
Proiect Experimental Demonstrativ
“Platformă robotică de precizie pentru agricultura eficientă” (PROTECT-Agri)

Nr. Contract 113PED/2025

RAPORTUL ȘTIINȚIFIC ȘI TEHNIC
(RST)

“ Cerințe, cazuri de utilizare și arhitectura sistemului. Module de detecție.”

Termen:	Decembrie 2025
Perioada	iunie – decembrie 2025
Autori/Participanți:	UNSTPB, BEAM
Etapa I Activități	<p>I. Cerințe cazuri de utilizare și arhitectura sistemului. Module de detecție</p> <ol style="list-style-type: none">1. Definierea cazurilor de utilizare în seră (cerințe funcționale și tehnice). Identificarea nevoilor de bază și a celor pentru creșterea productivității fermelor. Colectarea, analiza, clasificarea și prioritizarea într-o manieră agilă ce permite captarea și selectarea necesităților prin diferite iterații.2. Proiectare arhitectură de referință PROTECT-Agri pe baza cerințelor tehnice.3. Recunoaștere bazată pe imagini (Vision based Recognition) pentru caracterizarea fiecărei plante și reidentificarea fiecăreia în mod individual în timpul sesiunilor de testări succesive.4. Analize multispectrale: dezvoltare algoritmi de analiză automată a imaginilor multispectrale și generarea de interpretări relevante din datele colectate de la platforma robotică terestră.5. Dezvoltare platformă de detecție a solului atașată direct la platforma robotică de la sol. Probele de sol vor fi colectate de platformă cu o anumită frecvență de prelevare și pe baza unui model prestabilit.
Natura:	Raport de etapă

© Copyright Consorțiul PROTECT-Agri, 2025

1	INTRODUCERE	4
	1.1 Obiectivele proiectului	4
	1.2 Obiectivele etapei curente	4
	1.3 Rezumat	4
2	CONTEXTUL ACTUAL AL AGRICULTURII DE PRECIZIE ÎN SERE	5
	2.1 Agricultură în sere: generalități	5
	2.2 Metodologie agricultură eficientă în sere	5
	2.3 Cazuri de utilizare	7
	2.4 Cerințe și cazuri de utilizare pentru platforma PROTECT-Agri	8
	2.4.1 Definirea cazurilor de utilizare în seră (cerințe funcționale și tehnice)	8
	2.4.2 Identificarea nevoilor de bază și a celor pentru creșterea productivității fermelor	9
	2.4.3 Colectarea, analiza, clasificarea și prioritizarea într-o manieră agilă	9
	2.5 Proiectare arhitectură de referință PROTECT-Agri pe baza cerințelor tehnice	9
	2.5.1 Scop	9
	2.5.2 Componente de bază	10
	2.5.3 Tehnologii de interconectare/comunicații	10
	2.6 Analiza multispectrală a culturilor de seră	11
	2.6.1 Metode de recunoaștere a plantelor bazate pe imagini (Vision based Recognition)	11
	2.6.2 Analize multispectrale în cadrul proiectului PROTECT-Agri	13
3	DEZVOLTAREA MODULULUI DE DETECȚIE A SOLULUI DIN CADRUL PROTECT-AGRI	15
4	CONCLUZII	18
5	DISEMINARE	19

1 Introducere

1.1 *Obiectivele proiectului*

În cadrul proiectului “Platformă robotică de precizie pentru agricultura eficientă” (PROTECT-Agri), va fi proiectată, implementată și evaluată o platformă robotică terestră autonomă, multifuncțională, capabilă să efectueze măsurători la nivel individual de plantă. Cu informații extrem de precise la nivel individual de plantă, fermierii vor putea răspunde la fluctuațiilor factorilor de creștere într-un mod mai prompt și mai informat. Planul unei sere nu se modifică în timp, așadar va fi creată și testată o soluție completă specială pentru sere. Platforma robotică terestră va încorpora metode *computer vision* pentru recunoașterea vizuală a plantelor, detecția solului și analiza multispectrală a plantelor pentru analiza sănătății plantelor. Fiecare cultură este înregistrată spațial la prima etapă de analiză robotică, atribuindu-i-se un ID de cultură. ID-urile individuale ale culturilor sunt identificate în timpul sesiunilor de analize consecutive prin potrivire vizuală, permițând generarea de înregistrări istorice pentru fiecare plantă în parte. Beneficiarii vor vizualiza rezultatele măsurătorilor robotizate prin intermediul unei platforme digitale care combină informații de la mai multe componente robotice și de la dispozitivele Internet of Things (IoT) deja existente, încorporate în sere.

1.2 *Obiectivele etapei curente*

Prezentul raport include aspecte legate de primele cinci activități ale etapei I a proiectului, în care se urmăresc:

- Identificarea cazurilor de utilizare în seră (cerințe funcționale și tehnice) în vederea selectării metodelor cele mai potrivite pentru colectarea, analiza și clasificarea culturilor. Scopul final este de a răspunde unor nevoilor de bază și de creștere a productivității fermelor.
- Proiectarea preliminară a arhitecturii platformei robotice PROTECT-Agri;
- Analiza celor mai eficiente metode de recunoaștere a plantelor bazate pe imagini prin tehnici *computer vision* în vederea caracterizării plantelor în mod individual, precum și pentru dezvoltarea de algoritmi de analiză automată a imaginilor multispectrale și generare a unor interpretări relevante din datele colectate de la platforma robotică terestră.

1.3 *Rezumat*

Tabelul 1 - Activitățile derulate în Etapa I a proiectului

Activități	Responsabil activitate
A1.1. Definierea cazurilor de utilizare în seră (cerințe funcționale și tehnice). Identificarea nevoilor de bază și a celor pentru creșterea productivității fermelor. Colectarea, analiza, clasificarea și prioritizarea într-o manieră agilă ce permite captarea și selectarea necesităților prin diferite iterații.	CO (UNSTPB), BEAM
A1.2 Proiectare arhitectură de referință PROTECT-Agri pe baza cerințelor tehnice.	CO (UNSTPB), BEAM
A1.3 Recunoaștere bazată pe imagini (Vision based Recognition) pentru caracterizarea fiecărei plante și reidentificarea fiecăreia în mod individual în timpul sesiunilor de testări succesive	CO (UNSTPB)
A1.4 Analize multispectrale: dezvoltare algoritmi de analiză automată a imaginilor multispectrale și generarea de interpretări relevante din datele colectate de la platforma robotică terestră	CO (UNSTPB)
A1.5 Dezvoltare platformă de detecție a solului atașată direct la platforma robotică de la sol. Probele de sol vor fi colectate de platformă cu o anumită frecvență de prelevare și pe baza unui model prestabilit.	CO (UNSTPB), BEAM

2 Contextul actual al agriculturii de precizie în sere

2.1 Agricultura în sere: generalități

Agricultura de precizie în sere combină tehnologiile digitale, senzorii inteligenți, automatizarea și analiza de date pentru a optimiza producția agricolă în medii controlate. Această abordare răspunde provocărilor actuale legate de creșterea populației globale, schimbările climatice și necesitatea utilizării eficiente a resurselor naturale [1].

