

CREȘTEREA COMPETITIVITĂȚII ECONOMIEI ROMÂNESTI PRIN CDI
Proiect Experimental Demonstrativ
“Platforma Next Generation Internet bazată pe 5G și UAV-uri pentru agricultura de precizie” (NGI-UAV-AGRO)

Nr. Contract 461PED/2020

RAPORTUL ȘTIINȚIFIC ȘI TEHNIC
(RST)

“Studiul specificațiilor NGI pentru agricultura de precizie”

Termen:	Decembrie 2021
Autori:	
Participanți:	UPB, BEIA
Etapa:	I. Stabilirea principiilor de bază ale unei platforme mobile compatibile NGI 5G
Activitatea:	1. Specificații NGI pentru agricultura de precizie; 2. Caracteristicile unei rețele 5G pentru sistemul de telemetrie
Etapa:	II. Proiectarea și testarea preliminară a unei platforme NGI 5G folosind WSN și UAV pentru agricultura de precizie
Activitatea:	1. Proiectarea preliminară a unei platforme NGI 5G folosind WSN; 2. Testarea preliminară a unei platforme NGI 5G folosind WSN; 3. Configurarea sistemului de telemetrie cu UAV; 4. Testarea outdoor a platformei NGI 5G cu WSN și UAV; 5. Prelucrarea preliminară a datelor și imaginilor obținute cu WSN și UAV prin testări outdoor folosind baze de date complexe și opțiuni de salvare în Cloud
Natura:	Raport de etapă

© Copyright Consorțiul NGI-UAV-AGRO, 2021

1	INTRODUCERE	4
1.1	Obiectivele proiectului	4
1.2	Obiectivele etapelor curente	5
1.3	Rezumat	5

ETAPA I - Stabilirea principiilor de bază ale unei platforme mobile compatibile NGI 5G

2	STABILIREA PRINCIPILOR DE BAZĂ ALE UNEI PLATFORME MOBILE NGI 5G	ERROR! BOOKMARK NOT DEFINED.
2.1	Principalele tehnologii folosite în agricultura de precizie	6
2.1.1	Ce este agricultura de precizie?	6
2.1.2	Definirea și explicarea tehnologiilor pentru agricultura de precizie	6
2.2	Specificații NGI pentru agricultura de precizie	8
2.2.1	NGI: generalități, cazuri de utilizare	8
2.2.2	NGI în agricultura de precizie	9
2.3	Sistem de telemetrie pentru agricultura de precizie	11
2.3.1	Parametrii de interes pentru un sistem de telemetrie pentru agricultura de precizie	11
2.3.2	Caracteristicile unei rețele 5G pentru sistemul de telemetrie pentru agricultura de precizie	12

ETAPA II - Proiectarea și testarea preliminară a unei platforme NGI 5G folosind WSN și UAV pentru agricultura de precizie

3	PROIECTAREA ȘI TESTAREA PRELIMINARĂ A UNEI PLATFORME NGI 5G FOLOSIND WSN ȘI UAV PENTRU AGRICULTURA DE PRECIZIE	13
3.1	Proiectarea și testarea preliminară a unei platforme NGI 5G folosind WSN	13
3.2	Configurarea sistemului de telemetrie cu UAV	17
3.3	Testarea outdoor a platformei NGI 5G cu WSN și UAV	19
3.4	Prelucrarea preliminară a datelor și imaginilor obținute cu WSN și UAV prin testări outdoor folosind baze de date complexe și opțiuni de salvare în Cloud	24
	CONCLUZII	32
	DISEMINARE/SITE WEB	33
	BIBLIOGRAFIE	33

1 Introducere

1.1 *Obiectivele proiectului*

Scopul principal al proiectului constă în dezvoltarea și implementarea unei platforme de monitorizare și prevenție pentru agricultura de precizie, deziderate realizate cu ajutorul specificațiilor actuale 5G și vehiculelor autonome de tip UAV (Unmanned Aerial Vehicle). La proiectarea platformei NGI se au în vedere utilizarea rețelelor de senzori dedicați wireless, precum și rutarea 6LoWPAN de tip punct-la-punct pentru interconectarea și comutarea între rețelele de senzori wireless și NGI. Vor fi monitorizate în timp real culturi (de ex. vița de vie) pentru a detecta în timp util modificarea parametrilor solului și plantelor și pentru a acționa mecanismele de irigare a solului, de identificare a stadiilor unor bolilor ce pot apărea datorită poluării aerului și a apei, aplicării unei cantități incorecte de pesticide, etc. Ulterior, prin fuziunea datelor provenite de la senzori, vor fi luate decizii de prevenție și combatere a bolilor plantelor. Totodată vor fi transmise alerte și recomandări beneficiarilor.

Caracteristicile platformei NGI bazată pe 5G și UAV au în vedere reconfigurabilitatea și scalabilitatea, consum redus de energie, interacțiune umană redusă și precizie maximă.

1.2 *Obiectivele etapelor curente*

Prezentul raport include aspecte legate de primele două etape ale proiectului:

A. **Etapa 1: „Studiul specificațiilor NGI pentru agricultura de precizie”** în care se urmăresc:

- Studiul principalelor tehnologii utilizate în agricultura de precizie;
- Analiza tehnicii NGI și aplicabilitatea în domeniul agriculturii de precizie;
- Prezentarea detaliată a parametrilor unei rețele 5G pentru agricultura de precizie.

B. **Etapa 2: „Proiectarea și testarea preliminară a unei platforme NGI 5G folosind WSN și UAV pentru agricultura de precizie”** în care se urmăresc:

- proiectarea preliminară și testarea incipientă a unei platforme NGI 5G folosind WSN;
- configurarea ulterioară sistemului de telemetrie cu UAV;
- testarea outdoor a platformei NGI 5G cu WSN și UAV;
- prelucrarea preliminară a datelor și imaginilor obținute cu WSN și UAV utilizând baze de date complexe și opțiuni de salvare în Cloud.

1.3 *Rezumat*

Tabelul 1 - Activitățile derulate în Etapele 1 și 2 ale proiectului

Activități	Responsabil activitate
A1.1. Studiul specificațiilor NGI pentru agricultura de precizie	CO (UPB), BEIA
A1.2 Caracteristicile unei rețele 5G pentru sistemul de telemetrie	CO (UPB)
A2.1 Proiectarea preliminară a unei platforme NGI 5G folosind WSN	CO (UPB)
A2.2 Testarea preliminară a unei platforme NGI 5G folosind WSN	CO (UPB), BEIA
A2.3 Configurarea sistemului de telemetrie cu UAV	CO (UPB), BEIA
Act 2.4 Testarea outdoor a platformei NGI 5G cu WSN și UAV	CO (UPB), BEIA
A2.5 Prelucrarea preliminară a datelor și imaginilor obținute cu WSN și UAV prin testări outdoor folosind baze de date complexe și opțiuni de salvare în Cloud	CO (UPB), BEIA
Act 2.6 Diseminarea rezultatelor în urma testărilor preliminare prin participarea la manifestări tehnico-științifice	CO (UPB), BEIA

2 STABILIREA PRINCIPILOR DE BAZĂ ALE UNEI PLATFORME MOBILE NGI 5G

2.1 Principalele tehnologii folosite în agricultura de precizie

În prezent, agricultura trebuie să facă față unor provocări dificile din mediul înconjurător. Fiind cea mai tradițională activitate dintre toate activitățile productive, a trecut de-a lungul timpului prin multe transformări tehnologice în scopul creșterii productivității și calității. Agricultura trebuie să-și reconsidere rolul și să se adapteze unei lumi aflată în continuă schimbare. Datorită creșterii continue a consumului de produse agricole, agricultorii și companiile mari care activează în zona “Big Data” investesc în agricultura de precizie folosind rețele de senzori, drone, sateliți și sisteme de urmărire GPS. Agricultorii care utilizează doar un singur tip de tehnologie de precizie au crescut randamentul cu 16% și au redus consumul de apă cu 50%, beneficiind de o rapidă amortizare a costurilor acestor tehnologii, realizând o economie de 15% la semințe, îngrășăminte și substanțe chimice.

Plantele agricole sunt extrem de sensibile la schimbările climatice deoarece temperaturile mai mari și modificările de precipitații sporesc șansa apariției bolilor, putând duce la afectarea culturilor și chiar la distrugerea ireversibilă a plantelor. Progresele actuale ale tehnologiilor Internet of things (IoT) și Cloud Computing au dus la dezvoltarea de noi aplicații bazate pe platforme de servicii extrem de inovatoare și scalabile, inclusiv în viticultură. Soluțiile IoT au un mare potențial în asigurarea calității și siguranței produselor agricole.

2.1.1 Ce este agricultura de precizie?

Estimările de anul trecut indicau faptul că piața agriculturii de precizie va atinge (la nivel global) 4,2 miliarde de euro, iar un fermier va ajunge să hrănească 256 de persoane până în 2030, de la 26 de persoane în prezent. Noua Politică Agricolă Comună 2020 a continuat să încurajeze prin stimulentele financiare, precum și schemele de sprijin, atât capacitatea fermierilor de a investi în tehnologiile agricole de precizie, cât și în inovarea în domeniu prin susținerea proiectelor de cercetare H2020 [1]. Agricultura de precizie contribuie substanțial la creșterea randamentului culturilor, reducând pierderile de resurse cum ar fi apa, îngrășămintele sau pesticidele prin direcționarea acestora către culturile care au cea mai mare nevoie. În prezent, practicarea agriculturii de precizie reprezintă viitorul și progresul fermelor din România și, ca urmare, tot mai mulți fermieri apelează la ultimele tehnologii în domeniu (sisteme și monitoare GPS automatizate, senzori, sisteme de monitorizare și control, etc.) pentru a-și ușura munca și a obține rezultate remarcabile cu resurse distribuite controlat.

2.1.2 Definirea și explicarea tehnologiilor pentru agricultura de precizie

O pare din tehnologiile și soluțiile eficiente pe termen lung propuse fermierilor sunt [2]:

1. sistemele de monitorizare GPS automatizate oferă rapiditate și eficiență în lucrările agricole din teren. Printre avantajele se pot enumera reducerea din oboseala operatorului, precizia în lucrările agricole, reducerea costurilor legate de producție, minimizarea deteriorării culturilor și îmbunătățirea producției.

2. programe pentru gestionarea fermelor: acestea pot aduna, împărți și gestiona informația necesară luării celor mai bune decizii în legătură cu activitatea fiecărui fermier cărui i se adresează. Programele și aplicațiile lor asigură capacități multiple care includ colectarea informațiilor din monitoarele cabinelor sau tablete, gestionarea hărților de agricultură de precizie și jurnalul de lucrări și până la protejarea datelor. Simultan, este asigurat accesul la informațiile despre fermă de oriunde și oricând.

3. program pentru monitorizarea flotei și a combustibilului: se poate accesa cu ușurință aplicația de mobil a sistemului pentru a monitoriza de la distanță utilajele din fermă. De asemenea, pot fi generate rapoarte personalizate în timp real, acestea fiind sub prezentate sub formă de tabele grupate cu toate detaliile solicitate. Pot fi setate notificări și alte opțiuni care contribuie la un control complet asupra flotei și combustibilului consumat, dar și cu privire la activitatea operatorilor din teren, astfel practicând cu succes agricultura de precizie.

4. utilizarea senzorilor în agricultura de precizie: prin intermediul lor se pot aduna date cu privire la disponibilitatea apei din sol, compactarea solului, fertilitatea solului, indicele suprafeței foliare, date climatice locale, etc. Pot fi luate decizii obiective (de ex. referitoare la calitatea de îngrășământ ce trebuie să fie aplicat unei anumite culturi). Pentru fermierii care se confruntă cu buruienile crescute în exces, sistemele inovative îi ajută să reducă cu până la 80% costurile de ținere sub control a buruienilor, prin reducerea costurilor cu substanțele chimice, micșorarea timpului de lucru și reducerea impactului activităților asupra mediului înconjurător.

5. rata variabilă de aplicare (VRA) este o tehnologie ce permite fermierilor aplicarea de materiale diferite (de ex. îngrășăminte) cu rată variabilă în timp real în scopul uniformizării fertilității suprafeței vizate. Aplicarea cu rata variabilă se efectuează pe baza unor hărți detaliate cu rezultate obținute în urma prelevării de probe de sol. Spre deosebire de prelevarea standard a probelor de sol, în acest caz probele sunt prelevate cu o densitate de până la 4 ori mai mare. Recomandările de corecție a acidității solului (pH), precum și cele de fertilizare (fosfor și potasiu) sunt transpuse sub forma unor hărți digitale ce se încarcă în computerul utilajelor dotate cu echipamente specializate. Astfel, se pot aplica cantități variabile de îngrășăminte.

