

---

TEZĂ DE DOCTORAT

# Cercetări privind posibilitățile de folosire a dronelor pentru cartarea pajiștilor oligotrofe cu *Arnica montana* din Munții Apuseni

(REZUMAT AL TEZEI DE DOCTORAT)

---

Doctorand **Dragomir Dan Sângeorzan**

---

Conducător de doctorat **Prof.univ.dr. Ioan Rotar**

---



## I. Introducere

Într-o lume globalizată și interconectată, biodiversitatea este văzută ca un indicator al sănătății biosferei. Biodiversitatea nu este doar o varietate de specii, ci include și diversitatea genetică, a ecosistemelor, și culturală.

Colectarea și analiza datelor despre biodiversitate, ca parte a unui efort de management, depinde de organizare socială și politică, și depinde de tehnologie. De la observații de înaltă calitate realizate de cercetători, la scanări rapide realizate de senzori, tehnologia permite acumularea unei cantități mari de date. Aceste date pot fi apoi utilizate pentru a înțelege mai bine impactul activităților umane asupra biodiversității și pentru a informa politicile de conservare. În ecosistemele naturale și semi-naturale de suprafață, trebuie considerat impactului activităților umane cum ar fi fertilizarea și exploatarea intensivă asupra biodiversității.

Un management complex ar putea fi o soluție, dar pentru a integra conservarea biodiversității în management avem nevoie de informații cantitative și calitative despre ecosisteme pe care dorim să le conservăm.

## II. Folosirea dronelor în agricultură

### **Teledetecția, Măsurătorile Terestre, și Automatizarea.**

Teledetecția, alături de Măsurători Terestre, măsoară radiațiile emise sau reflectate de obiecte pentru a obține informații despre ele, iar tranziția de la geografie la biologie și ecologie este una revoluționară. Există două abordări principale de utilizare a teledetecției în acest sens:

Abordarea directă implică înregistrarea datelor la diferite niveluri, de la organisme individuale la comunități ecologice. Abordarea indirectă implică modelarea datelor împreună cu parametrii și indicatorii ecologici, transformând rezultatele în informații relevante pentru studiul biologiei, ecologiei și biodiversității.

Diferitele tehnologii sunt utilizate în teledetecție pentru automatizarea măsurătorilor și a observațiilor: Vectori Suport Mașină, algoritmi de Orientare la Obiect, algoritmi de analiză spectrală amestecată și altele. Astfel de tehnologii permit analiza și clasificarea datelor la diferite niveluri, de la pixeli individuali la segmente de pixeli mai uniforme. Tehnologiile de învățare automată joacă un rol din ce în ce mai serios în paradigma Agriculturii 4.0. Digitalizarea și automatizarea aceasta este bazată pe dezvoltarea de noi metode și algoritmi, ca rețelele neuronale convoluționale (CNN), folosind și aparatură din ce în ce mai performantă. Modelele CNN au devenit metoda dominantă pentru recunoașterea obiectelor dintr-o imagine sau video, ajungând să egaleze și chiar să depășească performanța umană în multe domenii, inclusiv în teledetecție.

### **Vehiculele aeriene fără pilot**

Vehiculele aeriene fără pilot sau „dronel” (termen folosit în continuare) au o

origine militară și continuă să fie importante în domeniul securității. Aceste vehicule vin în multe forme și mărimi, având design potrivit deseori pentru misiuni speciale.

În funcție de tipul de zbor, dronele pot fi cu aripi fixe, cu mai multe rotoare, sau hibride cu aripi fixe și cu rotoare. În funcție de procedura de aterizare și decolare, dronele pot necesita o pistă pentru a decola/ateriza, pot ateriza sau decola de pe loc, sau pot fi lansate cu o platformă scurtă de lansare și aterizează cu ajutorul unei parașute. În funcție de construcție, dronele pot fi clasificate după greutate și dimensiune sau după sursa de alimentare. În funcție de încărcătură, dronele civile pot fi folosite pentru transport de marfă, transport de senzori pentru măsurători terestre, sau fără încărcătură, de exemplu pentru divertisment și competiții.