Prin integrarea conceptelor de Internet of Things (IoT) și inteligență artificială (IA), sistemele moderne de seră pot monitoriza și ajusta în timp real condițiile interne — precum temperatura, umiditatea, nivelul de CO₂ și lumina — pentru a asigura un microclimat optim [2]. În plus, digitalizarea agriculturii este susținută și la nivel european, fiind un pilon central al Strategiei UE pentru agricultură durabilă și digitalizare rurală [3].

Adoptarea agriculturii de precizie în sere este determinată de mai mulți factori cheie printre care [4]:

- Eficiența utilizării resurselor, prin reducerea consumului de apă și fertilizanți;
- Sustenabilitatea producției, prin reducerea poluării și a pierderilor de nutrienți;
- Productivitatea ridicată, datorată controlului exact al condițiilor de creștere;
- Calitatea superioară a produselor, cu parametri uniformi și valoare nutritivă crescută;
- Trasabilitatea și digitalizarea procesului de producție, prin colectarea și analiza datelor.

Tipurile de culturi întâlnite în sere variază în funcție de tehnologia serei și de cerințele pieței. Cele mai frecvente sunt:

- Legume: roșii, ardei, castraveți, salată, vinete, dovlecei;
- Plante aromatice și medicinale: busuioc, mentă, coriandru, cimbru, lavandă;
- Fructe de nișă: căpșuni, zmeură, afine și fructe exotice în sere climatizate;

Agricultura de precizie în sere permite reglarea optimă a mediului, economii de apă și fertilizanți, creșterea randamentului cu 30–50%, monitorizare automatizată prin senzori IoT și IA, reducerea impactului ecologic și obținerea de produse uniforme și trasabile [2],[4]. Acest tip de agricultură este promițător, dar implică costuri ridicate, complexitate tehnică și interdisciplinară, consum energetic mare și riscuri legate de defecțiuni sau incompatibilități între echipamente [2].

2.2 Metodologii eficiente pentru agricultura în seră

Agricultura de seră modernă integrează o varietate de dispozitive care asigură monitorizarea, controlul și întreținerea plantelor în medii controlate. Dispozitivele sunt de obicei clasificate în următoarele trei categorii: platforme robotice, senzori și actuatori, dispozitive de control.

● **Platformele robotice autonome** colectează și procesează date despre plante și mediu, utilizând senzori pentru observații precise din multiple unghiuri, sprijinind automatizarea proceselor agricole și reducerea intervenției umane. Principalele tipuri de platforme robotice utilizate în sere, conform [5]-[9], sunt:

○ Platformele robotice mobile terestre UGV (Unmanned Ground Vehicles) pot naviga autonom pe roți în interiorul serelor ori pe teren deschis, fiind utilizate pentru monitorizarea și analiza culturilor sau pentru măsurători.

○ Platformele robotice cu brațe manipulatorii sunt utilizate pentru sarcini de precizie (tăiere, cules, prinderea fructelor, inspecție de aproape).

○ Sistemele robotice pe șine sunt platforme care se deplasează pe șine deasupra culturilor pentru plantare, monitorizare și recoltare.

○ Dronele UAV (Unmanned Aerial Vehicle) sunt folosite pentru inspecții din aer și cartografiere locală, în special pentru culturi cu plante înalte.

● **Senzorii** detectează variațiile parametrilor fizici ai mediului, prelucrează și transmit informațiile. Aceștia includ: senzori optici pentru analiză vizuală (RGB, multispectrale/hiperspectrale, RGB-D, fluorometrie), senzori de distanță și geometrie (LiDAR, TOF), senzori de mediu (temperatură, umiditate, lumină, termici, PAR) și senzori de sol (umiditate, conductivitate electrică) [10].

● **Actuatorii** sunt dispozitive prin care un sistem de control acționează asupra mediului înconjurător. Printre actuatorii cei mai utilizați în serele moderne se pot număra sistemele de iluminat LED ajustabile, sisteme de irigare automatizate, supape pentru ventilație, motoare BLDC (Brushless DC motors) [10].

Principalele metode de analiză a plantelor/culturilor

Diferitele tipuri de senzori integrate pe platforme robotice determină principalele metode de analiză a culturilor de plante. Uzual, metodele prezentate sunt corelate pentru o analiză completă a sănătății plantelor.

● **Camerele multispectrale** sunt sisteme optice capabile să capteze imagini în mai multe benzi spectrale distincte, uzual domeniul vizibil RGB, cu lungimea de undă între 380-780 nm [11] și în domeniul NIR (Near-Infrared), cu lungimea de undă între 1100–2500 nm [12]. Sunt utilizate pentru monitorizarea vizuală a stării generale culturilor prin analiza proprietăților optice ale frunzelor plantelor, permițând estimarea unor parametri biofizici precum conținutul de clorofilă, apă sau azot [5],[6],[13].

● **Camerele hiperspectrale** reprezintă o tehnologie avansată de imagistică spectrală, capabilă să înregistreze informații dintr-un spectru continuu de lungimi de undă, de obicei între 400 și 2500 nm [14]. Spre deosebire de camerele multispectrale, care operează în câteva benzi discrete, sistemele hiperspectrale captează sute de benzi înguste, oferind o amprentă spectrală detaliată a fiecărui pixel din imagine. Sunt utilizate pentru calculul indicilor vegetativi: NDVI (Normalized Difference Vegetation Index), GNDVI (Green Normalized Difference Vegetation Index), PRI (Photochemical Reflectance Index) [5].

● **Camere RGB-D (Red-Green-Blue + Depth)**: utilizate pentru reconstituirea 3D și pentru estimarea caracteristicilor geometrice (înălțime, volum, suprafață foliară, indice de umbrire). Aceste camere combină imaginea color convențională cu o hartă de adâncime obținută prin senzori activi TOF (Time of Flight) [5], [6], [8].

● **LiDAR (Light Detection and Ranging)**: tehnologie de măsurare activă care folosește impulsuri laser pentru a calcula distanța până la obiecte, generând modele tridimensionale precise ale mediului. Este utilizată pentru reconstituirea 3D a plantelor, estimarea biomasei, măsurarea înălțimii culturilor și navigația autonomă a roboților. Avantajele sale sunt acuratețea ridicată și independența față de iluminarea naturală [8],[9].

● **Termografia infraroșu IRT (Infrared thermography)**: metodă de măsurare a temperaturii suprafeței bazată pe detecția radiației termice emise de plante (utilă pentru a evalua uniformitatea irigației, identifica zonele de stres și optimiza consumul de apă [6],[7].