Funcționalitatea sistemului NGI-UAV-AGRO se bazează pe transmitere, recepția și stocarea datelor de la/către echipamentele de bază și, în prezent, există numeroase soluții care oferă servicii de conectivitate între componentele unui sistem utilizat în agricultură. Pentru transmiterea pe distanțe mici se pot utiliza numeroase tehnologii wireless precum RFID, NFC, Wi-Fi, Bluetooth, XBee, zigBee, Z-Wave, iar pentru conectivitate de rază mare și pe zone extinse se pot folosi linkurile existente în rețele mobile de GSM/GPRS/3G/LTE și conexiunile satelitare [3].

În tehnologia wireless din prezent se folosesc cu precădere următoarele rețele [4]:

- GSM (Telemetrie, SMART City, colectarea datelor având o cantitate medie);
- LTE (Telemetrie, SMART City, colectarea datelor);
- Bluetooth (Automatizarea casei – SMART Home);
- Wi-Fi (Automatizarea casei – SMART Home);
- Lora / LoRaWAN (Telemetrie, Contoare de energie, SMART City);
- SigFox (Telemetrie, Contoare de energie, Senzor de Transfer al Datelor).

Câteva tehnologii, împreună cu avantajele și dezavantajele lor, sunt detaliate în continuare.

GSM (Global System for Mobile Communications)

Rețeaua GSM asigură interconectivitatea între diverse dispozitive electronice de măsură folosite în agricultură. Companiile specializate în distribuția de dispozitive electronice utile tuturor fermelor cu un teritoriu de la câteva sute la mii de hectare folosesc sistemul GSM pentru interconectarea echipamentelor, echipamente care îmbunătățesc atât calitatea, cât și eficiența economică a agriculturii [5]. De exemplu, sisteme LD-Agro [6] folosesc modem GSM DualSIM LD-Agro (prin intermediul rețelei GSM se recepționează semnalele NTRIP RTK și astfel acoperirea poate să joace un rol însemnat în precizia efectuării activităților. De aceea, în anumite țări, poate fi justificată folosirea unui modem DualSIM cu cartele SIM prin abonare la doi furnizori de servicii GSM diferiți), stație de bază RTK GeoAce (pentru deservirea unui număr la alegere de utilaje și vehicule), modem GSM LD-Agro (pentru a realiza o conexiune între furnizorul de semnale RTK și un vehicul în mișcare. Transferul datelor se realizează prin intermediul unei rețele GSM (fiecare modem are o cartelă SIM cu abonament GSM pentru traficul de date).

Ca și avantajele, această tehnologie are acoperire vastă la nivel mondial, număr mare de operatori, echipamente fiabile, cost mic pentru transferul datelor, etc.

Principalele dezavantaje sunt date de un consum relativ mare de energie, viteză redusă de transmitere, comunicare mai solicitantă cu alte module. Pentru a reduce din dezavantajele acestui sistem a fost licențiată de către 3GPP o versiune extinsă GSM IoT (EC-GSM-IoT - tehnologie de zonă largă de putere redusă). Acesta este conceput ca un sistem celular de mare capacitate, cu rază lungă de acțiune, cu consum redus de energie și cu complexitate scăzută, pentru a susține IoT și poate fi implementat făcând un upgrade software la rețelele existente GSM, asigurând astfel acoperirea pe scară largă. Dispozitivele conectate la EC-GSM-IoT pot avea o durată de viață a bateriilor de până la 10 ani într-o gamă largă de cazuri de utilizare [7].

LTE (Long Term Evolution)

Dispozitivele IoT care funcționează pe Cat-M1/LTE-M presupun costuri scăzute, consum mic de energie, acoperire extinsă, conexiuni masive și o platformă solidă pentru transmitere. În combinație cu acoperirea LTE deja existentă și capacitățile comunicațiilor audio, operatorii pot lansa o gamă largă de aplicații legate de SmartCity, logistică, medicină, transport, minerit, agricultură, etc. Tehnologia Cat-M1/LTE-M joacă un rol important la nivel global deoarece oferă o combinație unică de acoperire îmbunătățită, durata de viață a bateriei și conectivitate rapidă și sigură pentru o nouă generație de aplicații și servicii IoT. Cat-M1/LTE-M permite VoLTE să fie lansat în bandă largă cu o eficientizare a costurilor [8].

Totuși, deși avantajele acestei tehnologii se referă la viteză mare de transfer, construirea și implementarea rapidă a rețelei, transferul de date în roaming gratuit în cadrul UE, tehnologie fiabilă, ca și dezavantaje există consum mare de energie și prețul extrem de ridicat al modulelor funcționale. În industria agricolă senzorii utilizați cu tehnologia LTE-M pot transporta direct agriculturilor informații vitale legate de temperatură, umiditate, presiunea aerului și alte date, fără a fi nevoie să se conecteze la un dispozitiv separat pentru a funcționa ca o interfață. Senzorii capacitivi LTE-M sunt capabili să transmită date pe distanțe mai mari [9].

Lora / LoRaWAN

LoRa (Long Range Wireless Network) este o tehnologie dezvoltată de către producătorul de chip-uri Semtech și transmite în spectrul sub-GHz (109MHz, 433MHz, 866MHz, 915MHz), bandă nelicențiată. Această tehnologie are o interferență mai redusă decât altele (cum ar fi gama de 2,4GHz utilizată de Wi-Fi, Bluetooth și alte protocoale). La aceste frecvențe, semnalele pătrund prin obstacole și parcurg distanțe lungi, solicitând relativ puțină putere – ideal pentru multe dispozitive, care sunt în IoT, adesea constrânse de viața bateriei. Deoarece utilizează un chip Semtech, LoRa nu se consideră un standard deschis [10].

LoRa este o rețea ce transmite până la 15-20 km distanță. Compromisul pentru o distanță atât de mare se regăsește în puterea micșorată și rata de bit mult mai mică (de la 0.3 kbps până la 50 kbps). Frecvența aleasă este 868 MHz în Europa și se utilizează o modulație cu spectru larg, transmițând pe canale între 7 și 500 KHz. Este o tehnologie gândită pentru dispozitive ce uneori nu au alimentare, iar frecvența și banda reduse fac ca un eventual dispozitiv LoRa să poată rezista luni de zile cu aceeași baterie. Aceste dispozitive stabilesc din când în când legătura cu un gateway și verifică dacă au primit între timp vreo comandă sau transmit mai departe informațiile trimise ceea ce asigură o autonomie mai mare a bateriei [11].

LoRaWAN permite comunicația prin intermediul unor frecvențe radio care nu necesită licențiere (sub pragul Gigahertz) 169 MHz, 433 MHz, 868 MHz (Europa) și 915 MHz (America de Nord). LoRaWAN specifică protocolul de comunicare și arhitectura de rețea Low Power Wide Area Network (LPWAN) pentru sistemul IoT. Oferă un sistem de comunicație de tip dispozitiv-portal-

server. Portalul comunică cu serverul printr-o conexiune IP standard, iar utilizatorul final folosește o comunicație wireless single-hop cu portalul. Comunicația cu utilizatorul final este, de obicei, bidirecțională. Arhitectura în stea este cea mai utilizată deoarece oferă o mai lungă durată de viață a bateriei. Extinderea duratei de viață a bateriei și a dispozitivului final, precum și maximizarea capacității totale a rețelei se poate asigura printr-un server de rețea care să gestioneze transferul datelor și un canal RF separat pentru fiecare dispozitiv prin Adaptive Data Rate Scheme (ADR). Pentru transfer folosește o bandă de frecvență de 868MHz, iar viteza datelor variază între 0.25 kb/s și 50 kb/s. Punctul final are atribuit un identificator unic de 64-biți și două chei pe 128-biți criptate de AES. Ca și avantaje, se pot enunța consum scăzut, rază de acțiune mare, standard internațional, existența operatorilor publici, iar ca și dezavantaje această tehnologie are costul mare suportat de operatori pentru transferul datelor și setări complicate de parametri [12].

2.2 Specificații NGI pentru agricultura de precizie

2.2.1 NGI: generalități, cazuri de utilizare

Noua generație de Internet (Next Generation Internet - NGI) este o inițiativă a Comisiei Europene care își propune să modeleze dezvoltarea și evoluția Internetului într-un Internet al oamenilor (*Internet of Humans*) care răspunde nevoilor fundamentale ale oamenilor, inclusiv încredere, securitate și incluziune, reflectând în același timp valorile și normele de care se bucură toți cetățenii în Europa [13]. NGI este un program ambițios de cercetare și inovare, cu o investiție inițială a CE de peste 250 milioane EUR între 2018 și 2020 și face parte din Horizon Europe Programme (2021-2027) [13].

Scopul NGI constă în dezvoltarea și adoptarea progresivă a tehnologiilor, conceptelor și metodologiilor avansate care să contribuie ulterior la transformarea viitorului Internet într-o perspectivă mai umană, în special în perioade de criză. Accentul este plasat pe tehnologii avansate, inclusiv confidențialitate și încredere, căutare și descoperire, arhitecturi descentralizate, blockchain, IoT, social media, tehnologii interactive, precum și tehnologii care susțin multilingvismul și accesibilitatea.

Rețelele inteligente în contextul NGI necesită soluții și inovații suplimentare pentru automatizarea rețelei optice dincolo de simpla programabilitate. Acoperirea globală, serviciile locale optimizate și capabilitățile trebuie combinate în moduri extrem de flexibile și concentrate și ar trebui să fie disponibile la cerere pentru lanțurile valorice ale software-urilor web și ale platformelor IoT [14]. În plus, întrucât multe tendințe de cercetare iau deja în considerare implementarea Edge Computing în VM (mașini virtuale), ar trebui luate în considerare soluții mai ușoare pentru micro servicii, de ex prin integrarea mai bună a *mobile edge computing* (MEC) cu conceptul *fog*. Factorii determinanți ai evoluției către NGI sunt reprezentați de creșterea numărului și a eterogenității dispozitivelor și nevoia continuă de a face față problemelor legate de securitate și confidențialitate. Implementarea mai multor dispozitive (vehicule, drone, portabile, camere, roboți, obiecte inteligente, etc.) conduce la necesitatea conectării acestora într-un mediu integrat *mobile edge computing* (MEC) / *fog*. Pe de altă parte, definirea soluțiilor avansate pentru securitate și confidențialitate va fi necesară în continuu, deoarece o cantitate imensă de date va fi transferată în sistemele de comunicații cu un nivel de complexitate mereu în creștere.

Dincolo de elementele de bază cunoscute ale tehnologiilor de bază (precum blockchain), problemele legate de „evolutivitate”, interoperabilitatea, partajarea între numeroase inițiative private / publice sunt specifice TIC. Rețelele sunt, în mod intrinsec, end-to-end, iar NGI trebuie să ofere soluții operaționale sub constrângeri care provin de la această limită transversală, adesea mai dificilă decât aplicația independentă over-the-top sau verticală [14].

Aplicabilitatea tehnologiilor NGI sunt legate de funcționalitățile IoT, iar un studiu indică faptul că, atunci când respondenții au fost întrebați în legătură cu domeniile de aplicabilitate ale IoT, preferințele au fost [15]:

- 35% - *Smart Cities* (și *Communities*);
- 28% - *Health*;
- 19% - *Energy*;
- 15% - ***Agriculture***;
- 15% - *Industry*;
- 13% - *Transportation*;
- 12% - *Environment*.

Ca și domeniile transversale ale aplicațiilor IoT, distribuția aproximativă a priorităților a fost [15]:

- 34% - *Smart Cities* (și *Communities*);
- 21% - *Health*;
- 19% - *Transportation*;
- 11% - ***Agriculture***;
- 10% - *Environment*;
- 10% - *Mobility*;
- 8% - *Buildings*.

Există numeroase domenii în care există oportunități pentru cea mai bună exploatare a tehnologiilor IoT dintr-o perspectivă economică, iar agricultura inteligentă se încadrează în această categorie deoarece tehnologiile IoT permit controlul picăturilor, monitorizarea la distanță a animalelor, colectarea de date despre sol, culturi și reducerea intervenției umane (și, prin urmare, a costurilor forței de muncă) în favoarea automatizării [15].

