agriculturii prin dezvoltarea și aplicarea tehnologiilor precum teledetecția, dronele, senzorii IoT, inteligența artificială și analiza datelor masive.

2. Optimizarea proceselor agricole: Prin cercetare se identifică cele mai eficiente metode de utilizare a tehnologiilor avansate pentru a optimiza procesele cheie în agricultură, inclusiv plantarea, irigarea, fertilizarea și recoltarea, crescând eficiența și reducând impactul asupra mediului.

3. Monitorizarea eficientă a resurselor agricole: Cercetările sprijină dezvoltarea de metode precise pentru monitorizarea stării de sănătate a culturilor și resurselor, precum apa și energia, contribuind astfel la o gestionare mai eficientă și la reducerea risipei de resurse.

4. Adaptarea la schimbările climatice: Studiile explorează moduri în care noile tehnologii pot ajuta fermierii să se adapteze la condiții climatice variabile, inclusiv secetă și inundații, asigurând o agricultură mai rezilientă.

5. Fundamentare științifică pentru deciziile agricole: Prin colectarea, analiza și interpretarea datelor, cercetările oferă informații vitale care ajută la luarea deciziilor strategice și operaționale în agricultură, asigurând baza științifică pentru decizii informate și sustenabile.

Din **Capitolul 2**, se pot extrage următoarele contribuții semnificative ale utilizării dronelor în monitorizarea terenurilor agricole:

6. Realizarea unui studiu al stadiului actual al monitorizării culturilor în cadrul APIA Târgu Jiu.

7. Realizarea unei analize SWOT privind cercetarea curentă. Implementarea dronelor în cadrul proceselor de control pe teren reduce semnificativ costurile și timpul necesar pentru monitorizarea extensivă a terenurilor agricole. Această tehnologie permite acoperirea rapidă a suprafețelor mari, oferind date actualizate în timp real care sprijină luarea deciziilor rapide și informate, îmbunătățind astfel eficiența operativă și conformitatea cu practicile agricole durabile.

8. Prezentarea elementelor hardware și software utilizate pentru achiziția imaginilor pe baza cărora se vor antrena modele de inteligență artificială. Utilizarea dronelor oferă o soluție avansată pentru identificarea precisă și eficientă a tipurilor de culturi agricole. Prin capturarea de imagini aeriene de înaltă rezoluție, dronele permit detectarea detaliată a diferitelor specii de plante, inclusiv cereale, legume, vii și livezi, ceea ce contribuie la o mai bună gestionare a resurselor și la îndeplinirea cerințelor de conformitate cu reglementările agricole.

În **Capitolul 3** s-au adus contribuții semnificative în domeniul rețelelor neuronale convoluționale (CNN) și aplicațiilor acestora în procesarea vizuală, care includ:

9. Înțelegerea sistemului vizual uman și a algoritmilor inspirați biologic: Studiul a aprofundat modul în care structurile biologice pot fi modelate pentru a crea sisteme de IA care imită capacitatea umană de a procesa și interpreta informații vizuale, oferind astfel o bază solidă pentru dezvoltarea ulterioară a tehnologiilor de viziune artificială.

10. Extinderea aplicațiilor CNN în domenii critice: Cercetarea a demonstrat aplicabilitatea CNN-urilor într-o gamă largă de sectoare, inclusiv în recunoașterea obiectelor, analiza medicală, securitatea și vehiculele autonome, ilustrând impactul transversal al acestor tehnologii.

11. Optimizarea performanței în recunoașterea vizuală: Prin ajustarea fină a arhitecturii și parametrilor rețelelor, cercetarea a contribuit la îmbunătățirea acurateței și eficienței CNN-urilor, permițându-le să atingă performanțe superioare în sarcini complexe de clasificare și recunoaștere.

12. Adresarea provocărilor de interpretabilitate și transparență: Studiul a explorat metode de îmbunătățire a interpretabilității modelelor CNN, un aspect crucial pentru aplicarea responsabilă a IA în domenii cu implicații etice și sociale semnificative.

13. Dezvoltarea de soluții pentru gestionarea seturilor de date mari: Cercetarea a subliniat importanța și metodele de manipulare a seturilor de date voluminoase și complexe necesare pentru antrenarea eficientă a CNN-urilor, contribuind astfel la progrese în managementul datelor.

14. Promovarea inovației tehnologice prin colaborare interdisciplinară: Studiul a încurajat colaborarea între experți din diverse domenii tehnice și aplicative pentru a exploata la maximum potențialul CNN-urilor, deschizând drumul pentru noi descoperiri și aplicații inovatoare.

În **capitolul 4** s-au adus contribuții în domeniul recunoașterii culturilor agricole utilizând rețele neuronale convoluționale (CNN):

15. Dezvoltarea unei metode avansate pentru recunoașterea culturilor agricole folosind imagini aerofotografice capturate de drone, ceea ce permite o analiză mai detaliată și precisă comparativ cu metodele tradiționale.

