Financira Europska unija NextGenerationEU

Sveučilište Josipa Jurja Strossmayera u Osijeku

Poziv za financiranje institucionalnih istraživačkih projekata

OBRAZAC 1.

Prijavni obrazac

Naziv projekta (puni naziv i akronim)

Primjena infracrvenog zračenja i strojnog učenja za optimizaciju proizvodnje vina WineAI

Područje (STEM, DH/UM – društveno-humanističko ili umjetničko)

STEM

Predlagatelj projektnog prijedloga (ime, prezime, radno mjesto, sastavnica)

izv.prof.dr.sc. Ivan Aleksi, izvanredni profesor Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek

Trajanje projekta (u mjesecima)

48

Kratki pregled predlagateljevih najvažnijih postignuća u dosadašnjem radu relevantnih za provedbu projekta (broj i kvaliteta radova u zadnjih 5 godina, vođenje i suradnja na projektima, citiranost, h indeks, pozvana predavanja i sl. - najviše jedna stranica)

Voditelj projekta izv. prof. dr. sc. Ivan Aleksi [poveznice: CroRis, Google Scholar] je u posljednjih pet godina ostvario značajne znanstvene i stručne rezultate relevantne za provedbu predloženog projekta. U razdoblju od 2020. do 2025. godine objavio je ukupno 20 znanstvenih radova, od čega 7 u međunarodnim časopisima i 13 u zbornicima konferencija, pri čemu su radovi tematski usmjereni na primjenu algoritama umjetne inteligencije, razvoj pametnih senzorskih sustava s ultra niskom potrošnjom energije. Kvaliteta i utjecaj njegovih radova potvrđeni su kroz ukupno 184 citata ostvarenih u posljednjih 5 godina. Trenutno, voditelj ima h-indeks 10, a u posljednjih pet godina h-indeks iznosi 7, što potvrđuje kontinuiranu znanstvenu produktivnost i prepoznatljivost u međunarodnoj znanstvenoj zajednici.

U području vođenja i sudjelovanja na znanstvenim projektima, voditelj je trenutno nositelj jednog bilateralnog znanstvenog projekta Hrvatska-Slovenija, a u posljednjih 5 godina je bio suradnik na 8 znanstveno istraživačkih EU projekata koji su se bavili primjenom naprednih senzorskih tehnologija, umjetne inteligencije i IoT rješenja u logistici i industriji [CroRIS popis projekata]. Kroz ove projekte stekao je bogato iskustvo u koordinaciji multidisciplinarnih timova i suradnji s industrijskim partnerima, što dodatno doprinosi njegovoj sposobnosti uspješne provedbe predloženog projekta.

Kroz EU projekt ESIA – Expert System for Intelligent Agriculture, razvijen u suradnji FERIT-a i tvrtke Gauss d.o.o., voditelj je sudjelovao u razvoju inovativne digitalne platforme namijenjene digitalizaciji i optimizaciji procesa proizvodnje vina, od razvoja senzorskih sustava, implementacije i validacije rješenja u suradnji s vodećim hrvatskim vinarijama. U okviru projekta, FERIT-ov tim razvio je napredne IoT uređaje za automatsko prikupljanje podataka o ključnim parametrima vina (temperatura, razina šećera, alkohol, SO_2). Prikupljeni podaci u realnom vremenu šalju se na ESIA web platformu, gdje se koriste za analizu i praćenje cijelog proizvodnog ciklusa, od berbe grožđa do finalne boce vina. Kroz ovaj projekt voditelj je koautor na ukupno 3 znanstvena rada.

Radom na EU projektu Pametna naljepnica - Smart Sticker for measuring and monitoring storage and transportation conditions of products, voditelj je stekao stručnost u području ultra-niskoenergetskih sustava, senzora, bežične komunikacije i optimizacije potrošnje energije. Kroz ovaj projekt voditelj je koautor na ukupno 5 znanstvenih radova.
WoS Q1 znanstveni radovi A kategorije koji kvalificiraju voditelja za istraživanje na temu umjetne inteligencije s primjenom dubokih neuronskih mreža su: I. Aleksi, et al. (2023) EfficientDet-4 Deep Neural Network-Based Remote Monitoring of Codling Moth Population for Early Damage Detection in Apple Orchard, Agriculture; I. Aleksi, et al. (2023) Development of an automatic monitoring system for pear leaf blister moth and its damage using artificial neural networks, Agriculture.

