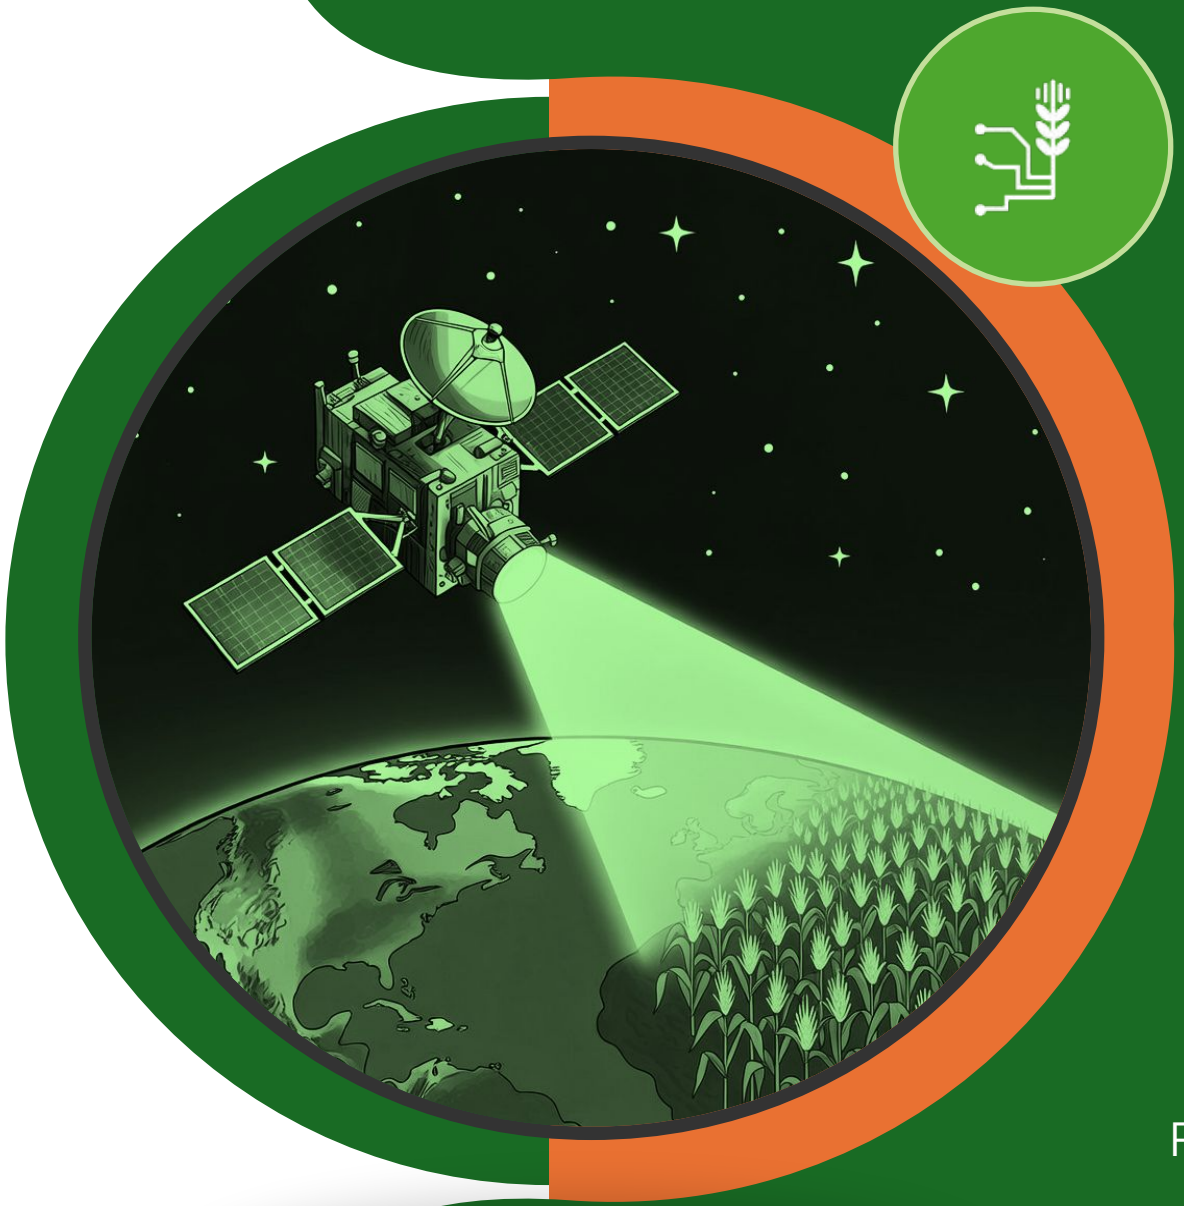
Osijek, 20. studeni 2025.