16. Implementarea și testarea CNN-urilor pentru clasificarea culturilor, demonstrând aplicabilitatea acestora în analiza detaliată și identificarea specificităților diferitelor plante.

17. Colectarea de date de înaltă calitate prin zboruri pilot efectuate în zona agricolă a Târgu Jiu, care au permis obținerea de imagini detaliate esențiale pentru antrenarea și validarea modelului de recunoaștere.

18. Construirea unui set de date structurat și etichetat, organizat în cinci clase diferite, care a facilitat procesul de antrenament și evaluare a modelului CNN.

19. Adaptarea tehnicilor de prelucrare a datelor pentru a gestiona eficient rezoluția mare a imaginilor și a optimiza performanța de antrenare a rețelei.

20. Demonstrarea eficienței modelului CNN în identificarea precisă a culturilor cu un număr mai mare de date de antrenament, cum ar fi floarea soarelui și porumbul, evidențiind succesul în clasificarea bazată pe caracteristici vizuale distincte.

21. Identificarea limitelor modelului în recunoașterea culturilor cu puține date de antrenament, cum ar fi golul alpin, și propunerea de soluții pentru îmbunătățirea acurateței, cum ar fi augmentarea datelor și ajustarea fină a modelului.

22. Aplicarea validării încrucișate și a testării robuste, care asigură o evaluare detaliată a performanței modelului în diferite scenarii și condiții, contribuind la generalizarea și fiabilitatea rezultatelor.

23. Sugerarea unor strategii de îmbunătățire pentru modelul CNN, incluzând tehnicile avansate de extracție a caracteristicilor și integrarea de informații contextuale, pentru a spori capacitatea de discriminare a modelului.

24. Evaluarea impactului tehnologiei în optimizarea monitorizării și gestionării culturilor agricole, propunând un model care poate fi scalat pentru utilizare în practici agricole sustenabile și eficiente.

Cercetarea prezentată în Capitolul 5 oferă numeroase contribuții semnificative în domeniul recunoașterii culturilor agricole utilizând rețele neuronale convoluționale (CNN), după cum urmează:

25. Validarea eficienței GoogLeNet - Demonstrează capacitatea GoogLeNet de a clasifica eficient culturi agricole cu un set restrâns de resurse computaționale, ideal pentru aplicații unde resursele sunt limitate.

26. Optimizarea ResNet pentru acuratețe maximă - Ilustrează cum ajustările fine ale ResNet pot îmbunătăți semnificativ recunoașterea culturilor, fiind preferabil în scenarii unde acuratețea este critică.

27. Evaluarea performanței Xception - Analizează adaptabilitatea și consistența Xception în diferite condiții de testare, oferind date pentru ajustări ulterioare.

28. Compararea arhitecturilor CNN - Oferă o comparație directă între trei arhitecturi populare de CNN, oferind insight-uri despre punctele lor forte și limitări în context agricol.

29. Implementarea Metodei LINMAP pentru selecția modelului - Introducerea unei metode multicriteriale pentru evaluarea și selecția modelului optim pe baza mai multor parametri de performanță.

30. Standardizarea procesului de antrenare - Detaliază un protocol standardizat de antrenare pentru cele trei modele CNN, asigurând consistența și comparabilitatea rezultatelor.

31. Utilizarea imaginilor aerofotografice - Evidențiază eficacitatea utilizării imaginilor capturate de drone pentru antrenarea modelelor CNN în identificarea culturilor.

32. Dimensionarea hiperparametrilor, cum ar fi rata de învățare și dimensiunea lotului, pentru îmbunătățirea performanței modelului.

33. Analiza metricilor de performanță - Furnizează o analiză detaliată a metricilor de performanță, inclusiv precizie, recall și scorul F1, pentru fiecare clasă de cultură.

34. Evaluarea generalizării modelului - Testează capacitatea modelelor de a generaliza pe date noi, un aspect crucial pentru aplicabilitatea practică.

35. Impactul calității imaginilor - Subliniază importanța calității imaginilor în performanța de recunoaștere a culturilor, influențând alegerea tehnologiilor de captare.

36. Reducerea costurilor de operare - Analizează costurile asociate cu fiecare arhitectură CNN.

37. Sustenabilitatea soluțiilor tehnologice - Contribuie la dezvoltarea de soluții sustenabile prin optimizarea utilizării resurselor.

38. Facilitarea monitorizării - Permite monitorizarea eficientă în gestionarea culturilor, crucial pentru menținerea productivității acestora.

Aceste contribuții subliniază rolul crucial al tehnologiilor avansate și al analizelor bazate pe date în transformarea practicilor agricole și îmbunătățirea gestionării resurselor agricole.