Dronele militare sunt folosite în moduri noi și cu lanțuri de producție complexe și sub mare stres. În acest context, dronele sunt transformate în „bombe inteligente” chiar și cu auto-distrugere, datorită tehnologiei cu costuri reduse. Apărarea împotriva dronelor este un alt aspect al complexității tehnologice produsă de aceste sisteme. Exemple de combatere: distrugerea prin proiectil cinetic, distrugerea prin raze electromagnetice concentrate, imobilizarea prin aruncător de plase, distrugerea prin drone anti-dronă, bruiajul comunicării sau a senzorilor, și infiltrarea sistemului de comunicare și preluarea controlului asupra dronelor. ONU face eforturi pentru a forma convenții de reglementare și control a acestor arme, cu obiectivul de a interzice internațional armele complet autonome până în anul 2026.

#### **Dronele în Agricultură 4.0**

Dronele, echipate cu senzori pentru spectrul luminos (vizibil și învecinat), pot colecta imagini aeriene de înaltă rezoluție care ajută la monitorizarea solului și sănătății culturilor, la detectarea factorilor de stres și la optimizarea practicilor agricole prin colectarea și analiza precisă a datelor. Modelele CNN sunt utilizate pentru a analiza imaginile colectate de drone și pentru a face predicții despre recolte. De exemplu, ele pot detecta cu succes înălțimea culturii, pot estima randamentul culturilor de porumb, pot măsura cantitatea de inflorescențe la culturile de căpșuni, și pot fi utilizate pentru a estima recolta la culturile de rapiță și de bumbac.

Dronele pot fi utilizate pentru pulverizarea pesticidelor și îngrășămintelor pe terenurile agricole. Astfel se reduc costurile de combatere a dăunătorilor și crește eficiența managementului în comparație cu metodele convenționale. Imaginile aeriene pot ajuta la identificarea buruienilor cu o acuratețe ridicată, permițând fermierilor să aplice tratamente cu precizie. Dronele se pot utiliza chiar și pentru a monitoriza atacurile de rozătoare și pot ajuta la controlul rozătoarelor prin metode de agricultură de precizie, cum ar fi adăugarea de rodenticide în zone specifice.

Importanța dronelor în agricultura modernă devine din ce în ce mai mare și prezintă o serie de aplicații utile pentru bune practici agricole.

#### **Dronele în conservarea biodiversității**

Dronele sunt folosite în principal pentru teledetectie, oferind o alternativă

accesibilă la sateliții de măsurători terestre. Acestea pot umple o nișă importantă între măsurătorile terestre și evaluarea biodiversității. Studiile de caz din domeniu evidențiază o gamă largă de aplicații, de la cartarea zonelor forestiere și monitorizarea speciilor invazive, până la explorarea relațiilor dintre vegetație și morfologia dunelor sau identificarea arborilor bolnavi. În unele cazuri, dronele au fost folosite pentru a produce date de înaltă calitate despre structura verticală a pădurilor, pentru a analiza vegetația de stânci maritime sau pentru a detecta și măsura balene în ocean. În alte cazuri, au fost utilizate pentru a monitoriza proiecte de restaurare a pădurilor sau pentru a detecta arbuști invazivi. Există și drone folosite pentru reîmpădurire.

Tehnologia dronelor se arată a fi un instrument valoros în eforturile de conservare a biodiversității, permițând cercetătorilor să obțină informații detaliate și actualizate despre diverse ecosisteme și specii. Cu toate acestea, există și limitări, cum ar fi acoperirea mai mică comparativ cu sateliții sau dificultățile legate de clasificarea automată a imaginilor. În ciuda acestor provocări, potențialul dronelor în acest domeniu este semnificativ și continuă să crească odată cu dezvoltarea tehnologiei.