Voditelj aktivno surađuje s domaćim i inozemnim institucijama, što je rezultiralo zajedničkim publikacijama, projektima i inovacijama u području primjene senzorske tehnologije, umjetne inteligencije i razvoja energetski učinkovitih pametnih rješenja u logistici.

Istraživački tim/suradnici na projektu (opisati metodologiju uspostave istraživačkog tima, za svakog od suradnika navesti ime, prezime, radno mjesto, sastavnicu i objasniti ulogu u provedbi projekta i kompetencije koje donosi u istraživački tim)

Za realizaciju projekta WineAI okupljen je tim stručnjaka iz različitih disciplina, koji uključuje eksperte iz STEM područja, kao i podršku za administrativne i komunikacijske aktivnosti. Osim što obuhvaća tehničke znanosti, među kojima su i senzorske tehnologije, algoritmi umjetne inteligencije i razvoj energetski učinkovitih pametnih rješenja u logistici, pojedini članovi tima ostvarili su zapažene rezultate te objavili relevantne radove i u području računarstva i informacijskih znanosti.

Istraživački tim se sastoji od ukupno 8 FTE članova i svi su 100% zaposleni na sastavnici Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek. Sastav tima je definiran na temelju njihove stručnosti, iskustva i dosadašnjih uspjeha u relevantnim znanstvenim područjima.

1. Voditelj projekta i glavni istraživač:
izv. prof. dr. sc. Ivan Aleksi, radno mjesto: izvanredni profesor, 100% zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
Poveznice: CroRis, GoogleScholar
Kompetencije: Stručnjak u području digitalne obrade signala i slike u stvarnom vremenu, visokoučinkovitog računarstva, umjetne inteligencije i dubokih neuronskih mreža. Njegov znanstveni rad posljednjih godina ističe se primjenom naprednih AI metoda i IoT tehnologija u poljoprivredi i industriji, što je potvrđeno radovima poput razvoja sustava za praćenje štetnika i oštećenja na biljkama temeljenih na umjetnim neuronskim mrežama, koji su objavljeni u časopisu Agriculture 2022. i 2023. godine. Osim toga, Ivan Aleksi ima značajno iskustvo u vođenju i sudjelovanju na međunarodnim i domaćim projektima, razvoju ekspertnih sustava za pametnu poljoprivredu te mentoriranju mladih istraživača. U ovom projektu doprinosi dizajnu i implementaciji sustava za digitalno prikupljanje i analizu podataka o vinu, razvoju AI modela za obradu infracrvenih spektralnih podataka te integraciji IoT rješenja za praćenje procesa obrade vina, čime osigurava povezivanje teorijskih i praktičnih aspekata digitalne enologije. U radu "A low-cost buoyant force measurement device for monitoring sugar concentration in water solution" (ICECCME 2023), razvio je pristupačan uređaj za kontinuirano praćenje koncentracije šećera, što omogućuje precizno i automatizirano upravljanje procesom fermentacije. U članku "Propagation of Radio Waves in Wine Cellars" (IWSSIP 2023) analizirao je izazove i mogućnosti bežične komunikacije u vinskim podrumima, što je temelj za implementaciju IoT sustava i digitalnog nadzora u enološkoj industriji. Kao koautor rada "Sugar/ethanol level measurement in liquids using analog refractometer and digital image processing" (ELMAR 2022), sudjelovao je u razvoju metode koja kombinira analogne instrumente i digitalnu obradu slike za daljinsko i automatizirano mjerenje šećera i etanola u vinima.
Uloga u provedbi projekta: Ivan Aleksi, voditelj projekta, preuzet će ključnu ulogu u koordinaciji i znanstvenom vođenju svih projektnih aktivnosti. Njegova odgovornost uključuje dizajn sustava za digitalno prikupljanje i analizu podataka te razvoj modela umjetne inteligencije za obradu spektralnih informacija. Sudjelovat će u radnim paketima 1, 2 i 5, gdje će osigurati tehničku i znanstvenu usklađenost razvojnih i primijenjenih komponenti projekta.