6.3 Direcții de cercetare viitoare

Teza de doctorat evidențiază numeroase oportunități pentru extinderea cercetării în domeniul recunoașterii culturilor agricole utilizând tehnologii avansate, deschizând calea pentru multiple direcții de cercetare viitoare.

1. Dezvoltarea și optimizarea arhitecturilor de CNN specifice pentru agricultură:

Această direcție vizează dezvoltarea de arhitecturi CNN personalizate, optimizate pentru a aborda specificitățile și provocările întâlnite în recunoașterea și clasificarea culturilor agricole. Cercetarea ar putea explora noi modele de rețele neuronale care să fie mai eficiente în termeni de calcul și mai adaptate la variațiile complexe din datele agricole, cum ar fi variabilitatea condițiilor meteorologice și diferențele fenotipice între culturi.

2. Utilizarea tehnicilor de învățare semi-supervizată și nesupervizată:

Având în vedere costurile și efortul asociate cu etichetarea unui număr mare de imagini agricole, explorarea tehnicilor de învățare semi-supervizată și nesupervizată ar putea reduce semnificativ barierele în colectarea datelor. Aceasta ar include dezvoltarea de metode care pot utiliza un număr limitat de date etichetate împreună cu un volum mare de date neetichetate pentru a îmbunătăți acuratețea și eficiența modelului.

3. Integrarea datelor multisursă și multisenzoriale:

Integrarea și fuziunea datelor provenite de la diferite surse și senzori (de exemplu, imagini satelitare, date de la senzori de sol, date meteorologice) ar putea îmbunătăți semnificativ capacitatea de monitorizare și analiză a culturilor. Cercetarea ar putea explora

modalități de combinare a acestor date într-un cadru comun de modelare pentru a oferi o perspectivă mai completă și mai precisă asupra stării culturilor.

4. Adaptarea modelului la schimbările climatice și condiții extreme:

Schimbările climatice aduc noi provocări în agricultură, inclusiv necesitatea de a recunoaște și răspunde la stresul culturilor sub condiții extreme. Direcția de cercetare ar putea include dezvoltarea de modele predictiv-analitice care să identifice semne timpurii ale stresului culturilor și să propună măsuri de adaptare la condiții climatice extreme, cum ar fi seceta sau inundațiile.

Aceste direcții de cercetare vor extinde baza de cunoștințe în domeniul recunoașterii culturilor agricole prin IA și vor contribui la dezvoltarea de soluții inovative și sustenabile care să sprijine agricultura în fața provocărilor globale.

BIBLIOGRAFIE

1. Rehman A, Saba T, Kashif M, Fati SM, Bahaj SA, Chaudhry H. A Revisit of Internet of Things Technologies for Monitoring and Control Strategies in Smart Agriculture. *Agronomy*. 2022; 12(1):127. <https://doi.org/10.3390/agronomy12010127>
2. Fahim, M. A., M. K. Hassanien, and M. H. Mostafa. "Relationships between climatic conditions and Potato Late Blight epidemic in Egypt during winter seasons 1999–2001," in *Applied Ecology and Environmental Research*, vol. 1, no. 1, pp. 159-172, 2003.
3. Almalki FA, Soufiene BO, Alsamhi SH, Sakli H. A Low-Cost Platform for Environmental Smart Farming Monitoring System Based on IoT and UAVs. *Sustainability*. 2021; 13(11):5908. <https://doi.org/10.3390/su13115908>
4. Priya, Lethcsmy & Rajathi G, Ignisha & Rajamani, Vedhapriyavadhana. (2020). Crop Disease Detection and Monitoring System. *International Journal of Recent Technology and Engineering (IJRTE)*. 8. 3050-3053. 10.35940/ijrte.D7857.118419.
5. Ghafarian Malamiri, Hamid Reza & Arabi, Fahime & Shojaei, Saeed & Mortaz, Morad & S. Band, Shahab. (2021). A study on the use of UAV images to improve the separation accuracy of agricultural land areas. *Computers and Electronics in Agriculture*. 184.
6. Glazkov, T. & Golubev, Alexey. (2019). Using Simulink Support Package for Parrot Minidrones in nonlinear control education. *AIP Conference Proceedings*. 2195. 020007. 10.1063/1.5140107.
7. IPATE, George & Voicu, Gheorghe & Dinu, I.. (2015). Research on the use of drones in precision agriculture. 77. 263-274.
8. Hamid Reza Ghafarian Malamiri a,b, Fahime Arabi Aliabad c, Saeed Shojaei c,, Mortaz Morad d, Shahab S. Band A study on the use of UAV images to improve the separation accuracy of agricultural land areas *Computers and Electronics in Agriculture* 184 (2021) 106079
9. L. R. Priya, G. Ignisha Rajathi, R. Vedhapriyavadhana Crop Disease Detection and Monitoring System *International Journal of Recent Technology and Engineering (IJRTE)* ISSN: 2277-3878, Volume-8 Issue-4, November 2019 <https://doi.org/10.35940/ijrte.D7857.118419>
10. Alexey E. Golubev and Timur V. Glazkov Nonlinear Quadrotor Control Based on Simulink Support Package for Parrot Minidrones Nonlinear quadrotor control based on SSPPM 127 This work is supported by the Russian Foundation of Basic Research (projects 19-07-00817 and 20-07-00279).
11. George Ipate, Gheorghe Voicu, Ion Dinu, RESEARCH ON THE USE OF DRONES IN PRECISION AGRICULTURE *U.P.B. Sci. Bull., Series D, Vol. 77, Iss. 4, 2015* ISSN 1454-2358
12. Rahman, M.F.F.; Fan, S.;Zhang, Y.; Chen, L. A Comparative Study on Application of Unmanned Aerial Vehicle Systems in Agriculture. *Agriculture* 2021, 11, 22. <https://doi.org/10.3390/agriculture11010022>
13. Muhammad Usman, Quadcopter Modelling and Control with MATLAB/Simulink Implementation, 68 pages LAB University of Applied Sciences Technology Lappeenranta Mechanical Engineering and Production Technology Bachelor's Thesis 2019