### **Teledetecția vegetației ierboase**

Studiile demonstrează potențialul tehnologiei dronelor și al învățării automate în monitorizarea și conservarea biodiversității. Dronele, prin capacitatea lor de a realiza teledetecție de înaltă rezoluție, permit cercetătorilor să obțină date detaliate despre diverse ecosisteme și specii. În plus, utilizarea algoritmilor de învățare automată, cum ar fi mașinile cu vector de suport (SVM) și rețelele neuronale convoluționale (CNN), facilitează procesarea și analiza acestor date, permițând identificarea și măsurarea speciilor de interes. Cu toate acestea, există provocări, cum ar fi necesitatea unei rezoluții înalte pentru detectarea speciilor de talie mică și dificultățile legate de clasificarea automată a imaginilor. Rezultatele studiilor sugerează că această abordare are un potențial mare în domeniul conservării biodiversității.

### **Utilizarea speciei *Arnica montana* L.**

*Arnica montana* este o plantă medicinală cu proprietăți terapeutice variate: antibacteriană, antitumorală, antioxidantă, antiinflamatorie, antifungică și imunomodulatoare. În ceea ce privește valoarea agronomică, *A. montana* poate fi cultivată ori recoltată în mod sustenabil – contribuind la conservarea biodiversității și a terenurilor cu înaltă valoare naturală (HNV).

Pajiștile oligotrofe în care crește *A. montana* sunt comunități complexe de plante și animale, cu o biodiversitate mare. Managementul acestor pajiști implică un echilibru între conservarea biodiversității și producția agricolă. Cosirea tradițională sau cosirea de două ori pe an sunt recomandate pentru conservarea *A. montana*. Amenințările la adresa conservării *A. montana* în pajiștile semi-naturale includ schimbările climatice, intensificarea agriculturii, abandonul, și pierderea habitatului.

*A. montana* este o specie valoroasă atât din punct de vedere medicinal, cât și agronomic. Conservarea și utilizarea durabilă a acestei specii reprezintă un caz exemplar al eforturilor internaționale de conservare a biodiversității.

### III. Obiectivele și metodele cercetării

Obiectivele cercetării duc spre o soluție pentru monitorizarea pajiștilor oligotrofe din Munții Apuseni prin folosirea dronelor și prin numărarea automată a inflorescențelor de *A. montana* în imaginile aeriene. Obiectivele principale:

- I. identificarea unei metodologii de studiu al biodiversității cu ajutorul dronelor;
- II. crearea unui soft pentru identificarea inflorescențelor de *Arnica montana* în imagini digitale aeriene.
- III. explorarea posibilităților de folosire a dronelor pentru cartarea pajiștilor oligotrofe cu *A. montana* din Munții Apuseni.

Obiectivele specifice sunt: efectuarea de zboruri cu drone într-o pajiște oligotrofă din Germania pentru a obține imagini din dronă în vederea antrenării unui model CNN; formarea unui model CNN robust pentru numărarea inflorescențelor; efectuarea de zboruri cu drone în mai multe pajiști oligotrofe din România pentru a obține imagini în vederea evaluării performanței modelului propriu; construirea unor aplicații anexe pentru folosirea modelului CNN in situ.

#### Metodele și tehnica

Pentru obținerea de imagini aeriene au fost folosite două drone: model „DJI S1000” în Germania și model „DJI M300” în România. Ambele drone sunt asemănătoare ca performanță. Dronele au purtat camere foto asemănătoare ca performanță, din fiecare zbor rezultând sute de imagini de înaltă rezoluție. Patru zboruri au avut loc în Pădurea Neagră, Todtnau, Germania (2018), producând imagini pentru efortul de antrenare a unui nou model CNN. Nouă zboruri au avut loc în Munții Apuseni, Ghețari, România (2021), producând imaginile pentru evaluarea sistemului software. Imaginile au fost eșantionate aleatoriu. Pentru antrenarea modelului CNN de numărare a inflorescențelor au fost etichetate imagini cu *A. montana* folosind mai multe tipuri de etichete ce au fost definite pentru a încerca să cuprindă cazurile posibile după grupare a inflorescențelor și după claritate, toate la rezoluție mică. Pentru prototip, au fost incluse doar inflorescențe individuale clare (AM1), inflorescențe individuale neclare (BAM1) și inflorescențe binare neclare (BAM2). A fost format un model dedicat pentru detectarea inflorescențelor *A. montana*, urmărind documentația convențională și folosind: limbajul Python, aplicații scrise special, platforma TensorFlow2, modelul de bază CNN ResNet101, și etichetele definite manual.