2. Istraživač:
izv. prof. dr. sc. Tomislav Matić, radno mjesto: izvanredni profesor, 100% zaposlen na ustanovi Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
Poveznice: CroRis, GoogleScholar
Kompetencije: Tomislav Matić ima bogato iskustvo u području računalnog vida, obrade digitalne slike u stvarnom vremenu i programiranja na GPGPU arhitekturama. Znanstveni rad uključuje napredne algoritama za segmentaciju i klasifikaciju slika te izradu prototipnih sustava za automatsku analizu i kontrolu kvalitete u industriji. Ističe se kao koautor rada "Sugar/ethanol level measurement in liquids using analog refractometer and digital image processing" (ELMAR 2022), gdje je sudjelovao u razvoju inovativne metode za mjerenje razine šećera i etanola u tekućinama korištenjem digitalne obrade slike. Ova metoda omogućuje automatizirano i daljinsko praćenje ključnih parametara fermentacije, važnih za suvremenu proizvodnju vina.
Uloga u provedbi projekta: Tomislav Matić usmjeren je na razvoj i optimizaciju algoritama digitalne obrade slike, s posebnim naglaskom na integraciju AI metoda u funkcionalnosti digitalne platforme. Njegov doprinos bit će ključan u radnim paketima 2, 4 i 5, gdje će raditi na integraciji modela strojnog učenja te testiranju funkcionalnosti platforme u stvarnim uvjetima.

3. Istraživač:
doc. dr. sc. Ivan Vidović, radno mjesto: docent, 100% zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Poveznice: CroRis, GoogleScholar
Kompetencije: Ivan Vidović ima izražene kompetencije u području robotike, računalnog vida i automatizacije u digitalnoj poljoprivredi. Njegov znanstveni rad usmjeren je na razvoj naprednih sustava računalnog vida i automatiziranih rješenja za prepoznavanje i obradu objekata, što je potvrđeno njegovim publikacijama i citatima u području robotike i poljoprivredne automatizacije. Njegov članak "A nearest neighbor approach for fruit recognition in RGB-D images based on detection of convex surfaces" (2018) predstavlja razvoj naprednih metoda računalnog vida i umjetne inteligencije za automatsko prepoznavanje i klasifikaciju plodova u složenim, neuređenim okruženjima.
Uloga u provedbi projekta: Ivan Vidović bit će zadužen za primjenu metoda računalnog vida i razvoj sustava za automatizirano prikupljanje podataka. Sudjelovat će u integraciji senzorskih sustava i njihovom povezivanju s digitalnom infrastrukturom. Njegove aktivnosti bit će usmjerene na radne pakete 3, 4 i 5, posebno u segmentima validacije i vizualizacije podataka.

4. Istraživač:
prof.dr.sc. Tomislav Keser, radno mjesto: redoviti profesor, 100% zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Poveznice: CroRis, GoogleScholar
Kompetencije: Tomislav Keser je u posljednjih pet godina ostvario značajne rezultate u području primjene digitalnih tehnologija i automatizacije u industrijskim i biotehničkim procesima, s posebnim naglaskom na vinsku industriju. Kao koautor rada "Automated Titration of SO_2 in the Winery Environment: Conceptual Design and Proof of Concept"

(OTO 2023), sudjelovao je u razvoju i eksperimentalnoj validaciji automatiziranog sustava za titraciju sumpor-dioksida u vinu, što pokazuje njegovu stručnost u razvoju hardversko-softverskih rješenja za preciznu analizu vinskih parametara. Također je surađivao na radu "RS485 Network Design and Maintenance in Food Processing Industry: A Winery Application", gdje je doprinosio razvoju i testiranju komunikacijskih mreža za pametno mjerenje i nadzor procesa u vinskim podrumima. U radu "Winery monitoring system: A semi-automated solution for product quality maintenance and production assistance" (OTO 2022) sudjelovao je u razvoju poluautomatiziranog sustava za praćenje i održavanje kvalitete proizvoda, što dodatno potvrđuje njegovu ekspertizu u digitalizaciji i optimizaciji proizvodnih procesa u vinarstvu. U članku "Propagation of Radio Waves in Wine Cellars" (IWSSIP 2023) analizirao je izazove i mogućnosti bežične komunikacije u vinskim podrumima, čime je dao doprinos razvoju IoT infrastrukture za digitalni nadzor i upravljanje procesima. Osim toga, kao koautor rada "A low-cost buoyant force measurement device for monitoring sugar concentration in water solution" (ICECCME 2023), sudjelovao je u razvoju pristupačnog uređaja za praćenje koncentracije šećera, što je ključno za automatizirano upravljanje fermentacijom.
Uloga u provedbi projekta: Tomislav Keser doprinosi projektu svojim stručnim znanjima iz područja IoT tehnologija i automatizacije. Bit će odgovoran za razvoj povezanih senzorskih sustava te implementaciju sustava u laboratorijskim i terenskim uvjetima. Sudjelovat će u radnim paketima 1, 3 i 5, gdje će omogućiti operativnu povezanost hardverskih i softverskih elemenata projekta.