● **Senzorii PAR (Photosynthetically Active Radiation)** măsoară radiația disponibilă pentru fotosinteză, din intervalul spectral al radiației solare cu lungimea de undă între 400-700 nm utilizat de plante pentru fotosinteză. Sunt folosiți pentru a corela răspunsul plantelor cu condițiile de iluminare și pentru optimizarea managementului luminii și a irigației [15].

Tehnologiile de interconectare a dispozitivelor

Tehnologiile de interconectare permit comunicarea între senzori, actuatori și platformele robotice din sere inteligente. Utilizând IoT, protocoale precum MQTT, rețele de senzori (ZigBee, LoRa, Wi-Fi) și platforme robotice (ROS), datele pot fi colectate și analizate în timp real, asigurând funcționarea integrată și optimizarea monitorizării și automatizării.

De exemplu, **ROS (Robot Operating System)** este un cadru software standard în robotică, oferind biblioteci și instrumente pentru interfațarea senzorilor și actoarelor, comunicarea între componente și planificarea navigației. Compatibil cu diverse hardware și algoritmi, ROS facilitează integrarea sistemelor robotice pentru monitorizarea și gestionarea culturilor. ROS2 extinde funcționalitățile pentru control în timp real, utilizarea microcontrolerelor și coordonarea mai multor roboți simultan [5], [6], [8].

2.3 Cazuri de utilizare

Agricultura de precizie aplicată în spații protejate (sere) oferă oportunități diversificate de optimizare a resurselor de apă, nutrienți, energie, precum și îmbunătățirea calității producției. Studii recente evidențiază integrarea senzorilor (microclimat, umiditate, nutrienți), IoT, inteligența artificială pentru predicție și control, viziune computerizată pentru monitorizare, roboți pentru intervenții. De exemplu, autorii din [16] arată că în perioada 2010-2025 s-au explorat peste 100 de lucrări privind controlul inteligent al sistemelor de sere (microclimat, irigare, creștere cultură).

În cele ce urmează, pentru fiecare cultură sunt prezentate contextul specific al aplicației de agricultură de precizie, tehnologiile implicate și aspecte relevante din literatură.

1. Tomate (roșiile)

Tomatele sunt printre cele mai studiate culturi în agricultura de precizie. În [17], un sistem de control și predicție a mediului (temperatură, umiditate, CO₂, iluminare) utilizând rețele neuronale BP („back-propagation”) și algoritmi genetici a permis reglaje automate în sere comerciale din Jilin, China. În [18], un sistem robotizat folosește GAN (Generative Adversarial Network) pentru augmentarea datelor și rețele neuronale convoluționale (CNN) pentru detecția și clasificarea bolilor la tomate.

Agricultura de precizie pentru culturile de tomate în sere include menținerea condițiilor optime de creștere și a reducerii variabilității producției, detectare automată boli/frunze pentru intervenție timpurie, reducând pierderile și monitorizare continuă și predicție, ceea ce permite intervenții proactive.

Ca și provocări, pot fi enumerate costul senzorilor și a sistemelor inteligente, integrarea cu serele existente, precum și scalabilitatea pentru întreaga cultură.

2. Castraveți

Cultivarea castraveților în seră beneficiază de sisteme de irigare inteligente, care ajustează volumul și frecvența irigării pe baza senzorilor. În [19] este prezentat un sistem pentru optimizarea consumului de apă, iar [20] arată că irigarea optimizată sau în deficit (~60% și ~36% din nivelul normal) reduce scurgerile de minerale fără a afecta randamentul și crește eficiența utilizării apei. Agricultura de precizie pentru culturile de castraveți în sere permite o monitorizare cu ajutorul senzorilor a umidității solului și nivelurilor de nutrienți, asigurarea controlului variabil al irigării în seră pentru reducerea pierderilor de apă și nutrienți, modelarea evapotranspirației. De exemplu, autorii din [21] au evaluat 20 de modele evotranspirație pentru

castraveți în seră cu CO₂ îmbogățit, găsind că modelul FAO56 Penman-Monteith este cel mai performant.

Aspectele negative ce trebuie combătute au legatură cu complexitatea integrării datelor climatice, substratului și plantei, costurile inițiale de implementare și adaptarea la sere diferite.

3. Ardei grași / iuți

Aplicațiile în agricultura de precizie vizează detecția fructelor pentru gestionarea recoltării și estimarea maturității, precum și monitorizarea stresului nutritiv prin imagistică multispectrală. În [22], recunoașterea maturității și numărarea fructelor în seră permit optimizarea recoltării, logisticii și ajustarea iluminării LED pentru îmbunătățirea uniformității culorii și calității fructelor.

Agricultura de precizie pentru culturile de ardei în sere a permis folosirea sisteme de viziune (RGB, multispectrale) și algoritmilor Deep Learning (YOLO, CNN) cu scopul ajustării microclimatului și a iluminării specific culturii de ardei pentru calitate optimă. Totuși, ca și dezavantaje pot fi numite necesitatea seturilor de date de antrenare pentru algoritmi; adaptarea la variații multiple ale soiurilor și mediu și integrarea cu sistemele de recoltare automată.

4. Căpșuni

În sere, căpșunile sunt cultivate în moduri variate (tunnel, benzi ridicate etc.) și agricultura de precizie oferă soluții pentru optimizarea irigației, nutrienților, monitorizarea fenologică și estimarea maturității culturilor. De exemplu, un studiu publicat în [22] arată utilizarea sistemelor de fertirigare controlate pentru îmbunătățirea randamentului și calității culturii de căpșuni.

Agricultura de precizie pentru culturile de căpșuni în sere a constat în utilizarea senzorilor de conductivitate electrică (pentru măsurarea cantității totale de săruri dizolvate în apă) și a senzorilor de umiditate substrat în benzi ridicate. De asemenea, a permis utilizarea tehnicilor *computer vision* pentru estimarea stadiului de maturitate și programarea recoltării.

În acestei culturi, provocările constau în utilizarea plasticului de acoperire a serelor ce poate afecta calitatea imaginilor; manipularea fructelor sensibile și costurile de automatizare.

2.4 Cerințe și cazuri de utilizare pentru platforma PROTECT-Agri

Cerințele și cazurile de utilizare pentru platforma PROTECT-Agri includ definirea scenariilor practice din seră împreună cu cerințele lor funcționale și tehnice, identificarea atât a nevoilor de bază, cât și a celor orientate spre creșterea productivității fermelor, precum și colectarea, analiza, clasificarea și prioritizarea acestora printr-o abordare agilă ce permite rafinarea necesităților în multiple iterații.

2.4.1 Definirea cazurilor de utilizare în seră (cerințe funcționale și tehnice)

Această etapă implică formularea modului în care sistemele vor fi utilizate în practică și pot fi numite:

- **Monitorizarea automată a plantelor cu robotul mobil**

- *Cerințe funcționale:* deplasare autonomă, captare imagini multispectrale, identificare boli.