1. SASTANAK
članova istraživačkog tima projekta

AgroVeFe

Predikcija potencijala prinosa kukuruza korištenjem modela strojnog učenja na temelju vegetacijskih indeksa i fenoloških metrika iz Sentinel-2 multispektralnih satelitskih snimki

581-UNIOS-30

Financiranje: NextGenerationEU / NPOO 2026

Trajanje: 48 mjeseci

Kontekst i opravdanost

Globalni izazovi: klimatske promjene, održivost i konkurentnost hrvatske poljoprivrede

Prepreka: visoki troškovi senzora i kartiranja prinosa → ograničena primjena precizne poljoprivrede

Rješenje: kombinacija besplatnih Sentinel-2 podataka + AI + EC tla

Strateška usklađenost: NPOO 2026, S3 2029, SDH 2032, FAZOS SR 2028



Ključna istraživanja u predikciji prinosa na temelju satelitskih podataka

Vegetacijski indeksi (VI) kao osnova za predikciju:

- NDVI, EVI, EVI2, SAVI → uobičajeni, ali **skloni zasićenju** u fazama visoke biomase
- **VI otporni na zasićenje:** WDRVI, IDVI, PPI, NDVI3RE → obećavajući, ali **rijetko testirani u poljoprivrednim kulturama kao što je kukuruz** (de Almeida et al., 2025; Gitelson, 2004; Qiao et al., 2024)

Fenološke metrike (FM) kao kontekstualni regulator:

- SOS, POS, EOS, Senescence — ključne za vremensko usklađivanje spektralnih signala s fiziološkim procesima (Jin & Eklundh, 2014; Santana et al., 2024)

ML modeli:

- Dominira korištenje **Random Forest** i **SVR**, ali često bez **rigorozne validacije** u višegodišnjem kontekstu
- **Ensemble metode** rijetko primijenjene u poljoprivredi, iako daju bolju stabilnost

Važne istraživačke praznine

Istraživačka praznina (research gap)	Obrazloženje
1. Nedostatak integracije VI-a otpornih na zasićenje s fenološkim metrikama	Većina istraživanja koristi **ili** VI **ili** FM, pa rizikuje **pogrešnu interpretaciju signala** iz satelita (Tavares et al., 2022)
2. Ograničena validacija na višegodišnjim i prostorno raznolikim podacima	Većina modela trenirana je na **jednogodišnjim yield kartama** → slaba generalizacija (Ouattara et al., 2020)
3. Nedostatak povezanosti između satelitskih predikcija i svojstava tla (npr. EC)	EC tla je ključan pokazatelj heterogenosti, ali rijetko se koristi u ML modelima za predikciju prinosa
4. Neprimjerenost za male poljoprivrednike	Skupi yield senzori ograničavaju primjenu u praksi → **potreba za besplatnim, skalabilnim alternativama (Sentinel-2)**
5. Nedostatak otvorenih alata i ISOXML karata za direktnu primjenu u polju	Znanost često ne prelazi u praksu jer nedostaju **interoperabilni izlazi** za poljoprivredne strojeve

Kako AgroVeFe rješava istraživačke praznine

Istraživačka praznina (research gap)	Naš pristup u AgroVeFe
1. VI + FM nisu integrirani	Testiramo **56 kombinacija** (8 VI × 7 FM) → tražimo optimalnu kombinaciju za kukuruz
2. Nedostatak višegodišnje validacije	Podaci iz **5 godina**, ≥10 ha/godina → robusnost modela
3. Ignoriranje svojstava tla	**EC skeniranje tla (EM38 + RTK GNSS)** + korelacija s predikcijom → višedimenzionalni pristup
4. Visoki troškovi za male poljoprivrednike	Korištenje **besplatnih Sentinel-2 snimki** → demokratizacija precizne poljoprivrede
5. Nedostatak primjenjivih izlaza	Generiranje **ISOXML karata zonacije** → direktna kompatibilnost s poljoprivrednim strojevima



Glavni ciljevi i očekivani rezultati 1.