14. "How to choose machine learning algorithms," Available: <https://docs.microsoft>
15. Elarab, Manal, "The Application of Unmanned Aerial Vehicle to Precision Agriculture: Chlorophyll, Nitrogen, and Evapotranspiration Estimation" (2016). *All Graduate Theses and Dissertations*. 4891. <https://digitalcommons.usu.edu/etd/4891>
16. Roger Lawes, Gonzalo Mata, Jonathan Richetti, Andrew Fletcher, Chris Herrmann, „Using remote sensing, process-based crop models, and machine learning to evaluate crop rotations across 20 million hectares in Western Australia” *Agronomy for Sustainable Development* (2022) 42:120 <https://doi.org/10.1007/s13593-022-00851-y>
17. Ahmed Mateen and Qingsheng Zhu” Weed Detection In Wheat Crop Using Uav For Precision agriculture *Pak. J. Agri. Sci., Vol. 56(3), 809-817; 2019 ISSN (Print) 0552-9034, ISSN (Online) 2076-0906 DOI: 10.21162/PAKJAS/19.8116* <http://www.pakjas.com.pk>
18. Rehman, A.; Saba, T.; Kashif, M.; Fati, S.M.; Bahaj, S.A.;Chaudhry, H. „A Revisit of Internet ofThings Technologies for Monitoring and Control Strategies in Smart Agriculture.” *Agronomy* 2022, 12, 127. <https://doi.org/10.3390/agronomy12010127>
19. Jakob Geipel” Implementation and Improvement of an Unmanned Aircraft System for Precision Farming Purposes” This thesis was accepted as a doctoral dissertation in fulfillment of the requirements for the degree of 'Doktor der Agrarwissenschaften' (Dr. sc. agr. / Ph.D. in Agricultural Sciences) by the Faculty of Agricultural Sciences at the University of Hohenheim on March 30, 2016. The colloquium took place on April 13, 2016
20. Wilbert G. Aguilar, Verónica P. Casaliglla, and José L. Pólit „Obstacle avoidance for low-cost UAVs” 2017 IEEE 11th International Conference on Semantic Computing.
21. C Y N Norasma, M Y Abu Sari, M A Fadzilah, M R Ismail, M H Omar, B Zulkarami, Y M M Hassim and Z Tarmidi” Rice crop monitoring using multirotor UAV and RGB digital camera at early stage of growth”, *IOP Conference Series: Earth and Environmental Science, Volume 169, 9th IGRSM International Conference and Exhibition on Geospatial & Remote Sensing (IGRSM 2018) 24–25 April 2018, Kuala Lumpur, Malaysia* IOP Conf. Series: Earth and Environmental Science 169 (2018) 012095 <https://doi.org/10.1088/1755-1315/169/1/012095/>
22. Lala El Hoummaidi, Abdelkader Larabi, Khan Alam „Using unmanned aerial systems and deep learning for agriculture mapping in Dubai” <https://doi.org/10.1016/j.heliyon.2021.e08154> Received 19 July 2021; received in revised form 8 September 2021; Accepted 7 October 2021
23. Emmanouil G. Fragkoulopoulos „Agricultural Robotics and Automation Robot Collaboration for Precision Agriculture” Institutional Repository - Library & Information Centre - University of Thessaly 15/09/2018 12:59:15 EEST - 193.230.241.122
24. Choi, Seok-Keun, Lee, Soung-Ki, Kang, Yeon-Bin · Seong, Seon-Kyeong · Choi, Do-Yeon · Kim, Gwang-Ho „ **Applicability of Image Classification Using Deep Learning in Small Area : Case of Agricultural Lands Using UAV Image** “ **Journal of Korean Society of Surveying** <https://doi.org/10.7848/ksgpc.2020.38.1.23>
25. Anthony Oliveira Pinto, Harrison Neves Marciano, Vinicius Pacheco Bacheti, Mauro Sergio Mafra Moreira, Alexandre Santos Brandão and Mario Sarcinelli-Filho” High-Level Modeling and Control of the Bebop 2 Micro Aerial Vehicle” 2020 International Conference on Unmanned Aircraft Systems (ICUAS) Athens, Greece. September 1-4, 2020