- *Cerințe tehnice:* camere multispectrale MIPI/USB3, iluminare controlată, conectivitate Wi-Fi în seră, Jetson Orin pentru procesare locală.

-
- **Optimizarea microclimatului în seră**
 - *Cerințe funcționale:* măsurarea temperaturii, umidității, CO₂ și ajustarea ventilației.
 - *Cerințe tehnice:* senzori I²C / Modbus, comunicație cu sistemul de climatizare, rate minime de sampling.
 - **Detectia automată a stadiului de creștere**
 - *Cerințe funcționale:* determinarea dimensiunilor plantei prin viziune computerizată.
 - *Cerințe tehnice:* algoritmi de segmentare, iluminare artificială, stocare în cloud pentru antrenare AI.

2.4.2 Identificarea nevoilor de bază și a celor pentru creșterea productivității fermelor are în vedere:

- *Colectarea datelor de mediu în timp real* (temperatură, lumină, umiditate) pentru a preveni stresul plantelor.
- *Alertarea automată* la depășirea unor praguri (ex. umiditate prea scăzută).
- *Urmărirea consumului de apă* pentru a evita risipa.

Pentru creșterea productivității vor fi considerate: *predicția momentului optim de recoltare* pe baza datelor istorice și a modelelor AI, *planificarea lucrărilor cu roboți autonomi* pentru inspecție sau tratament, *analiza multispectrală pentru fertilizare precisă*, reducând costurile și crescând randamentul și *detectia timpurie a bolilor* pentru diminuarea pierderilor.

2.4.3 Colectarea, analiza, clasificarea și prioritizarea într-o manieră agilă

Această abordare permite rafinarea continuă în funcție de feedback și evoluția condițiilor din seră precum:

- **Colectarea prin interacțiuni cu fermierii și tehnicienii**
Ex.: interviuri, observații la fața locului, sesiuni de testare cu prototipul robotului.

- **Analiză și clasificare:**

- *Esențiale:* detectarea defectelor la plante, stabilitatea conexiunii robot–platformă.
- *Importante:* integrarea cu sistemul de irigație.
- *Opționale:* generarea rapoartelor grafice avansate.

- **Prioritizare în etape:**

- *Etapa 1:* implementare senzorică și comunicație de bază.
- *Etapa 2:* analiză de imagini și algoritmi de diagnostic.
- *Etapa 3:* optimizări pentru navigație autonomă.
- *Etapa 4:* integrare cloud pentru recomandări inteligente.

De exemplu, inițial robotul trimite doar imagini brute → feedback că fermierul vrea și *diagnostic automat* → se prioritizează implementarea clasificatorului AI → noua versiune este testată → cerințele se ajustează.

2.5 Proiectare arhitectură de referință PROTECT-Agri pe baza cerințelor tehnice

2.5.1 Rolul platformei robotice PROTECT-Agri

Arhitectura propusă (Figura 1) prezintă o structură ierarhică formată din trei niveluri: (i) modulul robotic, (ii) platforma digitală și (iii) aplicația utilizator final. Această organizare permite coordonarea optimă a controlului robotic, precum și colectarea, procesarea și vizualizarea integrată a datelor obținute în teren, asigurând un flux informațional coerent și funcționalitatea completă a sistemului.

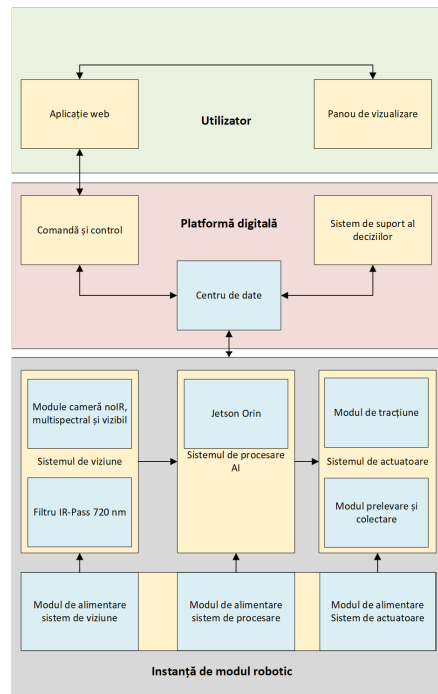


Figura 1 – Prototip arhitectura sistem robotic PROTECT-Agri

2.5.2 Componente de bază

Instanța modulului robotic reprezintă componenta fizică centrală a arhitecturii, integrând trei subsisteme principale: viziune, procesare AI și actuatore, fiecare cu alimentare proprie. Sistemul de viziune capturează imagini cu camere noIR, multispectrale și RGB cu filtru IR-Pass 720 nm, transmise către unitatea Jetson Orin pentru analiză AI, identificarea și clasificarea obiectelor. Rezultatele generează comenzi pentru actuatore, care permit robotului deplasarea autonomă și executarea precisă a sarcinilor de recoltare și colectare a eşantioanelor de sol.

Platforma digitală este centrul de comandă și control al sistemului, gestionând comenzile utilizatorului, coordonând modulul robotic și centralizând datele pentru vizualizare. Sistemul de suport al deciziilor analizează aceste informații și, prin algoritmi avansați, poate oferi recomandări sau acțiuni automate, sporind inteligența și eficiența operațională a întregului flux.

Utilizatorul interacționează cu sistemul prin aplicația web și panoul de vizualizare: aplicația permite transmiterea comenzilor și configurărilor, iar panoul afișează datele colectate și analizate. Ambele comunică constant cu platforma digitală, centrul logic al arhitecturii.

2.5.3 Tehnologii de interconectare/comunicații

În continuare este prezentată o listă de tehnologii de interconectare și comunicații adecvate fiecărui nivel și fiecărei legături din schema Utilizator–Platformă digitală–Modul robotic, incluzând atât variante cablate, cât și wireless, precum și protocoale specializate pentru viziune, control, senzori și cloud.

1. Comunicația între Utilizator și Platforma digitală: Aplicație web / Panou de vizualizare → Platformă digitală (posibile tehnologii și protocoale ce vor fi implementate):

- **HTTPS / REST API** – pentru comenzi, configurări și vizualizare date.
- **WebSockets** – pentru telemetrie în timp real, livestream, notificări.

- **MQTT** – pentru comunicații ușoare, publish–subscribe (foarte utilizat în IoT).
- **RTSP / WebRTC** – pentru streaming video în timp real din sistemul de viziune.

2. **Comunicația internă în Platforma digitală (intern)** ce realizează rolurile de Comandă și control ↔ Sistem de suport al deciziilor ↔ Centru de date. Printre tehnologiile de interconectare și comunicație considerate pot fi enumerate:

- **Message brokers: Kafka, RabbitMQ, ZeroMQ**
 - **REST / gRPC** – pentru microservicii.
 - **GraphQL** – pentru interogări structurate ale datelor.
 - **OPC-UA** – dacă se dorește interoperabilitate industrială.
- **Database protocols:** PostgreSQL / MySQL / MongoDB drivers.