5. Istraživač:
prof.dr.sc. Damir Blažević, radno mjesto: redoviti profesor, 100% zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Poveznice: CroRis, GoogleScholar
Kompetencije: Damir Blažević je u posljednjih pet godina ostvario značajne rezultate u području digitalizacije i automatizacije industrijskih procesa, s posebnim naglaskom na primjenu naprednih metoda analize podataka i IoT tehnologija. Posebno je relevantan njegov koautorski rad "Automated Titration of SO_2 in the Winery Environment: Conceptual Design and Proof of Concept" (OTO 2023), u kojem je sudjelovao u razvoju i eksperimentalnoj validaciji automatiziranog sustava za titraciju sumpor-dioksida u vinu. Ovaj rad potvrđuje njegovu stručnost u integraciji senzorskih i digitalnih rješenja za precizno praćenje i kontrolu ključnih parametara u enološkim procesima.
Uloga u provedbi projekta: Damir Blažević usmjeren je na analizu senzorskih podataka i razvoj sustava za potporu odlučivanju temeljenih na modelima strojnog učenja i umjetne inteligencije. Sudjelovat će u implementaciji digitalne platforme i osiguravanju točnosti rezultata. Njegove aktivnosti uključuju radne pakete 2, 3 i 5, s naglaskom na povezanost obrade podataka i korisničkog sučelja.

6. Istraživač:
Josip Zidar, mag.ing.comp. radno mjesto: asistent, 100% zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Poveznice: CroRis, GoogleScholar
Kompetencije: Josip Zidar je istraživač s iskustvom u području ugradbenih računalnih sustava, mikroupravljača sa ultra-niskom potrošnjom električne energije te senzorskih

mreža, što potvrđuju njegovi znanstveni radovi u zadnjih pet godina. Posebno se ističe doprinos u razvoju pametnih senzorskih rješenja za praćenje okolišnih uvjeta i optimizaciju procesa, što je izuzetno važno za digitalnu transformaciju u enologiji.
Uloga u provedbi projekta: Josip Zidar fokusirat će se na dizajn i razvoj senzorskih sklopova, uključujući fizičku integraciju senzora s pratećim elektroničkim komponentama. Njegov doprinos u radnim paketima 1, 3 i 5 bit će ključan za uspostavu robusne hardverske infrastrukture potrebne za akviziciju podataka.

7. Istraživač:
Ivana Kovačević, mag.ing.comp., radno mjesto: asistent, 100% zaposlena na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Poveznice: CroRis, GoogleScholar
Kompetencije: Ivana Kovačević je član projektnog tima s iznimnim znanstvenim i praktičnim iskustvom u području proizvodnje vina, analize vinskih parametara i primjene umjetne inteligencije u enologiji. U posljednjih pet godina objavila je više radova koji izravno potvrđuju njezinu stručnost. Posebno se ističe rad "Predicting the Specific Gravity of Must During Fermentation Using Machine Learning Models" (OTO 2023), u kojem je razvila i validirala modele strojnog učenja za predviđanje specifične gustoće mošta tijekom fermentacije na temelju stvarnih podataka iz hrvatskih vinarija. U radu "RS485 Network Design and Maintenance in Food Processing Industry: A Winery Application" (OTO 2023) bavi se dizajnom i održavanjem industrijskih komunikacijskih mreža u vinskoj industriji, što je temelj za digitalizaciju i automatizaciju procesa. Kao koautorica rada "A low-cost buoyant force measurement device for monitoring sugar concentration in water solution" (ICECCME 2023), sudjelovala je u razvoju inovativnog uređaja za praćenje koncentracije šećera, dok je u radu "Propagation of Radio Waves in Wine Cellars" (IWSSIP 2023) analizirala mogućnosti bežične komunikacije u vinskim podrumima, važne za implementaciju IoT rješenja. U članku "Modelling the Fermentation Process in Winemaking using Temperature and Specific Gravity" (CECIIS 2023) fokusira se na modeliranje fermentacije koristeći temperaturne podatke i specifičnu gustoću, a u radu "Sugar/ethanol level measurement in liquids using analog refractometer and digital image processing" (ELMAR 2022) razvija metode za automatizirano mjerenje šećera i etanola u vinima. Također, u radu "Winery monitoring system: A semi-automated solution for product quality maintenance and production assistance" (OTO 2021) sudjelovala je u razvoju sustava za nadzor i održavanje kvalitete proizvoda u vinarijama.
Uloga u provedbi projekta: Ivana Kovačević radit će na razvoju i evaluaciji modela strojnog učenja za analizu enoloških parametara te integraciji senzora s industrijskim komunikacijskim protokolima. Njezine aktivnosti bit će usmjerene na radne pakete 2, 4 i 5, gdje će pridonijeti izgradnji skalabilnog i interoperabilnog sustava.