2.2.2 NGI în agricultura de precizie

Provocările aduse de conceptul NGI constau în proiectarea și construirea de tehnologii accesibile, dezvoltarea și implementarea sistemelor, de a crea oportunități luând în considerare incertitudinile crescânde și comportamentele sistemice emergente în care oamenii și mașinile cooperează perfect. Agricultura de precizie cu tractoare autonome, drone de sondare și dispozitive de monitorizare a stării de sănătate a animalelor, poate fi considerată o rețea H2M (Human to Machine) [16].

Agricultura urmează să se transforme dramatic în următorii ani: automatizarea, AI, învățarea automată și conceptul *edge computing* duc la apariția de noi oportunități în vederea creșterii eficienței și sporirii productivității - atât pe teren, cât și în afara acestuia. Soluții precum tractoare semi-autonome, instrumente inteligente pentru pulverizarea îngrășamintelor și algoritmi de arat sunt dezvoltate nu numai pentru a economisi timpul fermierilor, ci și pentru a crește semnificativ producția [17].

Unul dintre marile proiecte internaționale axate pe integrarea NGI în agricultura de precizie este IntelliIoT (una dintre cele șase acțiuni de cercetare și inovare (RIA) lansate de Comisia Europeană în 2020). Scopul acestei inițiative este de a permite aplicații IoT semi-autonome pentru sisteme compatibile cu AI, depășind limitele IoT-ului tradițional centrat pe Cloud, cum ar fi conectivitatea nesigură și/sau problemele legate de confidențialitate [17]. Domeniul agricol se confruntă cu multe situații periculoase și, din păcate, se produc multe accidente mortale în cazul în care sunt implicate vehicule agricole. IntelliIoT încorporează factorul uman în mediul inteligent IoT al unui vehicul agricol semi-autonom în colaborare cu alte dispozitive, cum ar fi dronele, pentru a îmbunătăți siguranța, fiabilitatea și securitatea. Intervenția umană este necesară în situații incerte (de exemplu, animale pe drum, praf sau alte particule). În mediul inteligent IoT, un operator uman preia controlul

de la distanță al vehiculului și, prin urmare, rafinează modelele AI. Acest rol poate fi luat de fermier sau chiar de un furnizor de servicii la distanță atunci când se lucrează în celule cu acoperire 5G. Tehnologiile VR sunt folosite pentru a afișa un flux live de 360° din vehicul. Infrastructura IoT / edge și de rețea va permite o operare sigură și sigură [18].

Un sistem ce integrează tehnologiile NGI pentru agricultura de precizie este detaliat în [19]. Autorii propun testarea sistemului la o fermă pilot reală situată în Santomera (Spania), mediu în care sunt implementate mai multe dispozitive IoT în diferite locațiile. Platforma agricolă creată este bazată pe date pentru irigarea precisă a culturilor și creează acțiuni automate cu privire la datele colectate de pe dispozitivele IoT. Soluția implementată permite derivarea cheilor de acreditare între un dispozitiv IoT limitat și un controler IoT extern pentru a crea canale sigure pentru protejarea schimbului de date M2M. Dispozitivele reale sunt conectate prin module NB-IoT pentru o rețea 4G și o infrastructură AAA (Authentication, Authorization, and Accounting). Rezultatele demonstrează că LO-CoAP-EAP (Low-Overhead CoAP-EAP) este o soluție fezabilă și eficientă pentru a fi utilizată în rețelele NB-IoT și viitoare 5G pentru a permite autentificarea secundară și asocierea d.p.d.v. al securității dispozitivelor IoT limitate.

2.3 Sistem de telemetrie pentru agricultura de precizie

2.3.1 Parametrii de interes pentru un sistem de telemetrie pentru agricultura de precizie

Pe lângă componentele și activitățile legate de sol care trebuie luate în considerare în agricultura de precizie, aspectele meteorologice au o influență semnificativă nu numai asupra productivității și randamentului, ci și asupra etapelor obligatorii legate de dezvoltarea și managementul culturilor. Parametrii relevanți de sol și vreme pentru dezvoltarea culturilor și influența lor asupra sănătății culturilor sunt prezentați în Tabelul 2.

Tabelul 2 - Parametrii relevanți de sol și vreme în agricultura de precizie

PARAMETRII DE BAZĂ	ROL	BOLI ASOCIATE	
UMIDITATEA SOLULUI	Umiditatea solului este cel mai important factor pentru creșterea plantelor	<ul style="list-style-type: none"> • Umiditate ridicată a solului: Infecția cu sclerotinia sclerotiorum și dezvoltarea bolii la salată verde. • Ralstonia solanacearum la tomate. • Secetă cu umiditate scăzută a solului: Magnaporthe oryzae în orez. 	[20],[21],[22]
TEMPERATURA AERULUI	Factorul cheie în creșterea și dezvoltarea plantelor	<ul style="list-style-type: none"> • Modificări ale timpului de începere a înfloririi ghimbirului alpin Roscoea. • Ferrugem_Branca în cultura de porumb. • Ofilirea culturii de trestie de zahăr. 	[23],[24],[25],[26]
UMIDITATEA AERULUI	Influență directă asupra creșterii frunzelor, fotosintezei, polenizării și apariției bolilor.	<ul style="list-style-type: none"> • Botrytis cinerea în culturi horticole proaspete (condiții umede și umede). 	[27]
RADIAȚIE SOLARĂ	Util în toate etapele dezvoltării culturilor începând de la germinarea semințelor până la înflorire / fructificare	<ul style="list-style-type: none"> • Întârzierea începerii înfloririi (de exemplu, timpul de deschidere a florii în culturile de cereale). • Boli fungice (mucegaiul pufos). • Rugina de soia. • Ferrugem_Branca în cultura de porumb. 	[25],[28],[29],[30]
PRECIPITAȚII	Influență în răspândirea agenților patogeni.	<ul style="list-style-type: none"> • Boli fungice în producția de struguri (putregaiul negru, teleomorf, 	[31],[32],[33]

	dăunătorilor și a altor boli la plante, ducând la culturi bolnave masive	petele frunzelor și putregaiul fructelor, fâinare, mucegai).	
--	--	--	--

2.3.2 Caracteristicile unei rețele 5G pentru sistemul de telemetrie pentru agricultura de precizie

Europa joacă un rol major în dezvoltarea tehnologiei 5G, exploatându-și astfel poziționarea pentru a influența viitorul infrastructurilor IoT, ceea ce reprezintă o oportunitate cheie pentru câștigarea poziției de leadership global. S-a calculat că, în 2019, aprox. 45% din proiectele Smart City au fost realizate în Uniunea Europeană, bani cheltuiți în cercetare și standarde 5G care conduc domeniului precum comunicațiile IoT și Machine-to-Machine (M2M). În dezvoltarea proiectelor din mai multe domenii convergente s-a stabilit că, în majoritatea cazurilor, specificațiile 5G îndeplinesc cerințele pentru implementarea cu succes a soluțiilor în Smart Mobility, Smart City, Smart Energy, Smart Agriculture, Smart Manufacturing și Verticale Smart Health. În plus, securitatea cibernetică și confidențialitatea rămân două dintre principalele preocupări pentru Europa în acest domeniu [15].

În agricultura de precizie, prioritățile au în vedere fiabilitatea, costul scăzut, sustenabilitatea și utilizarea rețelelor scalabile de senzori wireless. În plus, tehnologia IoT ajută la luarea deciziilor în timp real. O importanță deosebită în implementarea tehnologiilor 5G pentru agricultura inteligentă o are dezvoltarea tehnologiilor și modelelor IoT Data Sharing and Monetisation. Toate aceste viziuni legate de implementarea 5G în agricultura de precizie au la bază faptul că adoptarea tehnologiei IoT în Smart Farming este încă limitată, în sensul că nu sunt foarte clar stabilite avantajele d.p.d.v. al costurilor pentru infrastructură vs beneficii. De aceea, diverse metode de predicție bazate pe datele IoT pot juca un rol determinant. Acești algoritmi de predicție/aceste metode de predicție necesită baze de date mari pentru implementare și astfel, sunt necesare stimulente pentru a face ca astfel de date să fie disponibile [15].

Deoarece tehnologia 5G permite agregarea datelor, fermele industriale mari pot încorpora mai bine analize predictive. Având în vedere datele trecute și prezente despre condiții (de ex., umiditatea solului și utilizarea pesticidelor), programul software de analiză creează modele și predicții pentru a ajuta fermierii să ia decizii. Deoarece 5G permite date mai dense în timp real, analiza va deveni mai precisă, maximizând producția și eficiența fermei [34].

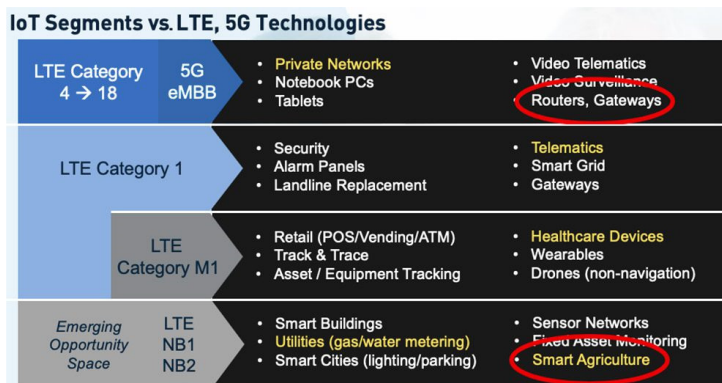


Fig. 1 – Evoluția variantelor LTE spre 5G [34]

Tehnologia 5G oferă un potențial mare pentru agricultură (Fig.1). Multe ferme, al căror acces la fibra optică este prea scump, vor primi o conexiune la Internet în bandă largă prin 5G. Mașinile și instalațiile din grajduri și pe câmpuri din orice locație pot fi integrate într-o rețea agricolă. De exemplu, un antreprenor își poate opera propria flotă de mașini într-o rețea separată, ceea ce face întreaga instalare și întreținere a mașinilor mult mai ușoară. Prin intermediul rețelei 5G, mașinile

rămân conectate în rețeaua fermei, chiar dacă funcționează în afara fermei. O gamă largă de noi tehnologii (controlul irigațiilor și al buruienilor, senzori pentru animale și vehicule autonome) beneficiază de transmisia rapidă a datelor. Ele vor fi, fără îndoială, importante pentru a face producția agricolă mai eficientă și mai durabilă cu scopul de a face față provocărilor majore actuale [35]. Pentru agricultura de precizie, tehnologia 5G poate oferi comunicații în timp real, de mare viteză, între senzori și dispozitive, incluzând [36]:

- **Acces la o conectivitate mai bună/mare și mai multe posibilități:** fermierii pot implementa o suită largă de tehnologii capabile să funcționeze în tandem, cum ar fi aplicații mobile, echipamente automate, drone, senzori și transmisie de date.

- **Comunicație bidirecțională mai rapidă și operațiuni în teren mai precise** prin partajarea datelor mai rapid și mai eficient. 5G Rural First a lansat aplicația pentru smartphone Me + Moo în martie anul trecut, care permite fermierilor să urmărească vacile echipate cu gulere IoT și senzori de picioare și să primească actualizări privind starea și comportamentul lor. Aceste date oferă fermierilor informații importante pe care să le transmită beneficiarilor și îi țin bine informați cu privire la potențialele probleme de sănătate din fermă.

- **Abilitatea de a lua decizii mai rapide și mai bune,** îmbunătățind în același timp performanța dispozitivelor, pentru o productivitate, eficiență și randamente mai mari. În China, Huawei Technologies a anunțat un parteneriat cu XAG (producător de drone agricole), pentru implementarea unui proiect agricol inteligent în vederea testării 5G, inteligenței artificiale și cloud computing în agricultură. Se urmăresc optimizarea performanței și eficiența dispozitivelor agricole inteligente, prin capacitatea tehnologiei 5G de a transmite și prelucra datele, precum și de a îmbunătăți precizia de control a dronelor și a roboților. În altă parte a regiunii, și Malaezia urmărește utilizarea 5G pentru o agricultură de precizie mai bună.

Un caz de utilizare cu succes a tehnologiei 5G în Spania (pentru agricultura de precizie) este detaliat în [37]. Cercetătorii fac referire la utilizarea AGV-urilor în acest framework pentru inspectarea infrastructurilor cu acces dificil, întreținerea la distanță a instalațiilor sau supravegherea și gestionarea situațiilor de urgență sau, de asemenea, utilizarea diferitelor tipuri de senzori și dispozitive IoT pentru îmbunătățirea productivității și întreținerea infrastructurilor.