3. **Platforma digitală ↔ Modul robotic** implică utilizarea unor tehnologii wireless precum:

- **Wi-Fi 6 / Wi-Fi 6E** – pentru transfer de date mare (imagini, modele AI).
- **4G / 5G** – pentru arii extinse, latență mică.
- **LoRaWAN** – pentru telemetrie simplă, consum redus (nu pentru video).
- **Bluetooth LE** – pentru configurări locale.
- **ZigBee / Thread / Matter** – pentru IoT low-power.

Tehnologii cablate posibile au în vedere **Ethernet Gigabit** – stabil pentru transfer de imagini / date.

4. **Comunicația internă în modulul robotic între sistemul de viziune și Jetson Orin** asigură transferul eficient al datelor necesare procesării și deciziilor în timp real. Interfețe specifice pentru camere pot fi:

Sistemul de viziune și Jetson	<ul style="list-style-type: none"> • MIPI CSI-2 – interfață standard pentru camere de înaltă viteză. • USB 3.0 / USB 3.1 – pentru camere industriale. • GigE Vision – camere conectate prin Ethernet.
Jetson Orin ↔ Modul de tracțiune / actuatoare	<ul style="list-style-type: none"> • CAN / CAN-FD – foarte utilizat în robotică pentru motoare și controllere. • EtherCAT – control în timp real pentru actuatoare. • RS-485 / Modbus RTU – pentru motoare, controllere sau senzori industriali. • PWM / GPIO / I²C / SPI – pentru control local, senzori și module de nivel inferior.
Jetson Orin ↔ Module de alimentare	<ul style="list-style-type: none"> • I²C – pentru monitorizarea tensiunii / curentului. • SMBus / PMBus – pentru telemetrie și control de putere.

5. **Sincronizare în timp real.** Pentru coordonare exactă între senzori și actuatoare:
- **PTP (Precision Time Protocol / IEEE 1588)** – sincronizare la nivel de microsecunde.
 - **NTP** – pentru sincronizare la nivel de milisecunde (platformă digitală).
 - **PoE (Power over Ethernet)** – alimentare + date prin același cablu.
 - **CAN / CAN-FD** – pentru vehicule și sisteme robuste.
 - **RS-485 / Modbus** – interfață industrială simplă și foarte robustă.

2.6 Analiza multispectrală a culturilor de seră

2.6.1 Metode de recunoaștere a culturilor bazate pe imagini (Vision based Recognition)

Analiza celor mai eficiente metode de recunoaștere a plantelor din imagini, bazate pe tehnici de computer vision, pentru caracterizarea individuală a plantelor și dezvoltarea algoritmilor de analiză automată a imaginilor multispectrale. În agricultura de precizie,

platformele robotice terestre autonome sunt esențiale pentru colectarea de date cu rezoluție înaltă, iar cele mai performante tehnici de viziune computerizată aplicabile acestor date vizează:

- **Caracterizarea individuală a plantelor**, permițând o analiză detaliată a stării fenotipice și de sănătate a fiecărei plante.

- **Dezvoltarea de algoritmi pentru analiza automată a imaginilor multispectrale**, cu scopul de a genera interpretări relevante despre starea generală a culturii.

Caracterizarea individuală este un proces granular care necesită izolarea precisă a unei singure plante din mediul său, adesea complex și aglomerat. Aceasta se realizează printr-o secvență de tehnici avansate:

A. Izolarea Plantei: Segmentarea Instanțelor

Analiza unei plante individuale începe prin separarea digitală a acesteia de plantele învecinate și de sol, realizată eficient prin segmentarea instanțelor, care identifică conturul fiecărei plante la nivel de pixel. Mask R-CNN și derivatele sale moderne (YOLACT, SOLOv2) sunt standardul în segmentarea instanțelor, gestionând ocluziile și generând măști binare. În [23] este prezentat un Mask R-CNN cu ResNet101-FPN și RPN pentru segmentarea și clasificarea frunzelor de cafea ca sănătoase sau nesănătoase, antrenat pe setul RoCole adnotat manual cu VGG Image Annotator.

B. Extragerea de Caracteristici Fenotipice

Odată izolată, planta poate fi analizată digital pentru a extrage parametri morfologici și de dezvoltare, precum suprafața foliară, biomasa și înălțimea, calculați automat din masca 2D. În [24], platforma Panicle Analyzer utilizează fenotiparea automată și deep learning pentru a analiza creșterea orezului, extrăgând 52 de trăsături ale paniculului și 35 ale lăstarului. Pe baza acestor date, producția de boabe a fost prezisă cu 86,2% acuratețe, iar analiza genetică (QTL) a identificat 3.586 de regiuni asociate etapelor de dezvoltare. Software-ul open-source poate fi extins și pentru alte culturi, precum grâul.

C. Diagnosticarea Sănătății

Pe imaginile individuale ale plantelor pot fi aplicate modele de clasificare pentru detectarea bolilor și dăunătorilor. În [25] este prezentată o metodă bazată pe Mask R-CNN pentru identificarea automată a bolilor din imagini ale frunzelor, antrenată pe setul PlantVillage (20.000+ imagini, 15 boli + clase sănătoase). Modelul a atins 95,68% acuratețe, permițând diagnostic rapid și prevenirea pierderilor de recoltă.

Analiza multispectrală oferă informații invizibile pentru evaluarea sănătății plantelor. NDVI evaluează vigoarea și fotosinteza, iar variațiile indică stres. Benzi spectrale specifice detectează deficitul de apă și nivelul de azot (Red Edge), permițând fertilizare țintită, iar modificările reflectanței frunzei semnaleză precoce boli. Datele sunt integrate în hărți de management pentru aplicarea precisă a apei, îngrășămintelor și tratamentelor.

Pentru generarea de interpretări relevante despre starea generală a culturii prin **analiza automată a imaginilor multispectrale**, sistemul multispectral format din camerele RGB și NoIR necesită un flux de procesare specific pentru a extrage informații relevante.

A. Pre-procesare: Alinierea Imaginilor (Image Registration)

O provocare majoră a sistemelor cu două camere este alinierea imaginilor RGB și NIR. Algoritmi DL sau clasici (SIFT/ORB) permit suprapunerea precisă per-pixel. În [26], autorii folosesc AKAZE pentru alinierea NIR peste RGB și o calibrare radiometrică cu panou de

referință, asigurând valori corecte de reflectanță și măsurători precise.

B. Generarea Indicilor de Vegetație

Odată imaginile aliniată, se calculează indicii de vegetație (VI) pentru evaluarea stării plantelor și monitorizarea secetei. VI-urile se împart în patru categorii: structură, clorofilă, luteină și umiditate, cele mai utilizate fiind NDVI, SAVI și OSAVI [26]. Indexul stresului hidric la plante (CWSI - Crop Water Stress Index) a fost estimat prin măsurători directe și analize multispectrale de la drone, metoda cu drone oferind o evaluare mai precisă și cuprinzătoare a stresului hidric la nivelul întregii culturi.