Modelul produs, numit „ArnicaAI”, a fost evaluat pe imagini aeriene produse în Ghețari. Rezultatele au fost colectate, investigate, și analizate statistic. Factorii cheie de zbor, valoarea GSD și ora zborului (exprimată ca lungimea umbrei produsă de lumina solară), au fost integrați în analiza statistică pentru a determina limite tehnologice de performanță (bune practici) în ceea ce privește planificarea zborurilor peste pajiști. Acoperirea cât mai mare prin survolare necesită găsirea unui echilibru între altitudinea

la care se zboară și calitatea detaliilor floristice din imaginile produse cu dronele.


## IV. Rezultate și discuții

### Software


În acest studiu a fost asamblată o suită software pentru a gestiona, procesa, și evalua imaginile aeriene. Suita software a inclus programe de suport ca cele pentru organizarea colecțiilor de imagini și cele pentru compunerea aplicațiilor. Pentru divizarea imaginilor în vederea antrenării, a fost creată o aplicație ce fragmentează eficient imaginile mari în imagini mici, adecvate pentru folosirea cu modelul (CNN) ResNet101. Antrenarea modelului s-a realizat prin platforma TensorFlow2 cu o configurație minim personalizată. Pentru testarea in situ au fost create două aplicații: una care folosește modelul (ArnicaAI) și una care ajută la raportarea rezultatelor.

### Etichete și învățare automată

Efortul de etichetare a produs un total de 23.680 etichete pentru învățare automată (antrenarea modelului). Majoritatea au fost pentru BAM1, urmate de AM1 și BAM2. Majoritatea etichetelor pentru inflorescențe individuale au avut rezoluție mică, sub  $33 \times 33$  px. Modelul a fost antrenat cu succes (Figura 1), atingând o rată de învățare de 0 și prezentând indicatori interni de auto-testare cu o viteză bună.



**Figura 1** Rata de învățare a modelului (ResNet101) ArnicaAI în 50000 de pași (epoci).



**Figura 2** Detecții adevărat pozitive.

### Detecție și evaluare

În rezultatele produse de ArnicaAI s-au observat mai multe cazuri de suprapunere a casetelor ce marchează inflorescențele detectate. Acest tip de rezultat este datorat configurației „din fabrică” a modelului, în special la reglarea filtrelor din aspectul numit „supresiune non-maximală”. Prin ajustarea configurației se pot face potriviri mai strânse și mai exacte a casetelor pe inflorescențele de *A. montana*. Detecțiile sugerează că

modelul se concentrează pe florile ligulate unde există cel mai mult detaliu la rezoluție mică. Această specializare poate să fie și rezultatul supra-învățării prin faptul că modelul a folosit etichetele neclare drept contra-exemple. În ansamblu, modelul ArnicaAI găsește inflorescențe AM1 în mai multe situații diferite, inclusiv unde este rezoluția mică și unde avem ocluzii de la alte plante. ArnicaAI are un prag de scor redus pentru a raporta cât mai multe detecții de *A. montana*, chiar dacă multe sunt greșite (scade precizia), astfel încât să putem observa limitele.