3 PROIECTAREA ȘI TESTAREA PRELIMINARĂ A UNEI PLATFORME NGI 5G FOLOSIND WSN ȘI UAV PENTRU AGRICULTURA DE PRECIZIE

Luând în considerare activitatea de cercetare fundamentală desfășurată în etapa 1 a proiectului, în etapa 2 activitățile prevăzute implică dezvoltarea și testarea preliminară a sistemului NGI-UAV-AGRO care să întrunească dezideratele enunțate anterior. Activitățile se referă la proiectarea și testarea preliminară a platformei NGI 5G folosind rețele de senzori specifici agriculturii de precizie, precum și la incorporarea UAV-urilor în cadrul sistemului global cu scopul de a colecta imagini ce urmează să fie ulterior prelucrate, contribuind astfel la îndeplinirea obiectivelor specifice și globale ale sistemului.

3.1 Proiectarea și testarea preliminară a unei platforme NGI 5G folosind WSN

Proiectarea arhitecturii generale a sistemului de telemetrie NGI-UAV-AGRO cu funcții de autodiagnosticare și autoconfigurare pentru agricultura inteligentă are la bază prototipul de arhitectură prezentat în Fig.2.

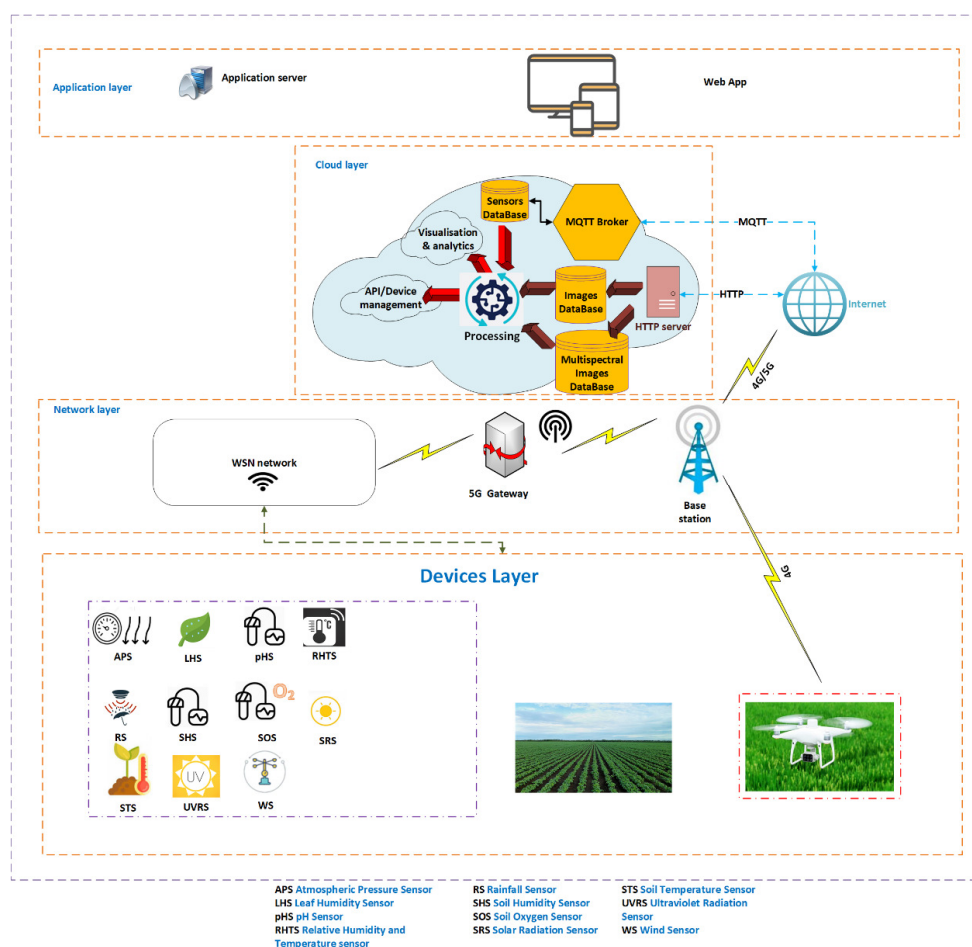


Fig. 2 – Protopi arhitectură platformă NGI-UAV-AGRO

Arhitectura NGI-UAV-AGRO dorește să ofere cadrul tehnologic adecvat pentru conceperea sistemelor complexe bazate pe IoT (incluzând elementele NGI 5G), folosind o abordare bazată pe servicii și punând accentul pe tehnologiile de automatizare și digitalizare, urmărind, simultan, respectarea unor cerințe stricte legate de flexibilitate, sustenabilitate, eficiență și competitivitate. Caracterul modular al arhitecturii este ilustrat de nivelele pe care aceasta este împărțită, după cum urmează:

- **Nivelul Dispozitive.** Acest nivel cuprinde dispozitivele și unitățile de achiziție, precum senzorii și platformele de dezvoltare. Astfel, nivelul cuprinde senzorii utilizați în agricultura de precizie. Dintre aceștia, se pot enumera: senzorii de temperatură a aerului și, respectiv, a solului, senzorul de umiditate a aerului, senzorul de permitivitate dielectrică a solului, senzorul de oxigen din sol. Tot la acest nivel, se încadrează și UAV.

- **Nivelul Rețea.** Acest nivel include rețeaua pe distanță scurtă (pentru nodurile de senzori din cadrul aceluiași WSN) și rețeaua pe distanțe lungi (pentru comunicația dintre nodurile centrale și poarta de acces). În plus, nivelul Rețea cuprinde mediile de comunicație și protocoalele de comunicație. Componenta inovativă propusă în cadrul acestui nivel constă în utilizarea UAV ca punct de acces pentru rețelele de senzori wireless care nu se află în aria de acoperire a porții de acces. Nivelul Rețea cuprinde și poarta de acces utilizată pentru a realiza translația dintre protocoalele de comunicații.

La acest nivel, pentru comunicația WSN-UAV-Poartă de acces se pot evidenția mai multe scenarii:

- Scenariul de comunicații pe distanțe scurte (A.I). Nodurile centrale ale WSN sunt apropiate de poarta de acces și se dorește o colectare rapidă și/sau frecventă a datelor. În consecință, este utilizată tehnologia Wi-Fi.
- Scenariul de comunicații pe distanțe scurte (A.II). Sensorii sunt apropiați de poarta de acces/router, dar nu este necesară o colectare rapidă și frecventă a datelor. Astfel, este folosită tehnologia LoRa.
- Scenariul de comunicații pe distanțe lungi (B.I). Sensorii sunt plasați la distanță de poarta de acces (în afara ariei de acoperire a comunicației Wi-Fi) și se dorește o colectare rapidă a datelor. Astfel, UAV se comportă ca un punct de acces, trimițând mai departe datele de la nodurile centrale ale WSN către poarta de acces.
- Scenariul de comunicații pe distanțe lungi (B.II). Sensorii sunt plasați la distanță de poarta de acces (în afara ariei de acoperire a comunicației Wi-Fi), dar nu este necesară o recuperare rapidă sau frecventă a datelor. Astfel, transmisia datelor va fi asigurată de tehnologia LoRa.

Mai departe, datele agregate de poarta de acces sunt transmise prin tehnologia 5G către rețeaua centrală 5G și către serverul platformei propuse.

○ **Nivelul Cloud**. De la poarta de acces, datele sunt trimise către nivelul Cloud prin intermediul protocoalelor de date (HTTP, MQTT). Componentele Nivelului Cloud au următoarele sarcini:

- Găzduirea serverului HTTP pentru preluarea imaginilor de la poarta de acces;
- Găzduirea broker-ului MQTT responsabil pentru preluarea datelor de la poarta de acces;
- Stocarea datelor în baza de date. Aici, sunt stocate datele colectate, împreună cu coordonatele GPS statice ale porții de acces, ale rețelelor de senzori wireless, precum și istoricul coordonatelor GPS ale UAV.
- Vizualizarea și analiza datelor și imaginilor;
- Managementul dispozitivelor.

○ **Nivelul Aplicație**. Pentru a vizualiza datele achiziționate de la dispozitive și rezultatul analizei, este necesară dezvoltarea unei aplicații cu interfață grafică cu utilizatorul.

Sistemul de prelucrare a datelor este compus dintr-un server ce găzduiește pachetele software aferente sistemului de prelucrare a datelor are următoarele capacități (Fig.3):

- CPU: 2 core-uri (vCPU)
- Memorie RAM: 16384 MB
- HDD: 200 GB
- Sistem de operare: Ubuntu 18.04.3 Server
- Software:
 - MQTT broker Mosquitto [38];
 - Agent de server Telegraf [40];
 - Bază de date InfluxDB [41];
 - Tool de vizualizare Grafana [42].

Arhitectura software a sistemului de prelucrare a datelor este format din stiva TIG (Telegraf - InfluxDB - Grafana) și un broker MQTT prin intermediul căruia se recepționează date măsurate de către senzori.

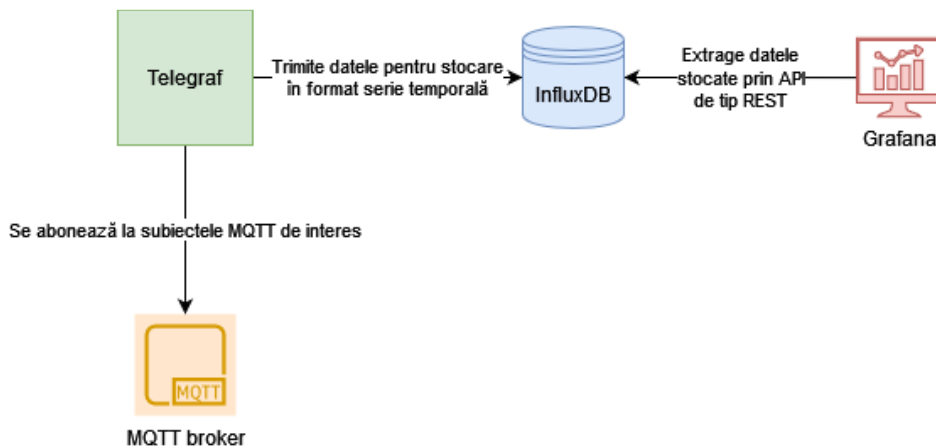


Fig. 3 - Arhitectura software conceptuală a sistemului de prelucrare a datelor

A. Broker MQTT Mosquitto

Eclipse Mosquitto [38] este un broker de mesaje cu sursă deschisă care implementează protocolul MQTT versiunile 5.0, 3.1.1 și 3.1. Mosquitto este ușor și potrivit pentru utilizare pe toate dispozitivele, de la computere de tip *Single Board (SBC)* până la servere puternice.

Proiectul Mosquitto oferă o bibliotecă C pentru implementarea clienților MQTT și clienți MQTT ce pot fi folosiți în linia de comandă *mosquitto_pub* și *mosquitto_sub*.

Se poate instala o instanță a Mosquitto în câteva minute dar, pentru a face testarea și mai ușoară, iar proiectul Mosquitto pune la dispoziție și un server de testare [39] unde clienții pot fi testați într-o varietate de moduri: MQTT simplu, MQTT peste TLS, MQTT peste TLS (cu certificat client), MQTT peste WebSockets și MQTT peste WebSocket cu TLS.

B. Telegraf

Telegraf [40] este un agent de server bazat pe conectori (*plugins*) pentru colectarea și trimiterea de valori și evenimente din baze de date, sisteme și senzori IoT. Este scris în Go și se compilează într-un unic fișier binar fără dependențe externe și necesită o amprentă de memorie foarte minimă.

Sistemul de conectori Telegraf permite adăugarea cu ușurință de noi intrări și ieșiri, cu multe integrări la o varietate de parametri, evenimente și jurnale (*logs*) de la containere și sisteme populare. Se pot extrage valori de la interfețe API terțe sau se pot asculta parametri prin intermediul serviciilor StatsD și Kafka.

Telegraf are, de asemenea, conectori de ieșire pentru a trimite valori către o varietate de alte magazine de date, servicii și cozi de mesaje, inclusiv InfluxDB, Graphite, OpenTSDB, Datadog, Librato, Kafka, MQTT, NSQ și multe altele.

C. InfluxDB

InfluxDB [41] este o bază de date open-source destinată seriilor de date temporale. Aceasta a fost scrisă în limbajul Go și este concepută pentru a susține un volum ridicat de scrieri și interogări, prin implementarea limbajului InfluxQL, asemănător SQL. InfluxQL acceptă expresii regulate, expresii aritmetice și funcții specifice seriei de timp pentru a accelera procesarea datelor și permite efectuarea ecuațiilor matematice simple, ceea ce face calcularea procentelor folosind două câmpuri într-o măsurătoare destul de simplă.