C. Generarea de Interpretări Relevante

Hărțile NDVI devin utile după post-procesare, care permite evaluarea sănătății plantelor, monitorizarea creșterii și detecția timpurie a stresului sau bolilor. În [27], este propus un model deep learning pe imagini RGB spațio-temporale pentru evaluarea sănătății tomatelor (scara 1–5), folosind CNN și Transformere, antrenat pe 12.000+ imagini, generând predicții corelate cu expertii și hărți dinamice pentru intervenții timpurii.

2.6.2 Analize multispectrale în cadrul proiectului PROTECT-Agri

În prima etapă practică, imaginile multispectrale și RGB au fost colectate în octombrie 2025, într-o seră privată din Comana, Giurgiu, pentru testarea poziționării camerei pe robot, a metodelor de captare și a cerințelor modulului de achiziție. Setul inițial a fost filtrat pentru relevanță (poziționare, conținut, rezoluție), iar prelucrarea în QGIS a generat imagini RGB, hărți NDVI și NDRE (Figura 2).




Figura 2 - Imagine RGB (stânga)/ Hartă NDVI (mijloc)/ Hartă NDRE (dreapta)

Interpretarea rezultatelor pentru harta indexului NDVI indică:

o cu culoare verde: Cele mai mari valori NDVI indică coronamentul cel mai dens și mai sănătos. Aceasta se referă la plantele care prezintă creștere sănătoasă în zona central-dreaptă a imaginii RGB.

o cu culoare roșie/portocalie/galbenă: Cele mai mici valori NDVI indică sol gol, structuri sau vegetație moartă. Este cartografiat solul lipsit de vegetație, „pereții” serei și culturile uscate din extrema stângă.

Principala diferență dintre hărțile NDRE și NDVI este că NDRE apare mai „zgomotoasă”, evidențiind mai multe detalii ale coronamentului. Aceasta se datorează sensibilității crescute a NDRE la variațiile de clorofilă: banda Red Edge pătrunde mai profund în coronament, permițând detectarea timpurie a stresului și a variațiilor subtile în vegetația densă. În practică,

NDRE este utilizat frecvent pentru fertilizare de precizie și identificarea deficiențelor de nutrienți în zonele aparent sănătoase.

Analiza canalelor R și NIR oferă informații relevante legate de captarea corectă a culorilor, dar și de aliniere în vederea obținerii unei rezoluții bune a imaginilor (Figura 3).

Cele 5 canale de culoare (R, G, B, Red Edge, NIR-Near Infrared) ale imaginilor multispectrale nu sunt alinierte spațial. Datorită pozițiilor senzorilor de captură există diferențe mai mici sau mai mari între componente de culoare.



Figura 3 - Imagine RGB (stânga)/ Componenta Red (mijloc)/ Componenta NIR (dreapta)

În Figura 4, obținută prin combinarea canalelor R și NIR, se observă diferența spațială dintre cele două canale. Imaginea obținută pare nefocalizată.




Figura 4 - Imagine RGB

Pentru a combate efectul de aliniere a fost utilizată funcția *GDAL Georeferencer* din aplicația QGIS, funcție care permite definirea unui set de puncte corespondente în două imagini și aplicarea unei transformări pe baza acestui set de puncte. A fost realizată, de asemenea, și alinierea componentei Red în funcție de NIR (Figura 5).




Figura 5 - Harta NDVI înainte de aliniere (stânga)/
Harta NDVI cu 3 clase după aliniere (mijloc)/ Harta NDVI cu 3 clase după aliniere (dreapta)




Figura 6 - Harta NDRE înainte de aliniere (stânga)/ Harta NDRE după aliniere (dreapta)

Cele două imagini din Figura 6 justifică nevoia alinierii canalelor multispectrale. Detaliile cu culoare roșu din imaginea din stânga ilustrează dez-alinierea spațială dintre componentele R și Red Edge. Din a doua imagine se poate observa că alinierea nu este perfectă și poate fi îmbunătățită printr-un algoritm automat care să caute punctele cele mai reprezentative.




Figura 7 - NIR cu punctele de control (stânga)/
Red cu punctele de control (mijloc)/ Harta aliniere Red – NIR (dreapta)




Figura 8 - NIR cu punctele de control (stânga)/
Red Edge cu punctele de control (mijloc)/ Harta aliniere Red Edge- NIR (dreapta)

În urma prelucrărilor și rezultatelor obținute, s-a constatat că este necesară implementarea unui algoritm care să facă automat alinierea spațială, calculul hărților, segmentarea plantelor și etichetarea acestora pentru conferirea unui ID unic spațial.

3 Dezvoltarea modului de detecție a solului din cadrul PROTECT-Agri

Utilizarea modului de detecție a solului are rolul de a permite platformei robotice să monitorizeze, să diagnosticheze și să optimizeze condițiile solului în timp real, pentru a crește randamentul culturilor și a reduce consumul de resurse.

Modalitate de prelevare a probelor de sol

Probele de sol au fost colectate la nivel de platformă agricolă (în seră), respectând un model prestabilit de prelevare și o frecvență fixă, stabilită în funcție de obiectivele studiului și tipul culturii (pentru analiza probelor de sol efectuată în laborator s-au luat probe de sol pe toată perioada de vegetație, de la plantare până la recoltare). Procedura a inclus următoarele etape:

1. Definirea platformei – s-a delimitat o suprafață reprezentativă pentru sera cultivate cu tomate și ardei, cu dimensiuni și coordonate clar marcate. Platforma este reprezentată de o suprafață de 100 m² (aprox. 6.5m x 12m).

2. Planul de prelevare – s-a aplicat un model prestabilit (grilă), astfel încât probele să fie reprezentative pentru întreaga platformă.

3. Frecvența prelevării – probele sunt recoltate la intervale regulate (pentru toată perioada de vegetație).

4. Procedura de recoltare – pentru fiecare punct de eșantionare s-a colectat un volum standard de sol (500 g), la adâncimea specificată (10 cm), folosind instrumente curate și dezinfectate pentru a evita contaminarea.

5. Etichetarea și transportul probelor – fiecare probă este etichetată cu cod unic, dată și locație, apoi transportată în condiții controlate către laborator pentru analiză.

Metoda garantează probe reprezentative și comparabile în timp, reducând erorile de eșantionare și oferind date solide despre sol, fertilitate și emisii. Pentru integrarea în algoritmul platformei, s-au determinat în laborator și teren valorile parametrilor multicriteriali:

Sol

- Umiditate sol/ Temperatura sol/ pH/ Conductivitate/ Nutrienți (N, P, K– determinare în laborator, în faza incipientă a proiectului, pentru a detecta limitele înregistrate)/ Compactare (determinare calitativă)

Aer

- Temperatura aer/ Umiditate relativă/ CO₂/ Intensitate luminoasă.