**Tabel 1.**

*Evaluarea ArnicaAI per zbor. MPZ – media precizie zborului.*

Zborul	Altitudine (m)	Umbră (CM)	GSD (CM)	Imagini	Detecții	MPZ (%)
JUN1	20	16	0,21	65	1570	51,23
JUN2	40	15	0,42	63	1648	49,05
JUN3	18	14	0,19	59	1450	44,92
JUN4	18	13	0,19	104	1470	51,62
JUN5	30	13	0,31	40	265	45,75
JUN6	60	30	0,65	68	911	16,03
JUL1	60	51	0,73	26	65	10,00
JUL2	40	56	0,49	37	111	10,54
JUL3	30	59	0,37	40	237	12,75

Din fiecare imagine evaluată rezultă o valoare pentru precizie (cazuri adevărat pozitive din totalul de detecții, ca procent), iar pentru fiecare zbor s-a calculat media acestor valori: Media Preciziei Zborului (Tabel 1). Modelul poate fi ajustat pentru a crește precizia, dar aceasta trebuie să fie o decizie în cadrul planului de management. Modelul prezintă o performanță de precizie care variază între 10% și 52%, cu o medie de succes de 32%. Prin urmare, utilizarea modelului pe teren implică utilizarea coeficienților de corecție pentru obține o estimare realistă.

GSD, ca scară a detaliului din imagine, este un factor cheie în succesul teledetecției și a identificării manuale de specii din imagini aeriene. Pentru identificarea automată a inflorescențelor, valoarea GSD este la fel de importantă ca pentru identificarea manuală. Un alt factor important este ora la care s-a efectuat zborul, data și locația, deoarece acestea determină umbrele produse de lumina soarelui, iar umbrele distorsionează imaginile.

**Tabel 2.**

*Statistici descriptive pentru evaluarea rezultatelor ArnicaAI*

Variabilă	n	Media	Eroarea Standard	Min.	Max.
<b>Analiza 1: între mediile celor 9 zboruri</b>					
Precizie (%)	9	32,43	19,27	10,00	51,61
GSD (cm)	9	0,40	0,20	0,19	0,73
Umbră (cm)	9	29,67	20,04	13,00	59,00
<b>Analiza 2: între toate imaginile evaluate</b>					
Precizie (%)	503	36,92	31,10	10,00	100,00
GSD (cm)	503	0,64	0,33	0,45	1,34
Umbră (cm)	503	23,90	16,83	13,00	59,00

Pentru a determina coeficienții de corecție s-a realizat o analiză statistică pe rezultate în două etape: întâi au fost analizate rezultatele în funcție de zbor, apoi au fost analizate rezultatele combinate într-un singur set cu toate imaginile evaluate din toate aceste zboruri, un set de 503 imagini (Tabel 2).

Pentru rezultatele între zboruri o analiză statistică ar avea rol exploratoriu, fiind doar 9 zboruri. Pentru setul întregit de rezultate s-au aplicat mai multe teste statistice, începând cu testul pentru coeficientul de corelație Pearson (Tabel 3).

**Tabel 3**

*Corelații între cele 3 variabile.*

*r - coeficientul de corelație Pearson, p - probabilitate, E.S. - eroare standard*

<b>Pereche de variabile</b>	<b>r</b>	<b>p</b>	<b>Efect</b>	<b>E.S. efect</b>
Precizie (%) - GSD (cm)	<b>-0,449 ***</b>	<0,001	-0,483	0,045
Precizie (%) - Umbră (cm)	<b>-0,258 ***</b>	<0,001	-0,263	0,045
Umbră (cm) - GSD (cm)	<b>0,237 ***</b>	<0,001	0,241	0,045

\*\*\*  $p < 0,001$

Corelațiile dintre cele 3 variabile indică relații semnificative statistic, cu un efect negativ al GSD asupra preciziei, și un efect ușor negativ al umbrei asupra preciziei. Pentru a formula un model statistic, între cele trei variabile, o ipoteză nulă ( $H_0$ ) a inclus cele două variabile independente astfel:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

Modelul statistic are forma: Y - variabila dependentă (Precizie);  $\beta_0$  - valoarea de interceptare (Precizie);  $\beta_1$  - coeficient GSD;  $X_1$  - variabila independentă GSD;  $\beta_2$  - coeficient Umbră;  $X_2$  - variabila independentă Umbră.