Ciljevi

1. Osnaživanje kroz nabavu istraživačke opreme
2. Razvoj robusnih ML modela za predikciju potencijala prinosa (VI + FM)
3. Optimizacija precizne poljoprivrede (sateliti + EC tla + ISOXML karte)
4. Edukacija i diseminacija (znanstvenici, studenti, poljoprivrednici)
5. Otvorene baze podataka i alati (open science)
6. Validacija na više regija i uvjeta



Glavni ciljevi i očekivani rezultati 2.

Ključni mjerljivi pokazatelji (MP)

- ≥15 znanstvenih radova (Q1/Q2)
- ≥5 formalnih suradnji s gospodarstvom
- 1 patentna prijava
- ≥100 ha validiranog modela
- 3 javna skupa podataka
- 2 open-source alata za obradu podataka
- Točnost modela: $R^2 \geq 0.7$



Metodologija – sažeto

1. → **Prikupljanje i harmonizacija podataka**: Kartiranje prinosa (2020–2025, ≥10 ha/godina)
2. → **Vremenske serije satelitskih podataka**: Sentinel-2 L2A → GEE → 20 m rezolucija
3. → **Izračun VI-a** (8 indeksa (uključujući WDRVI, PPI, NDVI3RE – otporni na zasićenje)) **i FM-a** (7 fenoloških metrika (SOS, POS, EOS, itd.))
4. → **Predikcija ML modelima**: Random Forest, SVR, Cubist, Ensemble → 10-fold krosvalidacija
5. → **EC tla**: skeniranje EM38MK2-4 + RTK GNSS (2 cm preciznost), **format izlaza**: ISOXML karte zonacije → direktna primjena u poljoprivrednim strojevima

Radni paketi – pregled i raspodjela uloga

RP	Naziv	Voditelj	Suradnici	Ključne aktivnosti
RP1	Nabava opreme	**Plaščak**	Jurišić Radočaj Rapčan Jurić Barač Zimmer Vidaković Pačarek Galić Subašić	GIS stanice, EC skener, drone, AV oprema...
RP2	Podaci o prinosu	**Vidaković**	Plaščak Jurić Barač Zimmer Pačarek	Harmonizacija yield-mapa, outlier detekcija
RP3	Sentinel-2 podaci	**Plaščak**	Jurišić Radočaj Rapčan Galić Subašić	GEE pipeline, cloud masking, ponovljivost
RP4	VI & FM	**Radočaj**	Plaščak Jurišić Galić Subašić	Izračun 56 kombinacija po točki

RP	Naziv	Voditelj	Suradnici	Ključne aktivnosti
RP5	ML modeliranje	**Radočaj**	Plaščak Jurišić Rapčan Galić Subašić	Evaluacija 4 algoritma, 10x krosvalidacija
RP6	Zoniranje i ISOXML	**Barač**	Plaščak Jurišić Radočaj Rapčan Jurić Galić Subašić	Mapiranje 3–7 klasa, generiranje ISOXML-ova
RP7	EC tla + korelacija	**Plaščak**	Jurić Barač Zimmer Vidaković Pačarek	Terensko skeniranje + analiza s yieldom
RP8	Diseminacija	**Zimmer**	Plaščak Jurišić Radočaj Rapčan Jurić Barač Zimmer Vidaković Pačarek **Galić Subašić**	Web, publikacije, konferencije, radionice, videozapisi

RP1: Nabava terenske i laboratorijske opreme

Trajanje: 24 mjeseca



Cilj: Osigurati opremu potrebnu za provedbu istraživanja, validaciju i diseminaciju rezultata.