D. Grafana

Grafana [42] este un tablou de bord și un compozitor de grafice care funcționează ca o aplicație web. Grafana permite interogarea, vizualizarea, avertizarea și înțelegerea datelor înregistrate indiferent unde sunt stocate acestea. După conectarea Grafana cu sursa de date, un tablou de bord și un panou pot fi create manual sau există posibilitatea de a importa diverse tablouri de bord. Fiecare sursă de date are un *Editor de interogare* specific care este personalizat pentru caracteristicile și capacitățile pe care le expune respectiva sursă de date.

Limbajul de interogare și capacitățile fiecărei surse de date sunt foarte diferite. Pot fi combinate date din mai multe surse de date pe un singur tablou de bord, dar fiecare panou este legat de o sursă de date specifică care aparține unei anumite organizații. Printre sursele de date acceptate oficial de Grafana, se regăsesc: Prometheus, TimescaleDB, Graphite și InfluxDB

Stiva TIG (Telegraf - InfluxDB - Grafana) poate fi împachetată într-un container de tip docker pentru instalare și deployment rapid.

3.2 Configurarea sistemului de telemetrie cu UAV

În vederea captării imaginii stării culturilor și a solului, în platforma NGI 5G WSN este integrată drona Multirotor DJI Phantom 4 Multispectral [43] (Fig.4). Procesarea imaginilor captate cu UAV are ca și scopuri identificarea posibilelor boli sau riscurilor de apariție a bolilor culturilor și degradarea solului. Drona permite comutarea în timp real între imaginea RGB și o analiză preliminară a indexului de vegetație NDVI, pentru a identifica imediat zonele unde este nevoie de atenție, astfel încât deciziile pot fi luate rapid și pe loc.



Fig. 4 – Drona Multirotor DJI Phantom 4 Multispectral [43]

Printre specificațiile tehnice de interes, se regăsesc:

Tabelul 3 - Specificațiile tehnice de interes pt drona DJI Phantom 4 Multispectral

DJI Phantom 4 Multispectral	
Greutate la decolare	1487 g
Lungime pe diagonală (fără elice)	350 mm
Înălțime zbor maxim deasupra nivelului mării	6000 m
Timp maxim de zbor	Aprox. 27 min
Temperatura de operare	De la 0° la 40° C
Frecvența de operare	2.4000 GHz la 2.4835 GHz (Europa, Japonia, Coreea) 5.725 GHz la 5.850 GHz (Alte țări/regiuni)
Puterea de transmisie (EIRP)	2.4 GHz: < 20 dBm (CE / MIC / KCC) 5.8 GHz: < 26 dBm (FCC / SRRC / NCC)

Precizie staționare (hover)	RTK activ și funcțional: Vertical: ± 0.1 m; Orizontal: ± 0.1 m RTK inactiv: Vertical: ± 0.1 m (cu poziționare vizuală); ± 0.5 m (cu poziționare GNSS) Orizontal: ± 0.3 m (cu poziționare vizuală); ± 1.5 m (cu poziționare GNSS)
Ground Sample Distance (GSD)	(H/18.9) cm/pixel, unde H este înălțimea la care se află dronă față de suprafața observată în metri
Interval controlabil Gimbal	Înclinare: -90° la $+30^\circ$

DJI Phantom 4 Multispectral este echipată cu o camera capabilă să capteze imagini RGB și 5 senzori monocromi pentru imagini multispectrale, toate montate pe un gimbal cu stabilizare în 3 axe. Este ideală pentru o gamă variată de aplicații, dar în special pentru agricultură și managementul vegetației. Acoperă benzile albastru, verde, roșu, red-edge și infraroșu apropiat la o rezoluție de 2 MP.

Tabelul 4 - Specificațiile tehnice cameră a dronei DJI Phantom 4 Multispectral

Camera	
Senzor	Șase camere CMOS 1/2.9", o cameră RGB pentru imagini în spectrul vizibil și cinci senzori monocromi pentru imagini multispectrale. Fiecare: Effective pixels 2.08 MP (2.12 MP in total)
Obiectiv	Câmp vizual (FOV - Field of View): 62.7° Distanță focală: 5.74 mm (35 mm format echivalent: 40 mm), autofocus la ∞ Deschidere: $f/2.2$
Interval ISO - senzor RGB	200 - 800
Dimensiunea maximă a imaginii	1600x1300 (4:3.25)
Format foto	JPEG (vizibil) + TIFF (multispectral)
Fișiere de sistem compatibile	FAT32 (≤ 32 GB); exFAT (> 32 GB)
Temperatura de operare	De la 0° la 40° C

Drona are în componență module dual-compass și unități dual IMU, eficientizând funcționarea, comparativ cu hexacopterele sau octocopterele. Compasul și IMU sunt unii dintre cei mai importanți senzori pe care drona îi are, pentru a își menține cursul de funcționare stabil. Un senzor integrat pentru detectarea luminii solare deasupra dronei înregistrează iradierea solară, care maximizează precizia și consistența colectării datelor în diferite momente ale zilei. Atunci când sunt combinate cu date postprocesate, aceste informații ajută la obținerea celor mai precise rezultate NDVI. De asemenea, UAV-ul DJI este capabil să ajusteze traseul dacă pierde semnalul cu radiocomanda, în așa fel încât să recunoască aceleași obstacole pe care le-a evitat de la decolare. Drona detectează cel mai potrivit loc pentru o aterizare sigură. Dacă întâlnește în drumul ei obstacole sau apă, își înștiințează pilotul și planează la o altitudine permisivă, astfel încât aterizarea să fie fără incidente.

DJI Phantom 4 Multispectral are autonomie de max. 30 min. cu o singura baterie. Aplicația de zbor permite verificarea bateriilor în timp real și calculează în mod automat timpul rămas în funcție de distanță și altitudine. Aplicația va trimite notificări când nivelul de energie dintr-un acumulator se apropie de 0, pentru o aterizare cât mai sigură.

Integrarea UAV în cadrul platformei NGI-UAV-AGRO are în vedere testarea calității și preciziei acesteia, precum și calibrarea și ajustarea parametrilor de captură/înregistrare pentru obținerea unor imagini de o acuratețe adecvată pentru prelucrări ulterioare cu algoritmi specifici.

Figurile 5, 6 și 7 redau imagini captate dintr-o filmare realizată prin deplasarea dronei pe deasupra zonei acoperită cu viță de vie (domeniu deținut de BEIA CONSULT).



Fig. 5 – Imagine captată din înregistrare video cu UAV



Fig. 6 – Imagine captată cu UAV pregătită de procesare (frunze viță de vie)



Fig. 7 – Imagine captată cu UAV (dintr-un set de imagini cu frunze de viță de vie)

3.3 Testarea outdoor a platformei NGI 5G cu WSN și UAV

Pentru testarea outdoor a platformei cu WSN și UAV s-au utilizat, pe lângă anumite componente, dispozitive și echipamente deja existente ca infrastructură, platforma Plug & Sense! SA-

PRO LoRaWAN EU + WiFi, sondele aferente senzorilor dedicați pentru agricultură (temperatură, umiditate și presiune; temperatura solului/apei (Pt-1000), umiditatea solului și a frunzelor), iar platforma a fost echipată cu anemometru + giruetă + pluviometru, iar alimentarea s-a realizat și prin intermediul panourilor solare externe (7V - 500mA). Ca urmare, pentru testarea platformei NGI cuprinzând WSN și UAV se pot pune în evidență trei direcții:

- Evaluarea parametrilor de comunicație dintre WSN și UAV;
- Evaluarea telecomenzilor date de UAV către actuatorile WSN;
- Evaluarea parametrilor agricoli monitorizați de WSN și transmiși către UAV.

În această etapă, s-a abordat prima direcție: evaluarea parametrilor de comunicație dintre WSN și UAV. Pentru exemplificare, s-a realizat comunicația dintre UAV și WSN în mai multe scenarii, rețeaua WSN și UAV fiind conectate prin tehnologia LoRa. Atât UAV, cât și WSN au fost echipate cu platforme de dezvoltare Lopy v4 cu modul de comunicații Semtech SX1272 și microcontroler ESP32. Platforme de dezvoltare au caracteristicile din Tabelul 5.

Tabelul 5 – Caracteristici Lopy v4

Caracteristică	Descriere
Microcontroler	Espressif ESP32-S2/Xtensa
Suport LoRaWAN	Da
Putere de transmisie maximă	14 dBm
Consum putere LoRa, sleep	0.2-1 μ A
Consum putere LoRa, idle	1,5 μ A
Consum putere LoRa, stand-by	1,6-1,8 mA
Consum putere LoRa, mod emițător	28 mA
Alte tehnologii	Sigfox, Bluetooth, Wi-Fi

În plus, WSN a fost echipată cu placă de expansiune Expansion Board v3 pentru alimentarea platformelor de dezvoltare și pentru extinderea capacităților lor (de ex. echiparea cu slot SD). De asemenea, s-a utilizat o placă de expansiune Pytrack v1 pentru alimentarea platformelor de dezvoltare și pentru urmărirea coordonatelor GPS (Pytrack). Placa de expansiune Pytrack v1 este echipată cu modul GPS L76GNSV și sistem de navigație suplimentar GLONASS (cu aprox. 20 de sateliți suplimentari) și accelerometru tri-axial LIS2HH12 cu cuantizare pe 12 b. Consumul său este de aproximativ 8 μ A în modul deep sleep.

Atât rețeaua WSN, cât și emițător-receptorul conectat la UAV sunt dotate cu antene antene LoRa de tip dipol $\lambda/2$ sleeve optimizate pentru frecvența tehnologiei LoRa de 868 MHz. Acestea au un diametru de 7 mm ($0.02 \cdot \lambda/2$) și o lungime de aproximativ 17 cm.

Pentru alimentarea dispozitivelor, s-au utilizat baterii Litiu-Polimer (Li-Po) pentru UAV (3850 mAh) și pentru plăcile de expansiune (1500 mAh) ale WSN și, respectiv, UAV.

Parametrii și câștigul maxim al antenelor pentru modulul de comunicații SX1272 al platformei de dezvoltare Lopy v4 sunt date în Tabelul 6.

Tabelul 6 – Parametrii generali ai modulului de comunicații

Platformă	Modul	Domeniu frecvență	P_{tx}	SF	Gtx,max	Grx,max
Lopy v4	SX1272	137-1020 MHz	14 dBm	6-12	2,15 dBi	2,15 dBi

În Fig. 8 este reprezentată platforma de testare bazată pe UAV, platforma de dezvoltare Lopy și plăcile de expansiune.



Fig. 8 - Platforma de măsurători bazată pe

UAV, module Lopy și placa de expansiune Pytrack pentru monitorizarea coordonatelor GPS

Pentru evaluarea comunicației dintre UAV și WSN, s-au propus următoarele scenarii:

Scenariul	h_{UAV}	$d_{UAV-WSN}$	$h_{TX,WSN}$
1	30 m	0-500 m	1,5 m
2	30-120	5 m	1 m
3	13-120	120 m	

Reprezentarea geometrică a scenariului 1 este redată în Fig. 9.




Fig. 9 - Reprezentarea scenariului pentru $h_{UAV}=30$ m și $d_{UAV-WSN}$ în domeniul 0-500

În acest scenariu, WSN este receptor, iar UAV emițător. În acest scenariu au fost transmise 573 de pachete și au fost recepționate 522, rata de succes a recepției fiind de 91.09%. Puterea semnalului recepționat (RSSI, Received Signal Strength Indicator) de WSN este reprezentată în Fig.10.

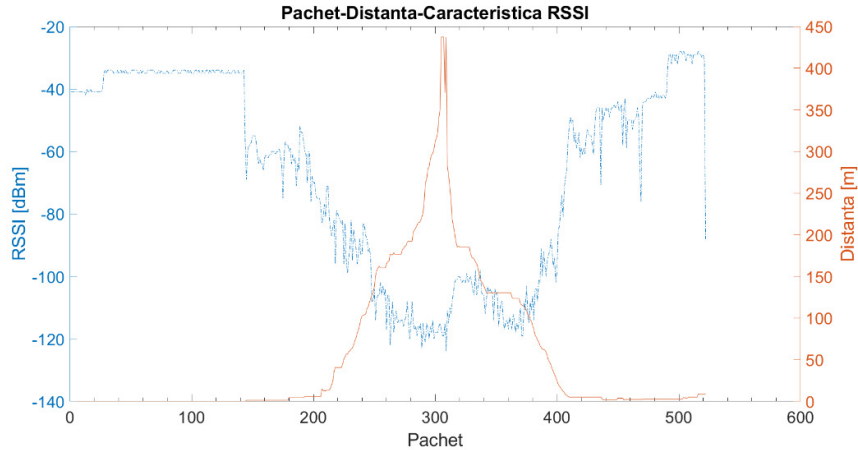


Fig. 10 - Puterea semnalului recepționat de WSN (RSSI) în scenariul 1

Deși experimentele s-au efectuat pe o distanță de 500 m, s-a constatat că distanța maximă la care s-au recepționat pachetele este de 437,175 m. Nivelul de putere minim pentru care s-au putut recepționa pachetele este de -124 dBm, față de -123 dBm menționat în foaia de catalog a modului Lopy v4 pentru factorul de împrăștiere SF=7 și lățimea de bandă BW=125kHz.