Authorized licensed use limited to: University College London. Downloaded on October 12, 2020 at 19:14:58 UTC from IEEE Xplore

26. Shyamal S. Virnodkar · Vinod K. Pachghare · V. C. Patil · Sunil Kumar Jha” Remote sensing and machine learning for crop water stress determination in various crops: a critical review” *Precision Agriculture* (2020) 21:1121–1155 <https://doi.org/10.1007/s11119-020-09711-9>

27. Inbal Becker-Reshefa, Christina Justicea, Brian Barkera, Michael Humbera, Felix Remboldb, Rogerio Bonifacioc, Mario Zappacostad, Mike Buddee, Tamuka Magadziref, Chris Shitotef, Jonathan Poundd, Alessandro Constantinod, Catherine Nakalembea, Kenneth Mwangig, Shinichi Sobueh, Terence ewbyi, Alyssa Whitcrafta, Ian Jarvisj, James Verdink „Strengthening agricultural decisions in countries at risk of food insecurity: The GEOGLAM Crop Monitor for Early Warning” *Remote Sensing of Environment* 237 (2020) 111553

28. Codeluppi, G.; Cilfone, A.; Davoli, L.; Ferrari, G. LoRaFarM: A LoRaWAN-Based Smart Farming Modular IoT Architecture Sensors 2020, 20, 2028. [CrossRef] [PubMed]

29. Popescu, D.; Stoican, F.; Stamatescu, G.; Ichim, L.; Dragana, C. Advanced UAV–WSN- System for Intelligent Monitoring in Precision Agriculture. *Sensors* 2020, 20, 817. [CrossRef]

30. Ratnakumari, K.; Koteswari, S. Design & implementation of innovative IoT based smart agriculture management system for efficient crop growth. *J. Eng. Sci.* 2020, 11, 607–616.

31. Castañeda-Miranda, A.; Castaño-Meneses, V.M. Internet of things for smart farming and frost intelligent control in greenhouses. *Comput. Electron. Agric.* 2020, 176, 105614. [CrossRef]

32. Tiglao, N.M.; Alipio, M.; Balanay, J.V.; Saldivar, E.; Tiston, J.L. Agrinex: A low-cost wireless mesh-based smart irrigation system. *Measurement* 2020, 161, 107874. [CrossRef]

33. Roy, S.K.; De, D. Genetic Algorithm based Internet of Precision Agricultural Things (IopaT) for Agriculture 4.0. *Internet Things* 2020, 100201. [CrossRef]

34. Jun Jiang, Mehrdad Moallem, Youbin Zheng ” An Intelligent IoT-enabled Lighting System for Energy-efficient Crop Production” *Journal of Daylighting* 8 (2021) 86-99 doi:10.15627/jd.2021.6

35. Ahmed Khattab, Serag E.D. Habib, Haythem Ismail, Sahar Zayan, Yasmine Fahmy, Mohamed M. Khairy „An IoT-based cognitive monitoring system for early plant disease forecast” <https://doi.org/10.1016/j.compag.2019.105028> Received 24 June 2019; Received in revised form 23 September 2019; Accepted 28 September 2019

36. N.L.M. Jeurgens „Identification and Control Implementation of an AR.Drone 2.0” Master’s Thesis DC 2017.013

37. John K. Schueller „Intensive Farming Systems: Efficiency and Innovation for Sustainability— The Case of North America” CLUB of BOLOGNA 25th Annual Meeting of the Club of Bologna November 15-16, 2014 Bologna – EIMA International 2014

38. Anna Triantafyllou , Panagiotis Sarigiannidis and Stamatia Bibi „Precision Agriculture: A Remote Sensing Monitoring System Architecture” *Information* 2019, 10, 348; doi:10.3390/info10110348 www.mdpi.com/journal/information

39. Kannan Nova „ AI-Enabled Water Management Systems: An Analysis of System components and Interdependencies for Water Conservation”