Ključne aktivnosti:

- **Nabava opreme:** sustava za skeniranje EC tla; GIS radnih stanica (stolna i pokretna), vanjskih diskova, AV opreme; Bespilotnog zrakoplova s multispektralnom kamerom; Analitičke jedinice za obradu podataka i multimedijalnu produkciju; Jedinice za terensku obradu, ISOXML kartografiju i validaciju AI modela.

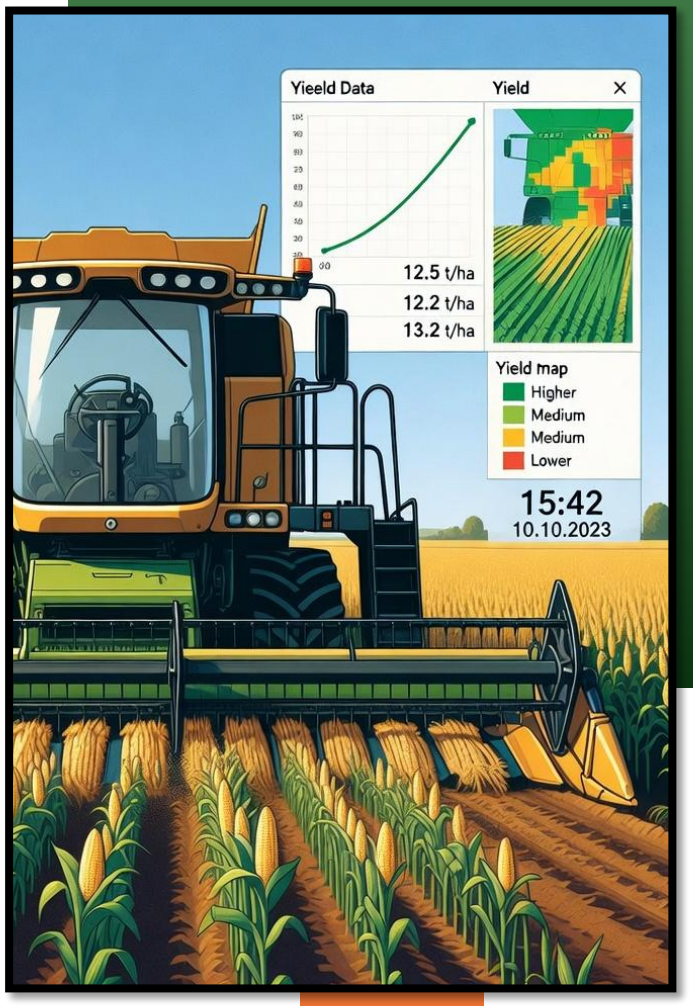
Voditelj: Plaščak

Suradnici: svi članovi tima

Ishodi: potpuno opremljeni laboratorij i terenski tim za sve potrebe projekta; Infrastruktura za AI analizu, generiranje ISOXML-a i produkciju edukacijskih videozapisa.

RP2: Prikupljanje i harmonizacija podataka prinosa

Trajanje: 24 mjeseca



Cilj: Stvoriti kvalitetan, višegodišnji skup referentnih podataka o prinosu za treniranje ML modela.

Ključne aktivnosti:

- Prikupljanje podataka iz kombajna (2020–2025, ≥10 ha/godina)
- Vektorizacija, transformacija u HTRS96/TM (EPSG:3765)
- Filtriranje outlier-a i inlier-a na temelju prostorne autokorelacije;

Voditelj: Vidaković

Suradnici: Plaščak, Jurić, Barač, Zimmer, Pačarek

Ishodi:

- Homogenizirana baza podataka u .shp formatu
- Validirani “ground truth” podaci za sve godine istraživanja

RP3: Prikupljanje i harmonizacija vremenskih serija Sentinel-2 snimki

Trajanje: 24 mjeseca



Cilj: Pripremiti vremenske serije Sentinel-2 podataka usklađene s terenskim podacima.

Ključne aktivnosti:

- Preuzimanje Sentinel-2 L2A snimki putem Google Earth Engine-a
- Maskiranje oblaka i sjena
- Harmonizacija prostorne razlučivosti na 20 m
- Transformacija u HTRS96/TM CRS.