În continuare, s-a pus în evidență scenariul 2. Reprezentarea sa geometrică este redată în Fig. 11.




Fig. 11 - Reprezentarea scenariului pentru $h_{UAV}=20-120$ m și $d_{UAV-WSN}$ în domeniul 4-10 m

În cadrul acestui subscenariu au fost transmise 400 de pachete, fiind recepționate cu succes 375 dintre ele, rezultând o rată de succes de 93,75%. Trebuie menționat că trecerea de la un nivel al înălțimii la altul nu se face brusc, ci treptat, cu o viteză medie a dronei pe axa verticală de 0.75 m/s. Întrucât sarcina UAV (containerul în care au fost amplasate componentele platformei de măsurători) se află ancorată de UAV cu un cablu cu lungimea de 1 m și ca urmare a limitării înălțimii UAV față de sol reglementată la 120 m, înălțimea antenei a variat în domeniul 29-119 m.

În Fig. 12 este reprezentată variația puterii semnalului recepționat (RSSI) și rezultatul medierii acestor valori în funcție de domeniul înălțimii.

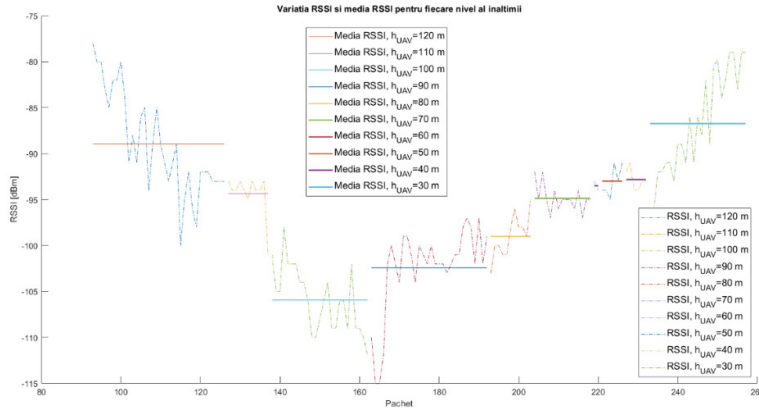


Fig. 12 - Variația puterii semnalului recepționat de WSN pentru Scenariul 2

Se constată o simetrie a graficului în jurul înălțimii de 90 m. În ciuda consumului ridicat de energie pentru ridicarea UAV la înălțimi mai mari de 90 m, efectul acestei acțiuni rezidă în creșterea considerabilă a probabilității de vizibilitate directă și, implicit, a domeniului de acoperire. În acest fel, mai multe WSN plasate în diferite parcele agricole pot fi deservite de același UAV.

În Fig. 13 este reprezentat geometric Scenariul 3.




Fig. 13 - Reprezentarea scenariului pentru $h_{UAV}=5-120$ m și $d_{UAV-WSN}=120$ m

Rezultatelor măsurătorilor experimentale sunt reprezentate în Fig. 14. Puterea recepționată maximă de referință este de aproximativ -60 dBm când UAV se află la distanța de 2 m de WSN, la nivelul solului.

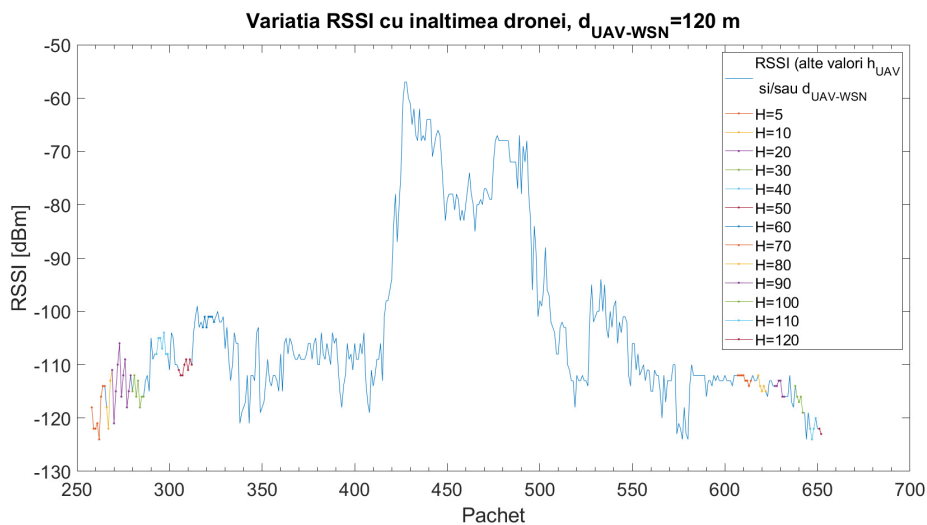


Fig. 14 - Variația RSSI cu înălțimea dronei (UAV)

Din cele trei scenarii în care comunicația UAV-WSN a fost testată în condiții experimentale extrem de defavorabile (reflexii multiple, propagare multicală, difracție) se poate constata că raza maximă de acoperire a fost de 437,15 m pentru înălțimea UAV de 30 m. De asemenea, se observă că acest domeniu de acoperire poate fi îmbunătățit prin creșterea înălțimii UAV.

3.4. Prelucrarea preliminară a datelor și imaginilor obținute cu WSN și UAV prin testări outdoor folosind baze de date complexe și opțiuni de salvare în Cloud

Frunzele de viță de vie pot fi folosite pentru a identifica și diagnostica bolile specifice acestei culturi încă din stadii incipiente. Detecția se poate realiza folosind tehnici de prelucrare de imagini și algoritmi *deep learning*, având ca secvențe de test imagini achiziționate cu UAV. Acuratețea procesului de detecție depinde de claritatea imaginilor testate, dar și de prelucrările aplicate imaginilor testate și de algoritmul de clasificare ales.

În această etapă a proiectului au fost urmărite 4 boli diferite care pot afecta vița de vie:

- *black rot* (putregaiul negru): Putregaiul negru este una dintre cele mai obișnuite boli ale viței de vie și este cauzată de fungi. Frunzele prezintă pete negre de dimensiuni ce pot varia, dar în general mult mai mici față de mărimea frunzei [44]. Acoperă suprafețe întinse de frunze învecinate, astfel încât imaginile preluate de camera UAV de la mică înălțime surprind ușor eșantioane afectate de boală.
- *esca* (sau *black measles* – apoplexia viței de vie): produce, de asemenea, modificări vizibile ale frunzelor viței de vie, fiind astfel o țintă identificabilă de către algoritmi de discriminare vizuală. Esca provoacă pete întinse pe suprafața frunzelor.
- *leaf blight* (Isariopsis leaf spot): leziunile caracteristice pentru *leaf blight* au un aspect neregulat cu diametru 2-25mm, cu pete de la roșu închis la brun care apar la început, urmate apoi de pete negre. Boala afectează ciorchinii de strugure integral.
- *powdery mildew* (făinarea): este una dintre bolile cu cea mai mare răspândire pentru culturile de viță de vie, fiind de asemenea provocată de fungi. Aspectul caracteristic este de pudră albicioasă sau gri care afectează circular zone ale frunzei, fiind un pericol real pentru toate soiurile de viță de vie (struguri de masă sau pentru vinificație).

Toate aceste boli reduc semnificativ cantitatea de fructe recoltată, astfel încât este necesară monitorizarea constantă a culturii. Exemple de frunze afectate de bolile menționate anterior, precum și eșantioane din imagini preluate de camera UAV sunt prezentate în Fig.15.

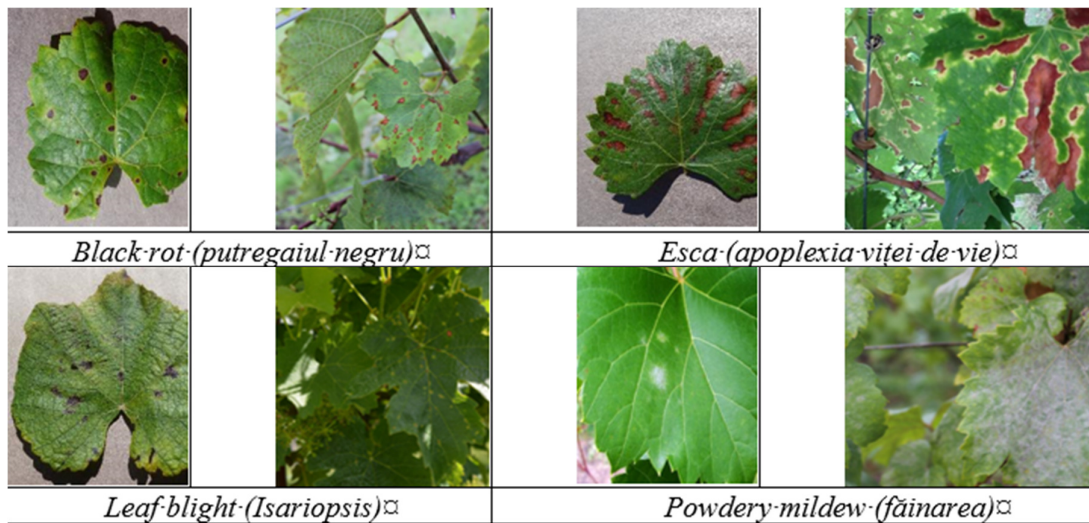


Fig. 15 - Exemple de frunze de viță de vie afectate de cele 4 boli

Pentru fiecare caz a fost dată o imagine de antrenare din baza de date cu imagini utilizată pentru clasificatorii Random forest și SVM, precum și o secțiune din cultura de viță de vie afectată. Seturile de imagini folosite în acest proiect provin din baze de date publice [46], [47] și imagini achiziționate de camera UAV și etichetate cu LabelME [45]. Baza de date a fost augmentată prin tehnicile: oglindire pe orizontală și verticală, rotație, scalări de intensitate, corecție de gamma. Prin augmentare se obține un set mult mai mare de imagini față de setul inițial. Augmentarea a fost necesară deoarece antrenarea unui clasificator necesită o cantitate uriașă de imagini etichetate.

3.4.1 Extragerea vectorilor caracteristici HOG. Descriptorii HOG (Histogram of Oriented Gradients) au fost utilizați frecvent în prelucrările de imagini pentru detecția de obiecte. Ideea fundamentală este aceea de extrage informația despre forma și structura obiectului și de a o transforma apoi într-un descriptor care se poate folosi la antrenarea unui clasificator. Se determină inițial gradientii pe verticală și orizontală, apoi -pe baza lor- se calculează amplitudinea și orientarea gradientului. Amplitudinea gradientului va fi mare în zonele cu schimbări bruște de intensitate (contururile frunzei, marginile petelor), fiind astfel evidențiate doar informațiile esențiale date de contururi. Pentru imagini color, se va lua în considerare valoarea maximă de gradient pentru fiecare canal de culoare în parte. Exemple de gradienti orientați se pot observa în Fig.16.



Fig. 16 - Gradienti orientați utilizați în construirea descriptorului HOG

Imaginea se împarte în celule de 8x8 pixeli și se determină o histogramă cu 9 bini pentru fiecare celulă. Cei 9 bini corespund gradientilor orientați cu unghiuri de 0°, 20°, 40°, ... 160°. Pentru blocuri de 16x16 pixeli, așadar câte 4 celule învecinate, se va aplica o normare, iar cele 4 histograme se concatenează pentru a forma un vector de 36 de elemente. Prin normare, descriptorul HOG devine independent de variațiile de iluminare. Blocurile de 16x16 pixeli se aleg astfel încât să se suprapună pe jumătate între ele, iar vectorii de 36 de elemente din toate blocurile, normați din nou și concatenați, vor forma descriptorul caracteristic HOG. Acest descriptor codează informația esențială despre structura obiectului din imagine. A

Din punctul de vedere al algoritmilor de prelucrare, atât Random Forest, cât și SVM folosesc descriptorii HOG pentru clasificare.