Coeficientul de determinare ( $R^2$ ) pentru acest model statistic este 0.226, cu o valoare semnificativă statistic ( $p < 0,001$ ). Rezultatul arată că 22.6% din variația Preciziei este explicată de modelul statistic.

Testul ANOVA confirmă ipoteza nulă cu GSD și Umbră ca model semnificativ statistic ( $p < 0,001$ ) și 2 grade de libertate.

Ultimul test statistic a fost o regresie liniară care a produs următorii coeficienți:

$$Precizia_{\%} = 69,173 - 39,283 \times GSD_{cm} - 0,296 \times Umbră_{cm}$$

Modelul regresiei liniare are o valoare de interceptare a preciziei de 69,173 cu o eroare standard de 2,959, și este semnificativă statistic ( $p < 0,001$ ). Valoarea aceasta de aproximativ 70% reprezintă precizia maximă realizată cu **ArnicaAI** în condițiile optime de zbor conform experiențelor de evaluare din Ghețari. Valoarea GSD (cm), distanța de eșantionare la sol, are un coeficient de -39,283 cu o eroare standard 3,874 și un coeficient standardizat de -0,411, formând o relație negativă cu Precizia (variabila dependentă). Valoarea testului  $t$  este -10,140 și este semnificativă statistic ( $p < 0,001$ ).

Coeficientul umbrei (cm) este de -0,296 cu o eroare standard de 0,075 și un



coeficient standardizat de -0,160, indicând un efect negativ ușor asupra Preciziei. Valoarea testului  $t$  este -3,956 și este semnificativă statistic ( $p < 0,001$ ). Corelația cu lungimea umbrei confirmă importanța variației în imaginile de la antrenarea modelului CNN, astfel că, pe lângă transferul învățării de la imagini cu populația de *A. montana* din Pădurea Neagră la populația din Ghețari, s-a transferat și limitarea orară.

Coefficienții modelului statistic permit estimarea detecțiilor dacă se cunosc parametrii de zbor GSD și umbră, iar aceste calcule se pot îmbunătăți cu date empirice prin folosirea sistemului și validarea manuală, incluzând chiar și alte variabile precum eterogenitatea reliefului cuprins în imaginile aeriene (mai mare înseamnă mai multe porțiuni neclare în imagini).

Rezultatul corelației cu GSD confirmă importanța imaginilor cu distanță de eșantionare mică și prezintă o limită a valorii GSD de maxim 0,45 cm pentru a obține precizie bună cu modelul ArnicaAI.

Dat fiind faptul că zborurile pentru imagini de antrenament au avut loc într-un interval mai scurt, între dimineață și prânz, cu umbre de lungime în intervalul 17-25 cm, putem observa o pierdere abruptă de performanță la evaluare pentru imaginile cu umbre mai mari de 25 cm. Aceasta ne indică orele mai potrivite pentru zbor.

Rezultatele studiului sunt pozitive, dar limitate, și sunt în concordanță cu eforturile recente similare care utilizează rețele neuronale convoluționale (CNN) pentru a detecta specii ierboase. Rezoluția scăzută a plantelor limitează performanța și vegetația suprapusă crește erorile.

Pentru *A. montana*, antrenamentul a fost concentrat pe fenofaza de înflorire, ceea ce a ușurat efortul. Studiul confirmă constatările metodologice ale altor cercetări care au utilizat o suită tehnologică similară pentru a detecta inflorescențele de la mai multe specii. Aceste studii au constatat că inflorescențele mai mari sunt mai ușor de detectat și că există dificultăți care apar din cauza inflorescențelor în grup care se suprapun. Această provocare ar putea fi rezolvată în viitor cu seturile de etichete de grup (AM2-5, AMN) pentru a evita confuzia și pentru a număra grupuri de „bucete” ce pot fi agregate, ulterior, într-un total mai reprezentativ pentru situația reală din pajiște.