Voditelj: Plaščak

Suradnici: Jurišić, Radočaj, Rapčan, Galić Subašić

Ishodi:

- Procesuirane vremenske serije za svaku godinu i parcelu
- Cloud-ready dataset spremn za izračun VI i FM.

RP4: Izračun vegetacijskih indeksa (VI) i fenoloških metrika (FM)

Trajanje: 12 mjeseci

Cilj: Generirati bogat skup spektralnih i fenoloških značajki za svaku referentnu točku.

Ključne aktivnosti:

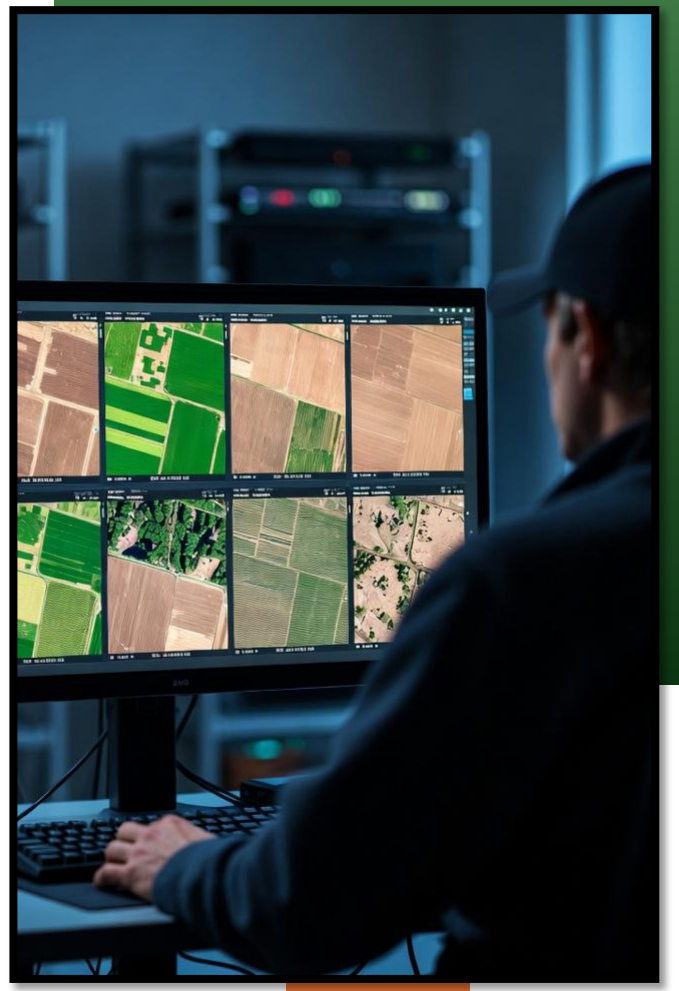
- Izračun 8 VI-a (4 klasična + 4 otporna na zasićenje): NDVI, EVI, EVI2, SAVI, WDRVI, PPI, IDVI, NDVI3RE
- Izračun 7 FM-a: SOS, POS, EOS, Greenup, Maturity, Senescence, Dormancy
- Evaluacija fenoloških modela: Beck, Elmore, Guo
- Kombinacija svih VI + FM → 56 indikatora/točki.

Voditelj: Radočaj

Suradnici: Plaščak, Jurišić, Galić Subašić

Ishodi:

- Geoprostorna baza sa 56 atributa po referentnoj točki
- Validirana metodologija izračuna za otvorenu znanost.



RP5: Modeliranje potencijala prinosa korištenjem ML-a

Trajanje: 12 mjeseci

Cilj: Razviti robusni ML model za predikciju potencijala prinosa s točnošću $R^2 \geq 0.7$.

