

PROIECT CERCETARE • PNRR • INVESTMENT I8

COSA

Collaborative Framework for Smart Agriculture

Primera Dru • Baia Mare

Prezentator

As. Univ. Dr. Ing. Erdei Rudolf-Eduard

Cercetător COSA • UTCN — CUNBM

01 • GENERAL OVERVIEW

Rezultate tehnice ale proiectului, pe niveluri

Nivel național

Specializare Inteligentă

Nivel regional

Bonitare, GIS,
Prelucrare imagini
satelitare

Nivel local vizibil


AI Vision
Detectarea automată a
bolilor plantelor

Nivel local invizibil

Stație Meteo Inteligentă
Asistentul tău în
agricultură

Ce este specializarea inteligentă?

O abordare strategică a dezvoltării regionale care orientează regiunile către domeniile lor de excelență și avantaj competitiv. Presupune alocarea ținută a resurselor și investițiilor pentru a construi capacități în sectoare specializate, stimulând inovarea, creșterea economică și competitivitatea.




Resurse ținute

Investiții direcționate către sectoarele cu cel mai mare potențial al regiunii



Avantaj competitiv

Construirea de capacități acolo unde regiunea poate excela cu adevărat



Decizii bazate pe date

Politici publice fundamentate pe dovezi, nu pe intuiție

Metodologia AEGIS: șapte straturi de analiză


Aplicația integrează șapte perspective complementare pentru a determina specializarea optimă a fiecărei localități din România.

**AEGIS**


→ combină cele 7 straturi într-o recomandare unică pentru fiecare localitate

Cum se propagă specializarea inteligentă


Hărțile de contagiune arată cum influența economică a unei zone se răspândește către vecini — culori mai închise = influență mai mare.



Influența economică brută, pe județe



Cine pe cine influențează?




Contagiunea de proximitate (efectul asupra vecinilor)




Contagiunea reșază ierarhia: județe aparent mici devin influente prin poziția lor în rețea, iar polii urbani își propagă specializarea către zonele învecinate.

Influențele la nivel de localitate


Aceleași hărți de contagiune, coborâte de la județe la localități — culori mai închise / cercuri mai mari = influență mai mare.



Influența brută a localităților



Cine pe cine influențează?



Contagiunea localităților (efectul asupra rețelei)



După contagiune, Bucureștiul domină clar rețeaua națională, iar polii Cluj, Iași, Timișoara și Constanța își propagă influența către localitățile vecine.

Bonitare, prelucrare date satelitare



BONITARE =
SISTEM DE
EVALUARE A
TERENURILOR




ÎMBUNĂTĂȚIRE
BONITARE PRIN
UTILIZARE GIS
ȘI AI



APLICATIE /
ALGORITM



Metodele clasice sunt rigide,
lipsește predicțiile și adaptabilitatea
datelor, dar sunt esențiale pentru
productivitatea și planificarea
agricolă de precizie.





urilor agricole ▾

Layers

Legend

Selection





Utilizare AI pentru predicții

01

Dezvoltare bonitatea terenurilor integrată cu GIS și îmbunătățită cu AI

02

Utilizarea învățării automate pentru prognoze climatice pe termen lung

03

Generare hărți spațiale utilizând Voronoi tessellation


17 indicators (soil, climate, topography)

Forecasting via deep learning

Voronoi tessellation for spatial representation

3. Clasificare multi-clasă: boli și dăunători la tomate

Modele IA pentru diagnostic automat din imagini



Realizări

- seturi echilibrate prin augmentare pentru 10/11 clase de tomate
- TPC Net: CNN cu blocuri Conv2D, BatchNorm, MaxPool și clasificator softmax
- performanță superioară modelelor transfer learning evaluate pe aceeași sarcină

99,31% acuratețe test TPC Net

98,2% acuratețe CNN inițial

TPC_Net: An Efficient CNN Architecture for Tomato Plant Classification





Fig. 2: Confusion matrix corresponding to the test dataset



Matrice de confuzie și acuratețe pe clase

Publicații

- [1] O. Cosma and L. Cosma, "TPC Net: An Efficient CNN Architecture for Tomato Plant Disease and Pest Classification," in SOCO 2024, pp. 188-198, 2025.
- [2] O. Cosma and L. Cosma, "A Novel CNN Approach for Accurate Tomato Disease Classification," in IEEE ICE/ITMC, pp. 1-7, 2024.

Modele capabile să detecteze simultan boli, deficiențe și dăunători




Fig. 5: Subset Accuracy and Hamming Accuracy of the proposed model versus transfer-learned models.




Fig. 6: Hamming Loss [%] comparison.




Fig. 7: Model Size [MB] comparison





Fig. 8: Inference Time [ms] comparison

CDLA vs. modele transfer learning

99,55% macro F1 CDLA
98,43% Subset Accuracy
0,31% Hamming Loss
10,9 MB model compact
9,3 ms timp inferență / imagine

Arhitecturi:

- TPN/CDLA: convoluții separabile, conexiuni reziduale, BatchNorm și ieșiri sigmoid
- 12 clase: 6 condiții individuale + 6 combinații multi-simptom
- ansamblurile cu TPN cresc stabilitatea: macro F1 până la 99,58%, Hamming Loss până la 0,28%




Publicații

[1] L. Cosma, Ș. V. Oniga, and O. Cosma, "Ensemble Deep Learning Model for AI-Powered Cyber-Physical Systems in Precision Agriculture," in DoCEIS 2025, IFIP AICT, vol. 759, pp. 115-127, 2025.
[2] L. Cosma, Ș. V. Oniga, and O. Cosma, "A Compact Deep Learning Architecture for Multi-Label Classification of Plant Diseases," in IEEE ICE/ITMC, pp. 1-10, 2025.