## V. Concluzii și Recomandări

În cadrul tezei de doctorat a fost dezvoltată o suită software specializată pentru procesarea și analiza imaginilor aeriene din drone. Soluția este adaptată pajiștilor oligotrofe cu *Arnica montana* din Munții Apuseni și Pădurea Neagră. Prin integrarea algoritmilor avansați, producerea, etichetarea și evaluarea imaginilor a fost simplificată sau automatizată, facilitând astfel cartarea pajiștilor. Au fost implementați algoritmi de învățare automată, cu antrenare pe un set de date cuprinzător. Utilizarea suitei software a redus semnificativ timpul necesar pentru procesarea și analiza imaginilor, oferind rezultate funcționale, calitative, și promițătoare (Obiective principale: 1 și 2.)

Înălțimea de zbor și valoarea GSD au un impact semnificativ asupra calității imaginilor obținute în studiile de biodiversitate bazate pe teledetecție automată. Zborurile la altitudini joase oferă o rezoluție mai bună, dar necesită o planificare atentă pentru a obține imagini clare. Înălțimile de zbor prea mici pot duce la imagini cu un nivel ridicat de detaliu, dar pot fi afectate de umbre, denivelări și ocluzii. În contrast, înălțimile de zbor prea mari pot duce la detalii floristice cu o rezoluție mai mică, ceea ce poate face dificilă identificarea speciilor de plante și a altor caracteristici ecologice (Obiective principale: 1 și 3.)

Momentul zborului are, de asemenea, un impact semnificativ asupra calității imaginilor. Zborurile efectuate în timpul zilei, când soarele este la zenit, produc cele mai bune rezultate. În schimb, zborurile efectuate dimineața devreme sau după-amiaza târziu, când soarele este la un unghi mai mic, pot produce imagini cu umbre lungi și detalii nefamiliare modelului antrenat.

O planificare atentă a zborurilor și o înțelegere aprofundată a factorilor care influențează calitatea imaginilor sunt esențiale pentru obținerea unor rezultate de înaltă calitate (Obiective principale: 1 și 3.)

Claritatea imaginilor este esențială pentru identificarea corectă a speciilor și a caracteristicilor de interes în studiile de biodiversitate bazate pe teledetecție. Imaginile clare, cu un nivel ridicat de detaliu, permit o identificare mai precisă a speciilor de plante și a altor caracteristici ecologice, permițând o analiză mai detaliată a structurii habitatului și a altor aspecte ale ecosistemului. În contrast, imaginile neclare sau afectate de condiții meteo nefavorabile pot duce la erori în identificarea speciilor și în analiza biodiversității, deoarece umbrele lungi sau lumina slabă pot face dificilă distingerea între diferite specii de plante sau pot ascunde detalii importante despre structura habitatului.

Obținerea unor imagini clare și de înaltă calitate este esențială pentru conservarea biodiversității. Prin optimizarea condițiilor de zbor și a proceselor de procesare a imaginilor, se pot obține imagini de înaltă calitate care permit o analiză detaliată și precisă a speciilor de interes. Acest lucru demonstrează importanța unei planificări și implementări atente a studiilor de biodiversitate bazate pe teledetecție.

Recomandarea principală este să se continue și să se extindă utilizarea dronelor pentru cartarea ecosistemelor cu *A. montana*, implicând planificarea și efectuarea zborurilor în mod sistematic, acoperind pajiștile monitorizate. Modelul ArnicaAI poate să fie actualizat cu imagini ce provin din zboruri de la răsărit până la apus în sezonul înfloririi *A. montana*. Se poate explora utilizarea altor modele CNN și folosirea unei configurații de antrenare mai bine adaptată nevoilor. Este importantă continuarea îmbunătățirii modelelor CNN pentru numărarea inflorescențelor de *A. montana* folosind imagini mai variate și configurații mai potrivite. Este importantă validarea și calibrarea datelor colectate prin zborurile cu drone, folosind pajiști de testare, compararea datelor cu măsurători de la sol și ajustarea coeficienților de corecție.