Ključne aktivnosti:

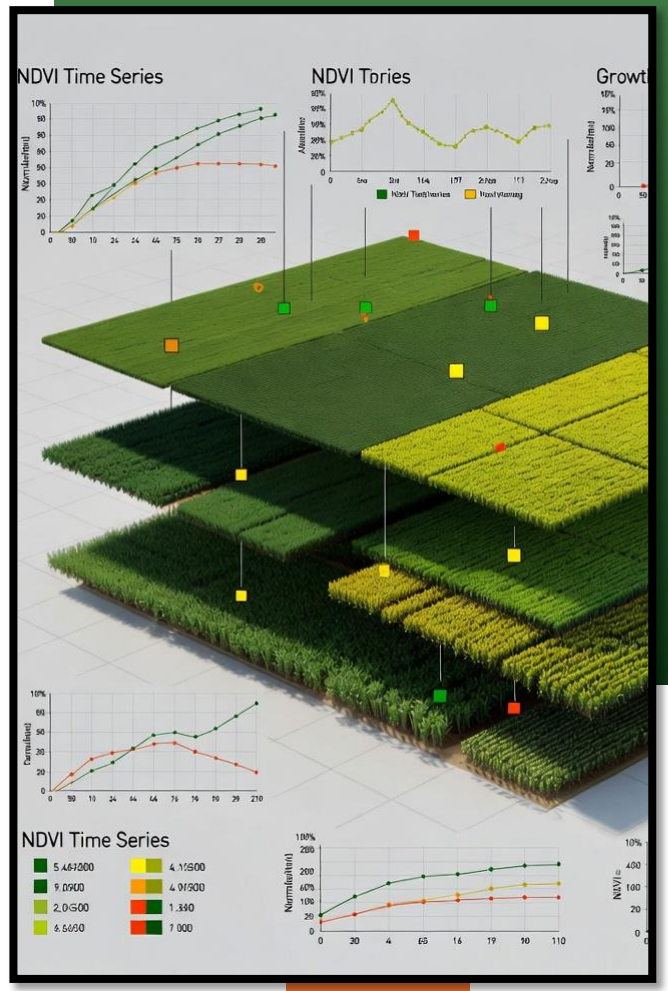
- Priprema podataka za treniranje i testiranje
- Evaluacija 4 ML algoritma: Random Forest, SVR, Cubist, Ensemble
- Optimizacija hiperparametara + 10-fold krosvalidacija x 10 iteracija
- Selekcija najboljeg modela po godini.

Voditelj: Radočaj

Suradnici: Plaščak, Jurišić, Rapčan, Galić Subašić

Ishodi:

- Validirani model(i) za svaku sezonu
- Open-source R skripte za ponovljivost
- Točnost modela dokumentirana za publikaciju i patent.



RP6: Predikcija i zoniranje potencijala prinosa

Trajanje: 24 mjeseca

Cilj: Proširiti model na sve parcele i generirati primjenjive karte za preciznu poljoprivredu.

Ključne aktivnosti:

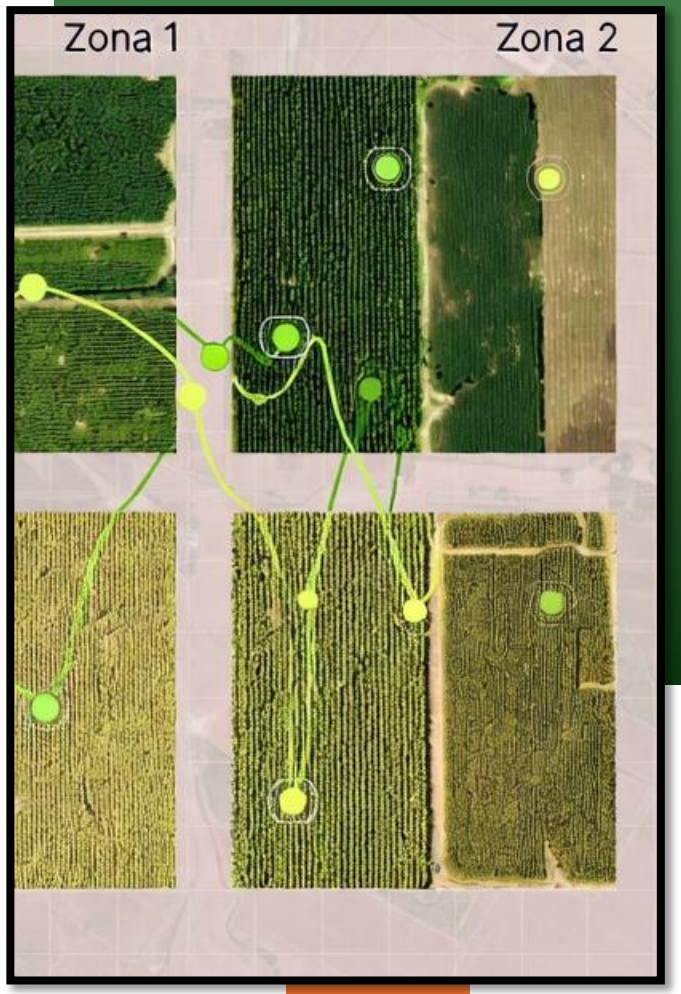
- Primjena optimalnog ML modela na sve poljoprivredne parcele u zoni istraživanja
- Zoniranje potencijala prinosa u 3–7 klasa
- Izrada karata u ISOXML formatu (kompatibilno s poljoprivrednim strojevima).