Segmentare semantică: hărți de buruieni din imagini UAV multispectrale

Hărți pentru erbicidare localizată



Model și protocol

- U-Net compact cu skip connections, Swish, BatchNorm și depthwise-separable convolutions
- 3 clase pixel-level: fundal/sol, cultură, buruiană
- split la nivel de ortofotoplan pentru a evita leakage-ul spațial

88,73% PR-AUC weed

98,72% ROC-AUC weed

<2% constrângere crop→weed




Fig. 4: Comparison of AUC metrics across the tested input configurations.




Fig. 5: Comparison of segmentation accuracy across tested input configurations




Fig. 6: Comparison of cross-class confusion rates

Metrici AUC, F1/IoU și risc operațional

Publicații

[1] L. Cosma, Ș. Oniga, and O. Cosma, "Risk-Aware Multispectral U-Net for Semantic Weed Mapping in Precision Agriculture," in SOCO 2026, CCIS, vol. 3046, pp. 53-65, 2026.

04 • STAȚIA METEO

4. Stație Meteo Inteligentă

Asistentul tău în agricultură






04 • STAȚIA METEO

4. Stație Meteo Inteligentă

Asistentul tău în agricultură



● Analiză agronomică parcelă

19 Iun, 15:37

1. Rezumat Stare Actuală

Cultura de tomate se află într-o stare de stres transpirator moderat, în ciuda temperaturilor ambientale optime.

2. Analiza "De ce" (Analiză XAI)

Principalul factor de risc este valoarea VPD (Vapour Pressure Deficit) de **1.63 kPa**, care a depășit pragul optim de 0.8 - 1.2 kPa. Deși XAI indică o tendință "Stabilă" și nu semnalează un driver critic de schimbare rapidă, valoarea absolută a VPD-ului a intrat în zona de stres conform cunoștințelor agronomice integrate, declanșând riscuri fiziologice.

3. Impact Agronomic

Un VPD de 1.63 kPa induce **închiderea stomatelor** ca mecanism de apărare pentru a preveni pierderile excesive de apă prin transpirație. Acest proces limitează absorbția de CO_2 , ceea ce poate reduce rata de fotosinteză și, implicit, ritmul de creștere al plantei.

Mai mult, combinația de temperatură (25.5°C) și umiditate relativă scăzută (50%) creează un mediu propice pentru dezvoltarea **Făinării (Powdery Mildew)**, care, spre contrariul altor fungi, preferă umidități mai scăzute pentru germinarea sporilor.

4. Sugestii Acționabile

* **Controlul Umidității:** Implementați măsuri pentru a crește umiditatea relativă a aerului (ex: nebulizare/fogging) pentru a readuce VPD-ul în intervalul optim de 0.8 - 1.2 kPa.

* **Monitorizare Fitosanitară:** Efectuați o inspecție vizuală riguroasă a frunzișului pentru a detecta primele semne de făinare, având în vedere condițiile climatice actuale.

* **Verificare Manuală Sol:** Deoarece datele pentru umezeala solului (`soil_moisture_20cm`) și precipitațiile sunt absente (N/A), încrederea în statusul hidric este scăzută; vă rugăm să verificați manual nivelul de hidratare pentru a evita stresul hidric compounding.

* **Tratamente:** Aplicarea tratamentelor fitosanitare este **permisă** în acest moment, deoarece Delta T (7.1) se află în intervalul sigur (între 2 și 8).

Închide

Agronom Senior AI

INTERFAȚĂ DE CUNOȘTINȚE CU SUPT MCP

Șterge Conversația

● ONLINE

Tu • 09:29 AM

in comuna 2, la unele roșii am observat că se încovoie frunzele, oare ce poate fi?

Agronom AI • 09:29 AM [In flux](#)

Se sintetizează recomandarea finală a expertului...

Bună ziua. Analizând datele live din **Comuna 2 Plot** și combinându-le cu simptomele descrise de dumneavă (încovoierea frunzelor), există câteva cauze probabile. Iată analiza mea agronomică:

1. Analiza Datelor Senzoriale (Comuna 2)

- **Umiditatea Solului:** Valorile actuale sunt de **23%/28%/28%**. Acestea sunt valori relativ scunde pentru cultura de tomate, indicând un stres hidric moderat, mai ales în stratul superficial (20 cm).
- **VPD (Deficitul de Presiune de Vapor):** Avem un VPD de **0.87 kPa**. Această valoare este optimă pentru absorbția nutrienților, dar dacă solul este prea uscat, planta nu poate compensa transpirația, ceea ce duce la pierderea turgorului.
- **RH (Umiditatea Relativă):** 68% este o valoare bună, deci nu vorbim despre un stres cauzat de aer extrem de uscat.

2. Cauze posibile pentru încovoierea frunzelor

Întreabă despre culturi, date live de la senzori sau reguli agronomice...


Trimite




Fapte Atomice (Graf Relațional)

reguli deterministe și praguri biologice.


⚙️ Pauzează fizica



Tendință istorică: Temperatura aerului



butors



CLOSING • ACKNOWLEDGEMENTS

Mulțumim!

Sunteți gata pentru Smart Agriculture?

COSA PROJECT RESULTS • AT A GLANCE

36+

Papers
published

6

Q1
articles

4

Q2
articles

5

Doctoral
theses

1

Patent
application

2

Practical
platforms