40. Jianxi Huang, Jose L. Gómez-Dans, Hai Huang, Hongyuan M, Qingling Wuf, Philip E. Lewis, Shunlin Liang, Zhongxin Chen, Jing-Hao Xue, Yantong Wu, Feng Zhao, Jing Wang, Xianhong Xie „Assimilation of remote sensing into crop growth models: Current status and Perspectives” *Agricultural and Forest Meteorology* 276–277 (2019) 107609 <https://doi.org/10.1016/j.agrformet.2019.06.008> Received 1 December 2018; Available online 01 July 2019
41. Katja Berger, Jochem Verrelst, Jean-Baptiste Féret, Zhihui Wang, Matthias Woche, Markus Strathmann, Martin Danner, Wolfram Mauser, Tobias Hank” Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions” <https://doi.org/10.1016/j.rse.2020.111758>
42. Monteiro, A.; Santos, S.; Gonçalves, P. „Precision Agriculture for Crop and Livestock Farming—Brief Review”. *Animals* 2021, 11, 2345. <https://doi.org/10.3390/ani11082345>
43. João R. S. Benevides, Roberto S. Inoue, Marlon A. D. Paiva and Marco H. Terra” ROS-Based Robust and Recursive Optimal Control of Commercial Quadrotors”
44. Khan S, Tufail M, Khan MT, Khan ZA, Iqbal J, Alam M (2021)” A novel semi-supervised framework for UAV based crop/weed classification.” *PLoS ONE* 16(5): e0251008. <https://doi.org/10.1371/journal.pone.0251008>
45. Dr. Kevin Price *Executive Vice President of Research & Technology Development, RoboFlight Systems, LLC* “ DRONES IN MODERN AGRICULTURE
46. Afshar, M.H.; Foster, T.; Higginbottom, T.P.; Parkes, B.; Hufkens, K.; Mansabdar, S.; Ceballos, F.; Kramer, B. “Improving the Performance of Index Insurance Using Crop Models and Phenological Monitoring”. *Remote Sens.* 2021, 13, 924. <https://doi.org/10.3390/rs13050924>
47. Kim Arild Steen “Pattern Recognition Methods for Reduction of Human-Wildlife Conflicts” A Dissertation Presented to the Faculty of Science and Technology of the University of Aarhus in Partial Fulfilment of the Requirements for the PhD Degree.
48. Leif Peder Hafsal “Master Thesis Precision Agriculture with Unmanned Aerial Vehicles for SMC estimations – Towards a more Sustainable Agriculture”
49. Thomas Moranduzzo “Detection And Analysis Methods For Unmanned Aerial Vehicle Images” International Doctorate School in Information and Communication Technologies Department of Information Engineering and Computer Science University of Trento
50. Marek Vajgl, Petr Hurtik, Petra Števíliáková “Drone real-time control based on pattern matching” Conference: Fuzzy Systems Association and 9th International Conference on Soft Computing and Intelligent Systems (IFSA-SCIS), 2017 Joint 17th World Congress of International DOI: [10.1109/IFSA-SCIS.2017.8023254](https://doi.org/10.1109/IFSA-SCIS.2017.8023254)
51. G. RONCHETTI, D. PAGLIARI, G. SONA “DTM GENERATION THROUGH UAV SURVEY WITH A FISHEYE CAMERA ON A VINEYARD” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-2, 2018 ISPRS TC II Mid-term Symposium “Towards Photogrammetry 2020”, 4–7 June 2018, Riva del Garda, Italy <https://doi.org/10.5194/isprs-archives-XLII-2-983-2018>