Voditelj: Barač

Suradnici: Plaščak, Jurišić, Radočaj, Rapčan, Jurić, Galić Subašić

Ishodi:

- ISOXML karte za varijabilnu primjenu inputa
- Demonstracija u praksi s poljoprivrednicima (5 formalnih suradnji)
- Potencijal za patent i komercijalizaciju.



RP7: Skeniranje EC-a tla i korelacijska analiza

Trajanje: 24 mjeseca

Cilj: Utvrditi geoprostornu povezanost između EC tla i potencijala prinosa.

Ključne aktivnosti:

- Skeniranje EC-a tla na 10 ha sa EM38 + RTK GNSS
- Analiza vertikalne i horizontalne distribucije EC-a
- Korelacija s predikcijom potencijala prinosa
- Procjena ekonomske isplativosti integracije EC podataka u zonaciju.

Voditelj: Plaščak

Suradnici: Jurić, Barač, Zimmer, Vidaković, Pačarek

Ishodi:

- Nova spoznaja o komplementarnosti EC-a tla i satelitskih VI/FM
- Smjernice za kombinaciju EC-a i ML-a u preciznoj poljoprivredi.



RP8: Diseminacija rezultata istraživanja

Trajanje: 48 mjeseci



Cilj: Osigurati vidljivost, prijenos znanja i održivost rezultata projekta.

Ključne aktivnosti:

- Objavljivanje ≥15 znanstvenih radova (Q1/Q2)
- Organizacija 3 konferencije: početna, “Drones AI+ 360 Ultra”, završna
- Izrada web stranice projekta i javnih baza podataka
- Produkcija otvorenih alata (2) i edukacijskih videozapisa
- Radionice za studente i poljoprivrednike.

Voditelj: Zimmer

Suradnici: svi članovi tima

Ishodi:

- 3 javna skupa podataka; 2 open-source alata; 11 aktivnosti popularizacije znanosti.

Ganttov dijagram: vremenski plan po godinama



Komunikacijski i upravljački protokol 1.

- **Sastanci tima**:
  - **Mjesečno** – uživo ili Teams (fiksni termin)
  - **Kvartalno** – detaljni napredak po RP-u (izvještaj voditelja RP-a)
- **Dokumentacija**:
  - Sve skripte, podaci i izvještaji na zajedničkom **FAZOS/Cloud repozitoriju**
  - Git/GitHub za R skripte i alate (verzioniranje)



Komunikacijski i upravljački protokol 2.