- **Random forest** este unul dintre algoritmii fundamentali utilizați pentru clasificare. Acesta se bazează pe o colecție extinsă de arbori de decizie care funcționează împreună ca un ansamblu. Fiecare arbore de decizie individual oferă o predicție de clasă, iar clasa cu cele mai multe voturi va constitui predicția modelului. Conceptul fundamental care stă la baza *random forest* este acela de "înțelepciune a maselor". Practic, se dorește ca predicțiile arborilor de decizie să fie slab corelate între ele. Modelele de decizie necorelate între ele vor produce predicții de ansamblu mult mai corecte decât predicțiile individuale (singulare). Unii arbori de decizie pot estima greșit, însă pe lângă aceștia, mulți alți arbori vor predicționa corect, astfel încât per ansamblu grupul de arbori să avanseze către un rezultat favorabil (o predicție bună).

- **Support Vector Machine (SVM)** constituie o metodă de clasificare care folosește setul de date de antrenare pentru a reprezenta o margine de decizie. Algoritmul identifică un hiperplan într-un spațiu M -direcțional care izolează punctele conform claselor din care fac parte. Dimensiunea M a spațiului este dată de numărul de clase. Datele de antrenare sunt vectori caracteristici HOG. Antrenarea în sine presupune identificarea hiperplanului sau a marginii de decizie. Distanțele de la o margine de decizie până la fiecare punct din spațiu (fiecare vector caracteristic aparținând unei clase din setul de antrenare) se numesc *vectori suport*. Hiperplanul care conduce la cei mai mari vectori suport va fi considerat optim. Alegerea marginii de decizie este un compromis între a obține cei mai mari vectori suport și clasificarea corectă a majorității datelor de antrenare. Cum datele de antrenare conțin aproape întotdeauna și valori singulare (extreme) greu de clasificat corect, SVM permite ca acele puține valori extreme să fie clasificate eronat, în schimbul unui hiperplan optim ce clasifică corect majoritatea datelor de antrenare.

3.4.2 Rezultate experimentale

În scenariile de tip învățare supervizată se folosesc în mod uzual matrici de confuzie pentru a pune în evidență performanța unui anumit algoritm. Analizând matricea de confuzie se poate vedea cât de bine funcționează algoritmul pentru o clasă la alegere. Clasele în acest caz sunt date de cele 4 categorii de boli prezentate anterior, cărora li se adaugă o a cincea clasă a frunzelor sănătoase. Matricile de confuzie permit așadar evaluarea performanțelor pentru modele de clasificatori, arătând efectiv câte predicții au fost corecte și câte au fost greșite. Se poate vedea de asemenea pentru ce clasă modelul a dat rezultate foarte bune și pentru care clasă a predicționat complet eronat. Pornind de la matricea de confuzie, se pot ulterior determina toate metricile de evaluare a unui clasificator: acuratețe, precizie, recall, scorul f1. În Fig.17 se poate vedea matricea de confuzie pentru clasificatorul *random forest*, alături de scorul pentru acuratețe. Se observă că cele mai bune predicții se obțin pentru *leafblight*, în vreme ce performanțele cele mai slabe se înregistrează pentru *esca*.

True label	blackrot	268 80.72%	42 12.65%	14 4.22%	7 2.11%	1 0.30%
	esca	134 36.61%	205 56.01%	8 2.19%	5 1.37%	14 3.83%
	healthy	7 6.19%	1 0.88%	89 78.76%	13 11.50%	3 2.65%
	leafblight	24 9.84%	8 3.28%	9 3.69%	203 83.20%	0 0.00%
	pmildew	4 5.48%	6 8.22%	5 6.85%	1 1.37%	57 78.08%
		blackrot	esca	healthy	leafblight	pmildew
		Predicted label				

Fig.17- Matricea de confuzie obținută în urma simulărilor pentru algoritmul de clasificare Random Forest

Etichetele "True label" din matricea de confuzie indică clasele din care fac parte imaginile testate. Aceste etichete fie erau pre-existente în bazele de date publice utilizate, fie au fost adnotate manual cu LabelMe pentru imaginile de test de la camera UAV. Etichetele "Predicted label" sunt cele estimate de către algoritmul de clasificare.

Întrucât Fig. 17 indică o rată de variație importantă a performanțelor de predicție de la o clasă la alta, s-au determinat și curbele ROC (Receiver Operating Characteristic Curves) pentru Random Forest, ilustrate în Fig. 18. Aceste curbe arată performanța de clasificare a modelului pentru toate pragurile de clasificare. Pe abscisă este parametrul FPR (False Positive Rate) definit ca $FPR = \frac{FP}{FP+TN}$. Pe ordonată este rata TPR (True Positive Rate), uneori denumită și rata de reamintire (recall), $TPR = \frac{TP}{TP+FN}$, unde TP, TN, FP, FN reprezintă numărul de eșantioane pentru "True Positive", "True Negative", "False Positive" și "False Negative" și ale căror valori se extrag din matricea de confuzie.

Praguri de clasificare mai mici conduc la mai multe clasificări ca pozitive, astfel încât crește TP și FP.

Parametrul AUC (Area Under the ROC curve) este -de asemenea- trecut pe grafic și reprezintă aria de sub fiecare grafic. AUC poate fi privit și ca o probabilitate a modelului, variază între 0 și 1, și cu cât valoarea sa este mai aproape de 1, cu atât performanțele de clasificare cresc.

Se remarcă, așadar, din Fig. 18 că Random Forest nu atinge aceleași performanțe de clasificare pentru toate cele 5 clase, ceea ce constituie un dezavantaj.

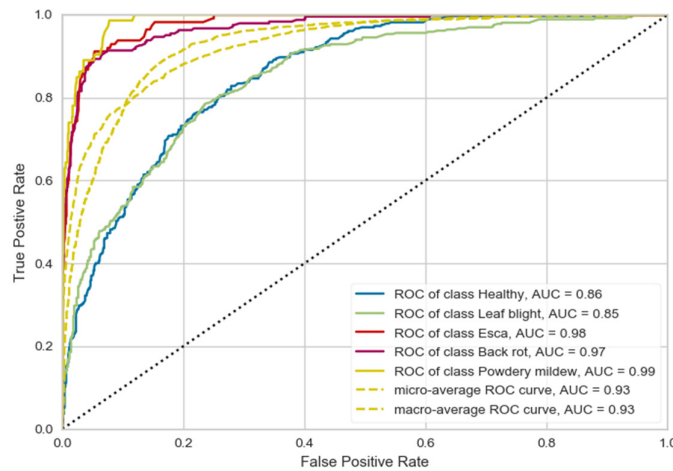


Fig. 18 - Caracteristicile ROC pentru Random Forest

În Fig. 19 este prezentată matricea de confuzie pentru algoritmul de clasificare SVM. Comparând această matrice cu cea obținută anterior pentru Random Forest, se observă că procentele de estimări corecte de pe diagonala principală, pentru fiecare dintre cele 5 clase, sunt net îmbunătățite. Pentru Esca și Black rot, estimările reciproce de FP (False positive) au scăzut considerabil, de la 13% și 36% cât erau pentru Random Forest, la maxim 14% ambele (sunt vizibile cu portocaliu în imediata vecinătate a diagonalei principale, stânga sus în Fig. 19). De asemenea, variațiile între performanțele de predicție per clasă sunt mult reduse la SVM, ceea ce înseamnă că algoritmul de clasificare atinge performanțe similare pentru toate cele 5 clase.

True label \ Predicted label	blackrot	esca	healthy	leafblight	pmildew
blackrot	279 84.04%	40 12.05%	5 1.51%	7 2.11%	1 0.30%
esca	49 13.39%	298 81.42%	3 0.82%	4 1.09%	12 3.28%
healthy	2 1.77%	1 0.88%	103 91.15%	5 4.42%	2 1.77%
leafblight	2 0.82%	9 3.69%	7 2.87%	226 92.62%	0 0.00%
pmildew	4 5.48%	3 4.11%	4 5.48%	0 0.00%	62 84.93%

Fig. 19 - Matricea de confuzie obținută în urma simulărilor pentru algoritmul de clasificare SVM

Acuratețea rezultatelor obținute cu cei doi clasificatori, Random Forest și SVM, se poate evalua comparativ pornind de la următoarea formulă:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}$$

unde TP, TN, FP, FN reprezintă numărul de eșantioane pentru "True Positive", "True Negative", "False Positive" și "False Negative". Valorile acestora s-au extras din matricile de confuzie aferente fiecărui algoritm. TP este numărul de predicții corecte pentru o clasă, valorile regăsindu-se pe diagonala principală a matricilor de confuzie. TN reprezintă numărul de predicții negative pentru o clasă (imagini predicționate corect ca neapartinând unei clase). În mod similar se vor defini FP și FN ca numărul de predicții incorecte pentru imagini etichetate manual în baza de date ca aparținând altor clase, dar clasificate de algoritmi în clasa de test considerată. Valorile de acuratețe obținute cu algoritmi de clasificare Random forest și SVM sunt prezentate în Tabelul 7.

Tabelul 7 - Acuratețea rezultatelor obținute cu cei 2 algoritmi de clasificare

	Random forest [%]	SVM [%]
<i>Acc</i>	72.87 %	85.82 %

Se observă că SVM are performanțe de predicție superioare față de Random Forest, acuratețea SVM nedepășind însă 86 %. Din acest motiv, în etapa următoare de desfășurare a proiectului se vor implementa și testa performanțele pentru clasificatori superiori de tip CNN (Convolutional Neural Network).












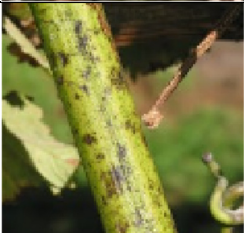





Fig. 20 - Exemplu de înregistrare realizată de camera UAV rezoluție 2720x1530, 30 fps.

Se pot observa în Tabelul 8, exemple de imagini de test, clasele lor reale de apartenență și predicțiile rezultate cu Random Forest și SVM. Întrucât ambii algoritmi au rezultate bune pentru clasa Healthy (conform matricilor de confuzie din Fig. 17 și Fig. 19), s-a ales o singură imagine din această clasă. Imaginile de test includ selecții de imagini din bazele de date preluate pentru antrenare, dar și selecții de imagini obținute de camera UAV. Selecțiile de imagini obținute cu ajutorul UAV au fost decupate din secvențe video înregistrate de membri ai echipei de proiect, un asemenea exemplu fiind ilustrat în Fig. 20. În tabelul 8 predicțiile eronate sunt marcate cu roșu, cele corecte sunt trecute cu portocaliu. Imaginile 1-7 aparțin bazelor de date folosite și pentru antrenare. Imaginile 8-14 sunt selecții din cadrele preluate de camera UAV.

Tabelul 8 - Imagini de test/ clasele de apartenență reale/predicțiile cu Random Forest și SVM.

	Imagine testată	Clasa reală	Clasa predicționată cu Random Forest Acuratețea predicției [%]	Clasa predicționată cu SVM Acuratețea predicției [%]
1.		Healthy	Healthy 47,40 %	Healthy 75,35 %
2.		Esca	Esca 41,00 %	Esca 67,51 %
3.		Black rot	Leaf blight 32,40 %	Black rot 76,75 %
4.		Leaf blight	Leaf blight 39,60 %	Leaf blight 68,63 %
5.		Leaf blight	Leaf blight 39,00 %	Leaf blight 78,62 %
6.		Black rot	Esca 35,20 %	Black rot 53,59 %
7.		Esca	Esca 41,39 %	Esca 62,39 %

8.		Powdery mildew	Powdery mildew 84,40 %	Powdery mildew 66,82 %
9.		Esca	Black rot 29,00 %	Esca 68,42 %
10.		Powdery mildew	Black rot 28,60 %	Black rot 45,49 %
11.		Powdery mildew	Powdery mildew 90,60 %	Powdery mildew 77,26 %
12.		Esca	Black rot 26,40 %	Esca 42,04 %
13.		Powdery mildew	Powdery mildew 86,60 %	Powdery mildew 71,04 %
14.		Esca	Esca 24,60 %	Esca 74,65 %

4 Concluzii

Desfășurarea etapelor 1 și 2 din cadrul proiectului au avut în vedere stabilirea principiilor ce stau la baza proiectării și implementării unei platforme de monitorizare și prevenție pentru agricultura de precizie. Principiile considerate se referă la adoptarea normelor NGI în cadrul proiectării, integrării tehnologiei 5G la transmisiune a datelor agregate de poarta de acces (date primite de la WSN) către rețeaua centrală 5G și către serverul platformei propuse, precum și integrării analizelor de imagini captate cu UAV în vederea predicției riscului de apariție a diverselor boli specifice viței de vie.