52. Chongyuan Zhang, Afef Marzougui, Sindhuja Sankaran " High-resolution satellite imagery applications in crop phenotyping: An Overview" <https://doi.org/10.1016/j.compag.2020.105584>
53. Dan Popescu , Florin Stoican , Grigore Stamatescu , Loretta Ichim and Cristian Dragana" Advanced UAV–WSN System for Intelligent Monitoring in Precision Agriculture" In Proceedings of the 10th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS 2019), Metz, France, 18–21 September 2019
54. Wilbert G. Aguilar, Vinicio S. Salcedo, David S. Sandoval^{2,3}, and Bryan Cobeña, Developing of a Video-Based Model for UAV Autonomous Navigation D.A.C. Barone et al. (Eds.): LAWCN 2017, CCIS 720, pp. 94–105, 2017. https://doi.org/10.1007/978-3-319-71011-2_8
55. Svitlana Kokhan, Oleg Drozdovskyi National University of Life and Environmental Science of Ukraine – Kyiv, Ukraine " GIS of crop monitoring remote sensing system" International Scientific Journal "Mechanization In Agriculture & Conserving Of The Resources" Web Issn 2603-3712; Print Issn 2603-3704
56. Geun-Ho Kwak and No-Wook Park " Impact of Texture Information on Crop Classification with Machine Learning and UAV Images" Department of Geoinformatic Engineering, Inha University, Incheon 22212, Korea Appl. Sci. 2019, 9, 643; <https://doi:10.3390/app9040643> www.mdpi.com/journal/applsci
57. Yuzhen Lu, Sierra Young "A survey of public datasets for computer vision tasks in precision agriculture" Computers and Electronics in Agriculture 178 (2020) 105760 <https://doi.org/10.1016/j.compag.2020.105760>
58. M'gharfaoui Ilyas" Implementation of An Image-Based Visual Servoing System on a Parrot Bebop 2 UAV" POLITECNICO DI TORINO CORSO DI LAUREA IN MECHATRONIC ENGINEERING
59. Thanh Tam Nguyen , Thanh Dat Hoang , Minh Tam Pham , Tuyet Trinh Vu , Thanh Hung Nguyen , Quyet-Thang Huynh , Jun Jo " Monitoring agriculture areas with satellite images and deep learning" <https://doi.org/10.1016/j.asoc.2020.106565>
60. Swagatam Bose Choudhury, Prachin Jain, Sujal Kallamkuth, Saranya Ramanath, Prakruti V. Bhatt, Sanat Sarangi and Srinivasu P. " Precision Crop Monitoring with Affordable IoT: Experiences with Okra" Authorized licensed use limited to: University of Petrosani. Downloaded on September 05,2023 at 10:04:23 UTC from IEEE Xplore.
61. Jo~ao R. S. Benevides , Roberto S. Inoue , Marlon A. D. Paiva , Marco H. Terra" Parameter Estimation Based on Linear Regression for Commercial Quadrotors" <https://DOI:10.17648/sbai-2019-111603>
62. Alaa Adel Araby, Mai Mohamed Abd Elhameed, Nada Mohamed Magdy, Loa'a Ahmed Said, Nada ,Abdelaal, Yomna Tarek Abd Allah, M. Saeed Darweesh, Mohamed Ali Fahim, H'assan Mostafa " Smart IoT Monitoring System for Agriculture with Predictive Analysis" 2019 8th International Conference on Modern Circuits and Systems Technologies (MOCASST) Authorized licensed use limited to: University of Petrosani. Downloaded on September 05,2023 at 09:59:05 UTC from IEEE Xplore

64. Philipp Lottes Raghav Khanna Johannes Pfeifer Roland Siegwart Cyrill Stachniss " UAV-Based Crop and Weed Classification for Smart Farming"
65. Almalki, F.A.; Soufiene, B.O.; Alsamhi, S.H.; Sakli, H. A Low-Cost Platform for Environmental Smart Farming Monitoring System Based on IoT and UAVs. *Sustainability* 2021, 13, 5908. <https://doi.org/10.3390/su13115908>
66. Xiaoyan Ma " Data Collection Of Mobile Sensor Networks By Drones" Doctorat De L'université De Toulouse, le lundi 6 novembre 2017.
67. Peter P. J. Roosjen " UAV-based multi-angular measurements for improved crop parameter retrieval" Thesis submitted in fulfilment of the requirements for the degree of doctor at Wageningen University.
68. Khush G Chandawat1, L Pavan Venkat, Prof Poornima K, Prof Priya D" Autonomous Drones using Reinforcement Learning" International Research Journal of Engineering and Technology (IRJET) e-ISSN: 2395-0056 Volume: 07 Issue: 07 | July 2020
69. Xin Hu, Xinyu Wang, Yanfei Zhong: WHU-Hi: UAV-borne hyperspectral and high spatial resolution (H2)benchmark datasets for crop precise classification " Copyright@RS-IDEA | Address: No.129 Luoyu Road,Wuhan,China. Room 308,No.3
70. Daniel Reynolds , Joshua Ball , Alan Bauer , Robert Davey ,Simon Griffiths and Ji Zhou " CropSight: a scalable and open-source information management system for distributed plant phenotyping and IoT-based crop management" doi: 10.1093/gigascience/giz009.
71. Erik Derner, Ji• Í Kubalík, And Robert Babu.Ka " Selecting Informative Data Samples for Model Learning Through Symbolic Regression" Received November 18, 2020, accepted December 14, 2020, date of publication January 18, 2021, date of current version January 26, 2021. *Digital Object Identifier 10.1109/ACCESS.2021.3052130*
72. Gabriela Calvario , Basilio Sierra , Teresa E. Alarcón , Carmen Hernandez and Oscar Dalmau " A Multi-Disciplinary Approach to Remote Sensing through Low-Cost UAVs" Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad del País Vasco , UPV/EHU, 20018 Donostia-San Sebastián, Spain
73. Mamadou Dian Bah, Adel Hafiane , And Raphael Canals " CRowNet: Deep Network for Crop Row Detection in UAV Images" Received October 21, 2019, accepted November 28, 2019, date of publication December 19, 2019, date of current version January 9, 2020. *Digital Object Identifier 10.1109/ACCESS.2019.2960873*
74. Ming Der Yang, Hsin Hung Tseng, Yu Chun Hsu, Wei Chen Tseng " Real-time Crop Classification Using Edge Computing and Deep Learning" 2020 IEEE 17th Annual Consumer Communications & Networking Conference (CCNC)
75. Chong Fan, Ru Lu " UAV image crop classification based on deep learning with spatial and spectral features" 2nd International Conference on Geology, Mapping and Remote Sensing IOP Conf. Series: Earth and Environmental Science 783 (2021) 012080 IOP Publishing doi:10.1088/1755- 1315/783/1/012080
76. Abdelmalek Bouguettaya, Hafed Zarzour, Ahmed Kechida, Amine Mohammed Taberkit " Deep learning techniques to classify agricultural crops through UAV imagery: a review" *Neural Computing and Applications* (2022) 34:9511–9536 <https://doi.org/10.1007/s00521-022-07104-9>