Figura 9 - Protocol de prelevare a probelor de sol

În Tabelul 1 sunt prezentate valorile rezultate din analiza probelor de sol în laborator, dar și valorile medii recomandate, în vederea integrării lor ca limite, pentru stabilirea parametrilor multicriteriali care sa intre in arhitectura platformei.

Tabelul 1 - Valori in situ și în laborator (nutrienți)

Parametru	Valoare analiză laborator	Valoare medie recomandată	Valoare medie recomandată
Umiditate sol (VWC)	32%	25–40 %	<25% = irigare; >45% = exces apă
Temperatura solului (°C)	18 °C	16–24 °C	<16°C sau >26°C = avertizare

pH sol	6.2	6.0–6.8	<5.8 sau >7.0 = corecții necesare
Conductivitate EC (dS/m)	Roșii: ~2.0 / Ardei: 2.4	1.8–3.0	>3.5 = salinitate; <1.5 = fertilizare insuficientă
Temperatură aer zi (°C)	20 °C	20–26 °C	>28°C = ventilație; <18°C = încălzire
Temperatură aer noapte (°C)	15 °C	14–18 °C	<12°C = risc de stres
Umiditate relativă aer (RH)	65 %	60–80 %	>85% = risc boli; <50% = stres hidric
CO ₂ (ppm)	800 ppm	700–1200 ppm	>1200 = ventilație; <400 = normal atmosferic
Compactare sol (g/cm ³)	1.2	1.0–1.4	>1.4 = compactare
Cantitate probă sol	500 g	100–500 g	<100 g = prelevare repetată
Frecvență prelevare	Senzori: zilnic / Probe: 1×/fiecare stare de vegetație	—	Anomalii = prelevare imediată
Lumina PPFD (μmol/m ² /s)	270	150–400	Valori mici = verificare iluminat
N total (mg/100 g sol)	187	100-300	Dacă N<100 mg/100 g sol, se aplică fertilizări faziale.
N-NO ₃ (mg/100 g sol)	11	2-20	Intervalul corespunde unei stări de rezervă minerală suficientă pentru culturi protejate; sub ~2 mg/100 g este considerat scăzut, iar peste ~20 mg/100 g înseamnă valori mari/foarte bine aprovizionate (atenție la riscul de levigare și poluare a apelor freatiche).
N-NH ₄ (mg/100 g sol)	0.9	0-3	Frecvent < 2 mg/100 g). Valori mari de NH ₄ ⁺ indică recentă fertilizare cu forme amoniacale sau condiții de nitrificare redusă — pot afecta pH local și pot modifica raportul NO ₃ :NH ₄ (important pentru tomate/ardei).
P (P ₂ O ₅) (mg/100 g sol)	9	8-16	Dacă P ₂ O ₅ < 8 mg/100g (sub ~80 mg/kg) → deficit: se aplică fosfor de bază.
K (K mobil) (mg/kg sol)	130	100-200	Dacă K < 100–150 mg/kg → se aplică potasiu (ex. 150–300 kg K ₂ O/ha).



Figura 10 - Determinarea in situ a parametrilor de sol, în ultima fază de vegetație



Figura 11 - Determinarea in situ a parametrilor de sol, în ultima fază de vegetație

Pentru determinarea nutrienților din probele de sol, în Tabelul 2 sunt prezentate metodele de detecție a concentrațiilor acestor elemente chimice.

Tabelul 2 - Metodele chimice de detecție a concentrațiilor de nutrienți

Element chimic	Parametru determinat	Metodă
N total	N organic + N amoniacal	Kjeldahl
N mineral (NO_3^- , NH_4^+)	Azot accesibil plantelor	Extracție KCl + spectrofotometrie / distilare
P mobil (P-AL)	Fosfor disponibil	Acid lactic (AL) + spectrofotometrie
K mobil (K-AL)	Potasiu disponibil	Acid lactic (AL) + flacmmetru/AAS/ICP

Analiza solului și aerului, în laborator și în teren, a oferit date coerente despre fertilitate și microclimat, calibrând sistemul multicriterial. Valorile de referință pentru tomate și ardei definesc praguri de avertizare și condiții optime pentru cultură. Combinarea măsurătorilor continue cu analiza de laborator susține o platformă robotică autonomă capabilă să interpreteze datele și să sprijine deciziile agronomice.

Următoarele etape vizează integrarea datelor într-un sistem inteligent al platformei robotice, cu modele predictive și module de acțiune care generează alerte și comenzi automate pentru gestionarea optimă a culturilor și atingerea autonomiei operaționale.

4 Concluzii

Desfășurarea etapei 1 din cadrul proiectului a constat atât în activități de cercetare ale literaturii de specialitate, cât și în activități de cercetare experimentale.

În cadrul etapei 1 au fost detaliate cazurile de utilizare în seră, cu cerințele funcționale și tehnice, precum și nevoile de bază și cele pentru creșterea productivității fermelor. Au fost prezentate modalități de colectare, analiză, clasificare și prioritizare a acestora într-o manieră agilă, prin iterații succesive. Raportul prezintă succint proiectarea arhitecturii de referință PROTECT-Agri pe baza cerințelor tehnice, implementarea analizelor multispectrale cu algoritmi de interpretare automată a imaginilor pentru dezvoltarea recunoașterii bazate pe imagini pentru caracterizarea și reidentificarea plantelor (în etapele ulterioare), precum și crearea unui mini-prototip de platformă de detecție a solului care prelevează probe conform unui model prestabilit, platformă ce urmează a fi atașată la platforma robotică.

În cadrul etapei 2 se va proiecta structura și funcționalitatea platformei robotizate terestre pentru aplicații agricole și se va dezvolta un prototip operațional.

5 Diseminare/Site web

Activitățile desfășurate în cadrul primei etape a proiectului de către membrii UNSTPB și BEAM INNOVATIONS, s-au concretizat în:

- crearea unui website al proiectului: <https://protect-agri.aiot-xplorer.eu/> ;
- diseminarea rezultatelor în cadrul unor lucrări științifice pe tematica proiectului:
 - C. Furculescu, M. Gheorghe, **A. Martian, T. Stoian, I. Marcu**, „Optimization Strategies for 5G Radio Coverage in Critical Urban Areas: A Case Study of Bucharest”, în pregătire de trimitere spre recenzare la IEEE Communication Letters.