În cadrul etapei 1 au fost detaliate aspectele teoretice legate actualele specificații NGI pentru agricultura de precizie, precum și potențialele caracteristici ale unei rețele 5G pentru sistemul de telemetrie.

Pentru etapa a 2-a a proiectului, raportul prezintă succint principiile proiectării și testării preliminare a unei platforme NGI 5G folosind WSN (senzori de temperatură, de umiditate a solului și aerului) și UAV pentru agricultura de precizie. În acest sens este prezentată arhitectura preliminară a sistemului NGI-UAV-AGRO, arhitectură bazată pe nivele Dispozitive, Rețea, Cloud și Aplicație. Testările efectuate în cadrul acestor două etape au avut în vedere testarea preliminară a platformei NGI 5G cu WSN (în 3 scenarii diferite), configurarea sistemului telemetrie cu UAV (drona Multirotor DJI Phantom 4 Multispectral), precum și testarea outdoor a platformei NGI 5G cu WSN și UAV. Ulterior, s-au realizat și analize legate de prelucrările datelor și imaginilor obținute cu WSN și UAV, prin utilizarea de algoritmi specifici identificării riscului de apariție a bolilor (Random forest și SVM).

Etapa a 3-a a proiectului va cuprinde activități legate de optimizare sistemului din toate punctele de vedere, incluzând testări outdoor pe o suprafață agricolă mai mare pentru verificarea acurateții datelor culese de la WSN și UAV, actualizarea bazei de date pentru o cantitate mai mare de date, precum și experimentarea și testarea fiabilității platformei prin experimente extinse. Simultan, se vor avea în vedere activități de diseminare a rezultatelor, precum și depunerea unei cereri de brevet pentru platforma dezvoltată (având în vedere aplicabilitatea industrială a platformei).

5 Diseminare/Site web

Activitățile de cercetare și dezvoltare experimentală desfășurate în cadrul primelor două etape ale proiectului de către membrii UPB și BEIA, s-au concretizat în:

- **crearea unui website al proiectului:** <http://nextagri.radio.pub.ro/> și <https://smartagro.beia-consult.ro/ngi-uav-agro/> ;
- **diseminarea rezultatelor** în cadrul unor lucrări științifice pe tematica proiectului:
 - **A. Vulpe**, M. Idu, D. Gheorghe, A. Marțian and **O. Fratu**, "ML-based Analytics Framework for beyond 5G Mobile Communication Systems," 2020 28th Telecommunications Forum (TELFOR), 2020, pp. 1-4, doi: 10.1109/TELFOR51502.2020.9306534, Date of Conference: 24-25 Nov. 2020, ISBN Information: CD:978-1-6654-0498-3, Electronic ISBN:978-1-6654-0499-0, Print on Demand(PoD) ISBN:978-1-6654-0500-3, INSPEC Accession Number: 20346209
 - V. S. Chedea, **A.-M. Drăgulescu**, L. L. Tomoiagă, **C. Bălăceanu**, M. L. Iliescu, „Climate Change and Internet of Things Technologies - Sustainable Premises of Extending the Culture of the Amurg Cultivar in Transylvania - A Use Case for Târnavă Vineyard”, Sustainability 2021, 13, 8170, DOI10.3390/su13158170
 - **A.-M. Drăgulescu**, S. Halunga, C. Zamfirescu, “Unmanned Vehicles Placement Optimization for Internet of Things and Internet of Unmanned Vehicles”, Sensors 2021, 21(21), 6984; <https://doi.org/10.3390/s21216984>

○ I. Marcu, G. Suciu, C. Bălăceanu, A. Vasilescu, I. Pirnog, C. Pațachia-Sultănoiu, „Sustainable crop production predictions and crop diseases risk assessment based on agri-weather parameters and precision agriculture platform”, submitted to International Journal of Agricultural Sustainability (Q1, IF: 2.905) (noiembrie 2021)

BIBLIOGRAFIE

- [1] <https://conferinte.tmtpr.ro/agricultura-de-precizie-editia-2018/>
- [2] „5 Precision agriculture technologies searched by farmers”, <https://vantage-ro.com/en/news/5-precision-agriculture-technologies-searched-by-farmers/>
- [3] C. McLellan, „M2M and the Internet of Things: A guide”, <https://www.zdnet.com/article/m2m-and-the-internet-of-things-a-guide/>, 2013
- [4] „Internet of Things (Partea a 2a): Tehnologii Wireless de transfer al datelor”, <http://electronica-azi.ro/2017/11/06/internet-of-things-partea-a-2a-tehnologii-wireless-de-transfer-al-datelor/>
- [5] „ABOUT LD-AGRO”, <http://www.ldagro.com/about-ld-agro.html>
- [6] „Tehnologie GPS profesională în agricultură”, http://www.ldagro.com/static/files/1/Download/Agrogazda_GPSkatalogus_2017_A4_RO_we_b_OK.pdf, 2018
- [7] „Extended Coverage – GSM – Internet of Things (EC-GSM-IoT)”, <https://www.gsma.com/iot/mobile-iot-technology-ec-gsm-iot/>
- [8] C. Nicolau, „La MWC 2017 se demonstreaza apeluri VoLTE pentru IoT”, <https://cristiannicolau.wordpress.com/2017/03/03/la-mwc-2017-se-demonstreaza-apeluri-volte-pentru-iot/>, 2017
- [9] S. Chhabra, „LTE-M is the next step in Canada’s IoT revolution, and consumers should be excited”, <https://mobilesyrup.com/2017/06/01/lte-m-iot-canada/>
- [10] „Tendința spre simplitate a IoT”, <http://electronica-azi.ro/2017/04/05/tendinta-spre-simplitate-a-iot/>, 2017
- [11] „LoRa, un nou tip de rețea wireless”, <https://www.nwradu.ro/2016/04/lora-un-nou-tip-de-retea-wireless/>
- [12] „Internet of Things (Partea a 3a): Tehnologii Wireless de transfer al datelor”, <http://electronica-azi.ro/2017/11/30/internet-of-things-partea-a-3a-tehnologii-wireless-de-transfer-al-datelor/>, 2017
- [13] „THE NGI INITIATIVE: AN INTERNET OF HUMANS”, <https://www.ngi.eu/about/>
- [14] “Smart Networks in the context of NGI”, <https://www.networld2020.eu/wp-content/uploads/2018/11/networld2020-5gia-sria-version-2.0.pdf?x11098>, 2018
- [15] „Next Generation Internet of Things”, <https://www.ngiot.eu/wp-content/uploads/sites/26/2020/09/D3.1.pdf>, 2020
- [16] M. Serrano, et al., „Next Generation Internet Research and Experimentation”, Building the Future Internet through FIRE, River Publishers, pp.43-84, 978-87-93519-12-1, 2017
- [17] „Autonomous tractors and plant-level precision farming”, <https://www.ngiot.eu/autonomous-tractors-and-plant-level-precision-farming/>, 2021
- [18] „Augmented remote operation of an intelligent agricultural fleet”, <https://intelliot.eu/agriculture>, 2021
- [19] J. Sanchez-Gomez, et al., “Secure Authentication and Credential Establishment in Narrowband IoT and 5G”, Sensors 2020, 20, 882; doi:10.3390/s20030882

-
- [20] J. P. Clarkson, L. Fawcett, S. G. Anthony, C. Young, “A Model for *Sclerotinia sclerotiorum* Infection and Disease Development in Lettuce, Based on the Effects of Temperature, Relative Humidity and Ascospore Density”, *PLoS ONE* 9(4): e94049, 2014
- [21] L. Ling, et al., “A *Streptomyces* sp. NEAU-HV9: Isolation, Identification, and Potential as a Biocontrol Agent against *Ralstonia solanacearum* of Tomato Plants”, *Microorganisms*. 2020 Mar; 8(3): 351.
- [22] H. Zhu, H. Zhou, Z. Ren, E. Liu, “Control of *Magnaporthe oryzae* and Rice Growth Promotion by *Bacillus subtilis* JN005”, *Journal of Plant Growth Regulation* (2021)
- [23] R. Manavalan, “Efficient Detection of Sugarcane Diseases through Intelligent Approaches: A Review”, *Asian Journal of Research and Review in Agriculture*, 2021
- [24] D. Mohandassa, J.-L. Zhao, Y.-M. Xia, M. J. Campbell, Q.-J. Li, “Increasing temperature causes flowering onset time changes of alpine ginger *Roscoea* in the Central Himalayas”, *Journal of Asia-Pacific Biodiversity*, Vol. 8, Issue 3, Pages 191-198, 2015
- [25] F. M. da Costa, et al., “Progress of the tropical rust of corn *Zea mays* L., under different fungicide treatments”, *Summa phytopathol.* 34 (3), 2008
- [26] A. C. Velásquez, C. D. M. Castroverde, S. Y. He, “Plant–Pathogen Warfare under Changing Climate Conditions”, *Current Biology*, Vol. 28, Issue 10, Pp. R619-R634, 2018
- [27] B. Williamson, B. Tudzynski, P. Tudzynski, J. A L van Kan, “*Botrytis cinerea*: the cause of grey mould disease”, *Mol Plant Pathol*, 8(5):561-80, 2007
- [28] A. D. Marta, V. Di Stefano, Z. G. Cerovic, G. Agati, S. Orlandini, “Solar radiation affects grapevine susceptibility to *Plasmopara Viticola*”, *Sci. agric. (Piracicaba, Braz.)* 65 (spe), 2008
- [29] T. Ishimaru, et al, “Effect of the light and dark conditions on flower opening time between cultivated rice (*Oryza sativa*) and a near-isogenic early-morning flowering line”, *AoB Plants*;13(4): plab040, 2021
- [30] H.M Young, et al, “Effect of solar radiation on severity of soybean rust”, *Phytopathology*;102(8):794-803, 2021
- [31] F. Du, et al, “Protecting grapevines from rainfall in rainy conditions reduces disease severity and enhances profitability”, *Crop Protection*, Vol. 67, Pages 261-268, 2015
- [32] A. L. Hazelrigg, T. L. Bradshaw, G. S. Maia, “Disease Susceptibility of Interspecific Cold-Hardy Grape Cultivars in Northeastern U.S.A”, *Horticulturae* 2021, 7(8), 216
- [33] J. Vanden Heuvel, M. Centinari, “Under-Vine Vegetation Mitigates the Impacts of Excessive Precipitation in Vineyards”, *Front Plant Sci.* 2021; 12: 713135
- [34] J. Clemow, “Use Cases of 5G Technology in Smart Farming and Agriculture”, <https://www.telit.com/blog/5g-smart-farming-agriculture-use-cases/>, 2021
- [35] Huawei, “Using 5G to revolutionize farming”, <https://www.cio.com/article/3564550/using-5g-to-revolutionize-farming.html>, 2021
- [36] “5G: the gamechanger for precision agriculture”, <https://sgtechcentre.undp.org/content/sgtechcentre/en/home/blogs/5g--the-gamechanger-for-precision-agriculture.html>, 2021
- [37] “Smart agriculture, a good use case for 5G networks in Spain”, <https://on5g.es/en/smart-agriculture-a-good-use-case-for-5g-networks-in-spain/>, 2021
- [38] “Eclipse Mosquitto™: An open source MQTT broker”, <https://mosquitto.org/>
- [39] test.mosquitto.org
- [40] <https://www.influxdata.com/time-series-platform/telegraf/>
- [41] <https://www.influxdata.com/>
- [42] <https://grafana.com/>
- [43] “Plant Intelligence for Targeted Action”, <https://www.dji.com/p4-multispectral>

- [44] Z. Jiajun, et al., “Grape Leaf Black Rot Detection Based on Super-Resolution Image Enhancement and Deep Learning”, J. Frontiers in Plant Science, vol. 12, <https://doi.org/10.3389/fpls.2021.695749>, June 2021.
- [45] B.C. Russell, et al., "Label Me: A Database and Web-Based Tool for Image Annotation", Int. Journal of Computer Vision. 77 (1–3): 157–173, 2008
- [46] “Grape disease data set”, <https://drive.google.com/drive/folders/1SFbc-dNzr325jHw434j8LYyCii6djzkC?usp=sharing>
- [47] <https://www.kaggle.com/xabdallahali/plantvillage-dataset>

Data
Decembrie 2021

Direct proiect,
Conf.dr.ing. Ioana-Manuela Marcu