77. Rahman MFF, Fan S, Zhang Y, Chen L. A Comparative Study on Application of Unmanned Aerial Vehicle Systems in Agriculture. *Agriculture*. 2021; 11(1):22. <https://doi.org/10.3390/agriculture11010022>
78. Steffen Fritz, Linda See, Juan Carlos Laso Bayas, François Waldner, Damien Jacques, Inbal Becker-Reshef, Alyssa Whitcraft, Bettina Baruth, Rogerio Bonifacio, Jim Crutchfield, Felix Rembold, Oscar Rojas, Anne Schucknecht, Marijn Van der Velde, James Verdin, Bingfang Wu, Nana Yan, Liangzhi You, Sven Gilliams, Sander Mùcher, Robert Tetrault, Inian Moorthy, Ian McCallum, A comparison of global agricultural monitoring systems and current gaps, *Agricultural Systems*, Volume 168, 2019, Pages 258-272, ISSN 0308-521X, <https://doi.org/10.1016/j.agsy.2018.05.010>.
79. **Gamulescu Oliviu-Mihnea**, Marius-Nicolae Risteiu, Roxana –Gabriela Popa. *THE DRONES, A MODERN INNOVATION IMPACTTING AREAS OF THE SITE NATURA 2000 ROSCIO128 NORTH EASTERN GORJ*. Annals of 'Constantin Brancusi' University of Targu-Jiu. Juridical Science Series. 2016, Issue 3, p. 128-131.
80. **Gamulescu Oliviu Mihnea**, Rosca Sebastian Daniel, Leba Monica, Ionica Andreea, *Agricultural Land Management Using Drones*, 6th RMEE 2018 Performance Management or Management Performance, sept 20-22 2018, Cluj-Napoca, Romania, pag. 264-270
81. **Gamulescu Oliviu-Mihnea**; Rosca Sebastian-Daniel. *USE DRONE IN SURVEYING, AS A MODERN TECHNOLOGY IN ROMANIA*. Annals of Constantin Brancusi University of Targu-Jiu. Juridical Science Series, 2017
82. **Gamulescu, Oliviu-Mihnea**; Risteiu, Marius-Nicolae; Leba, Monica; *THE HARDWARE USED IN THE STRUCTURE OF DRONES*. Annals of 'Constantin Brancusi' University of Targu-Jiu. Engineering Series / Analele Universității Constantin Brâncuși din Târgu-Jiu. Seria Inginerie, 2016, Issue 4, p27
83. Rosca Sebastian, Leba Monica, Ionica Andreea and **Gamulescu Oliviu**, *Quadcopter control using a BCI*, ICAS Conference Hunedoara – 2017, (2018) In IOP Conference Series: Materials Science and Engineering (Vol. 294, No. 1, p. 012048
84. **Gamulescu, Oliviu-Mihnea**; Musetoiu, Oliviu Mihai, Leba Monica *ENVIRONMENTAL PROTECTION AND INTEGRATED MEASURES TO PREVENT SOIL EROSION AT THE FARM LEVEL SC. YLO-PROD SRL, VALCEA* Annals of the „Constantin Brancusi” University of Targu-Jiu, Engineering Series , No. 4/2017
85. **Gamulescu, Oliviu-Mihnea**; Musetoiu, Oliviu Mihai, Leba Monica *AGRICULTURAL LAND MANAGEMENT USING DRONES*, 6th RMEE 2018 Performance Management or Management Performance, sept 20-22 2018, Cluj-Napoca, Romania, pag. 264-270
86. Popa Roxana–Gabriela, **Gămulescu Oliviu –Mihnea**, *THE VITAMIN CONTENT OF FRUITS*, Annals of the „Constantin Brancusi” University of Targu-Jiu, Engineering Series, No. 4 /201
87. **Oliviu Mihnea Gamulescu**, Sebastian Daniel Rosca, Fabian Panaite, Alin Costandoiu, and Simona Riurean, *ACCIDENT SITES MANAGEMENT USING DRONES*, In MATEC Web of Conferences (Vol. 305, p. 00004). EDP Sciences, <https://doi.org/10.1051/mateconf/202030500004> 3456789.