BIBLIOGRAFIE

- [1] M. Cantillo, et. al, “The State of Food and Agriculture 2021 agrifood systems resilient to shocks and stresses”. doi: [10.4060/cb4476en](https://doi.org/10.4060/cb4476en)
- [2] Y. Zhang, et al, “Smart greenhouse management using IoT and AI technologies: A comprehensive review”, *Computers and Electronics in Agriculture* 2022, 198,
- [3] European Commission, “Digitalisation in Agriculture: Smart Farming and Data Management”, 2023.
- [4] Liakos, K.G.; Busato, P.; Moshou, D.; Pearson, S.; Bochtis, D. “Machine Learning in Agriculture: A Review”. *Sensors* 2018, 18, 2674. <https://doi.org/10.3390/s18082674>
- [5] Atefi A, Ge Y, Pitla S and Schnable J (2021) Robotic Technologies for High-Throughput Plant Phenotyping: Contemporary Reviews and Future Perspectives. *Front. Plant Sci.* 12:611940.
- [6] Rui Xu, Changying Li, A Review of High-Throughput Field Phenotyping Systems: Focusing on Ground Robots, *Plant Phenomics*, Volume 2022, 2022, 9760269, ISSN 2643-6515,
- [7] Łągiewska, M.; Panek-Chwastyk, E. Integrating Remote Sensing and Autonomous Robotics in Precision Agriculture: Current Applications and Workflow Challenges. *Agronomy* 2025, 15, 2314. <https://doi.org/10.3390/agronomy15102314>
- [8] Abdelkrim Abanay, Lhoussaine Masmoudi, Mohamed El Ansari, Javier Gonzalez-Jimenez, Francisco-Angel Moreno. LIDAR-based autonomous navigation method for an agricultural mobile robot in strawberry greenhouse: AgriEco Robot[J]. *AIMS Electronics and Electrical Engineering*, 2022, 6(3): 317-328. doi: 10.3934/electreng.2022019
- [9] J.A. Sánchez-Molina, F. Rodríguez, J.C. Moreno, J. Sánchez-Hermosilla, A. Giménez, Robotics in greenhouses. Scoping review, *Computers and Electronics in Agriculture*, Volume 219, 2024, 108750, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2024.108750>.
- [10] Xie, D.; Chen, L.; Liu, L.; Chen, L.; Wang, H. Actuators and Sensors for Application in Agricultural Robots: A Review. *Machines* 2022, 10, 913.

-
- [11] R. T. Marcus, chapter 2 - The Measurement of Color, Editor(s): Kurt Nassau, AZimuth, North-Holland, Volume 1, 1998, Pages 31-96, ISSN 1387-6783, ISBN 9780444898463,
- [12] C.N.G. Scotter, INFRARED SPECTROSCOPY | Near-Infrared, Editor(s): Paul Worsfold, Alan Townshend, Colin Poole, Encyclopedia of Analytical Science (Second Edition), Elsevier, 2005, Pages 415-426, ISBN 9780123693976, <https://doi.org/10.1016/B0-12-369397-7/00277-6>.
- [13] Laveglia, S.; Altieri, G.; Genovese, F.; Matera, A.; Scarano, L.; Di Renzo, G.C. Development of a Short-Range Multispectral Camera Calibration Method for Geometric Image Correction and Health Assessment of Baby Crops in Greenhouses. *Appl. Sci.* 2025, 15, 2893.
- [14] Anuja Bhargava, Ashish Sachdeva, Kulbhushan Sharma, Mohammed H. Alsharif, Peerapong Uthansakul, Monthippa Uthansakul, Hyperspectral imaging and its applications: A review, *Heliyon*, Volume 10, Issue 12, 2024, e33208, ISSN 2405-8440,
- [15] Rahman, M.M.; Jamil, U.; Pearce, J.M. Open-Source Photosynthetically Active Radiation Sensor for Enhanced Agricultural and Agrivoltaics Monitoring. *Electronics* 2025, 14, 2225.
- [16] Li, K.; Shi, J.; Hu, C.; Xue, W. "The Intelligentization Process of Agricultural Greenhouse: A Review of Control Strategies and Modeling Techniques", *Agriculture* 2025, 15, 2135.
- [17] Zhang, Wei, Wenyu Zhong, Zhidong Liu, Baoxia Du, Mingliang Li, Meng Huang, Helong Yu, BOWEI Chen, and You Tang. 2024. "Precision Regulation and Forecasting of Greenhouse Tomato Growth Conditions Using an Improved GA-BP Model", *Sustainability* 16, no. 10: 4161.
- [18] Mac, T.T., Nguyen, TD., Dang, HK. *et al.* "Intelligent agricultural robotic detection system for greenhouse tomato leaf diseases using soft computing techniques and deep learning", *Sci Rep* **14**, 23887 (2024). <https://doi.org/10.1038/s41598-024-75285-5>
- [19] Behzadipour F, Ghasemi-Nejad-Raeini M, et al. "Optimizing water use efficiency in greenhouse cucumber cultivation: A comparative study of intelligent irrigation systems". *PLoS One.* 2024,
- [20] Guo, Yicong, Shan Wang, Dong Li, Jing Nie, Lihong Gao, and Xiaolei Sui. 2025. "Deficit Irrigation of Greenhouse Cucumber Reduces Mineral Leaching and Improves Water Use Efficiency While Maintaining Fruit Yield", *Nitrogen* <https://doi.org/10.3390/nitrogen6010018>
- [21] Ghiat Ikhlas , Govindan Rajesh , Al-Ansari Tareq, "Evaluation of evapotranspiration models for cucumbers grown under CO2 enriched and HVAC driven greenhouses: A step towards precision irrigation in hyper-arid regions", *Frontiers in Sustainable Food Systems*, 2023, DOI=10.3389/fsufs.2023.1155443
- [22] Sonali, Jing He, Yuanyuan Wang, et. al., "Optimised fertigation improves yield and quality of cucumbers for resource efficiency and economic return in high-tech greenhouses", *Journal of Agriculture and Food Research*, Volume 19, 2025, <https://doi.org/10.1016/j.jafr.2025.101699>
- [23] Mazen, F.M.A., and Nashat, A.A. (2024). Instance Segmentation and Classification of Coffee Leaf Plant using Mask RCNN and Transfer Learning, *Fayoum University Journal of Engineering*, Vol: 7(1),130-141
- [24] Geng, Z.D.; et al. High-throughput phenotyping and deep learning to analyze dynamic panicle growth and dissect the genetic architecture of yield formation. *Crop Environ.* 2024, 3, 1–11.
- [25] S. D. Meena, H. Katragadda, P. Bijin Sanny, K. Dande and J. Sheela, "Using Region-Based Deep Learning Algorithm Mask RCNN Algorithm on Image-Based Plant Disease Detection," *2023 International Conference on Data Science, Agents & Artificial Intelligence (ICDSAAI)*, Chennai, India, 2023, pp. 1-8, doi: 10.1109/ICDSAAI59313.2023.10452514.
- [26] Zhang, L.; Zhang, H.; Niu, Y.; Han, W. Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. *Remote Sens.* 2019, 11, 605.
- [27] JLee, G.; et al. Vegetation Classification in Urban Areas by Combining UAV-Based NDVI and Thermal Infrared Image. *Appl. Sci.* 2023, 13, 515.

05.12.2025

Director de proiect
Prof.dr.ing. Ioana-Manuela Marcu