- **Izvještavanje**:
  - **Interno praćenje realizacije** – obvezna dostava **polugodišnjeg** i **godišnjeg** izvješća o realizaciji **financijskog** i **radnog plana**, te **ostvarenju postavljenih ciljeva** prema Uredu za znanost, tehnologije, projekte i programe Sveučilišta u Osijeku (npoo.projekti@unios.hr)
- **Problemi / blokade**:
  - Izravna komunikacija s voditeljem projekta + rezervni plan za kritične zadatke



Matrica rizika za AgroVeFe

Rizik	Vjerojatnost	Učinak	Razina rizika	Strategija ublažavanja
1. Nedostatak kvalitetnih podataka (npr. outlier-i, nepotpuni yield podaci)	Srednja	Visok	**Visok**	Automatizirana detekcija i filtracija **outlier-a i inlier-a** na temelju prostorne autokorelacije; korištenje **višegodišnjih podataka** za povećanje robusnosti modela (RP2).
2. Oblačnost i nepotpuni Sentinel-2 podaci	Visoka	Srednji	**Visok**	Korištenje **Google Earth Engine (GEE)** platforme s naprednim algoritmima za **maskiranje oblaka i sjena**; vremenska interpolacija za kritične fenofaze (RP3).
3. Overfitting ML modela	Srednja	Visok	**Visok**	**10-fold krosvalidacija × 10 iteracija**; usporedba **4 ML algoritma** (Random Forest, SVR, Cubist, Ensemble); ograničenje broja kovarijata; upotreba ensemble metoda za stabilnost predikcije (RP5).
4. Kašnjenje u nabavi opreme (npr. EC skener, GIS stanice)	Niska	Visok	**Srednji**	Pokretanje **nabavnih postupaka u 1. mjesecu projekta**; planiranje **alternativne opreme iz partnerskih institucija**; korištenje budžetske stavke **„Nepredviđeni troškovi“ (9.000 EUR)** u T4 (RP1).
5. Kvar ključne opreme (hardver/softver)	Niska	Visok	**Srednji**	**Redovito održavanje** i tehnički pregledi; **cloud i lokalne sigurnosne kopije**; **redundantni sustavi** (rezervni laptopi, cloud obrada); edukacija tima o osnovnom rješavanju problema (RP1).
6. Odsutnost ključnih članova tima	Niska	Srednji	**Nizak**	Jasna **raspodjela zadataka** s višestrukom pokrivenošću; **rezervni članovi** s komplementarnim kompetencijama; dokumentirani **protokoli rada** (svi RP-ovi).
7. Niska uključenost poljoprivrednika	Srednja	Srednji	**Srednji**	**Demonstracijske aktivnosti** i **radionice na terenu**; **koristi vizualizacije** kroz edukativne videozapise i infografike; suradnja putem **formalnih ugovora** (cilj: **5 suradnji**) (RP8, RP6).

Konačna poruka i sljedeći koraci

- **Projekt AgroVeFe** = prilika za:
  - **Znanstvenu izvrsnost** (AI + agronomija + geoinformatika)
  - **Transfer znanja** u praksu
  - **Izgradnju trajne infrastrukture** na FAZOS-u
- **Sljedeći koraci**:
  - Potvrda razumijevanja uloga i rokova od strane svih članova
  - Dogovor o terminu **mjesečnog sastanka**
  - Prijedlozi





Vidljivost projekta

Potrebno je osigurati **mjere vidljivosti projekta**:

Na radu, posteru i dr.:

- Rad ili istraživanje financira Europska unija – NextGenerationEU.
- This research was funded by the European union-NextGenerationEU.

Kada je to primjenjivo, država članica dužna je navesti sljedeće odricanje od odgovornosti:

- „Financira Europska unija – NextGenerationEU. Izneseni stavovi i mišljenja samo su autorova i ne odražavaju nužno službena stajališta Europske unije ili Europske komisije. Ni Europska unija ni Europska komisija ne mogu se smatrati odgovornima za njih.
- ...

Funded by
the European Union
NextGenerationEU

Funded by
the European Union
NextGenerationEU

Funded by
the European Union
NextGenerationEU

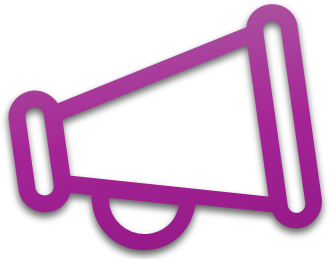
Funded by
the European Union
NextGenerationEU

Funded by
the European Union
NextGenerationEU

Funded by
the European Union
NextGenerationEU

Funded by
the European Union
NextGenerationEU

Funded by
the European Union
NextGenerationEU







PITANJA?