8. Istraživač:
mr. sc. Željko Štanfel, radno mjesto: predavač, 100% zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
Poveznice: CroRis, GoogleScholar].
Kompetencije: Željko Štanfel je znanstvenik s dugogodišnjim iskustvom u području digitalne obrade signala, industrijske automatizacije i komunikacijskih tehnologija. Njegova ekspertiza obuhvaća projektiranje, razvoj i integraciju automatiziranih i

distribuiranih sustava upravljanja, kao i implementaciju pouzdanih komunikacijskih rješenja u industrijskim okruženjima.
Uloga u provedbi projekta: Željko Štanfel sudjelovat će u razvoju digitalne platforme za prikupljanje, analizu i vizualizaciju podataka. Njegova uloga obuhvaća radne pakete 1, 3 i 5, gdje će se fokusirati na stabilnost i pouzdanost komunikacije unutar integriranog sustava.

Sažetak projekta (najviše 200 riječi)

Projekt WineAI bavi se razvojem inovativnih digitalnih rješenja za optimizaciju proizvodnje vina primjenom infracrvene spektroskopije i algoritama umjetne inteligencije. U fokusu je razvoj prototipa inovativnog spektrometrijskog uređaja za analizu enoloških parametara. Prototip koristi specifične valne duljine za detekciju kemijskih parametara vina, kao što su sadržaj šećera, alkohola i potencijalno ostalih bitnih parametara vina, te njihovu obradu pomoću strojnog učenja za preciznu karakterizaciju proizvoda. Primjenom FTIR spektrometra identificirat će se najvažnije valne duljine za pojedino vino određenog vinara, na temelju kojih će se razviti inovativni prototip optoelektroničkog sustava s LED emiterima i fotodetektorima, čime se omogućuje selektivno mjerenje apsorpcije svjetla na specifičnim valnim duljinama. Projekt uključuje izradu centralizirane digitalne platforme otvorenog pristupa za prikupljanje i analizu podataka u stvarnom vremenu, razvoj algoritama za automatizirano odlučivanje te primjenu računalnog vida za vizualnu kvantifikaciju parametara poput boje vina i pH vrijednosti. Svi prikupljeni podaci bit će strukturirano pohranjeni u bazu podataka te korišteni za daljnju znanstvenu obradu, dok će projekt uključiti i niz edukativnih aktivnosti s ciljem prijenosa znanja. Projekt WineAI odgovara na potrebu vinske industrije za povećanjem efikasnosti kroz digitalnu transformaciju, uz naglasak na dostupnost tehnologije manjim proizvođačima. Projekt traje 48 mjeseci i okuplja tim stručnjaka s FERIT-a.

Cilj projekta (navesti glavne ciljeve projekta povezane s programskim pokazateljima i strateškim ciljevima programskog financiranja i dodatne ciljeve koji se odnose na predloženo istraživanje)

Strateški cilj: 1. Podizanje znanstvene izvrsnosti;
Posebni cilj: 1.1. Povećanje sudjelovanja javnih visokih učilišta i javnih znanstvenih instituta u kompetitivnom projektnom financiranju
Pokazatelj: Broj znanstvenih radova u SCOPUS i WoS, A1 časopisima te međunarodno recenziranim zbornicima za društvene i humanističke znanosti te umjetničko područje

Projekt WineAI izravno doprinosi ostvarenju strateškog cilja 1. Podizanje znanstvene izvrsnosti kroz multidisciplinarni pristup koji objedinjuje primjenu naprednih digitalnih tehnologija, umjetne inteligencije i senzorskih sustava u kontekstu enološke proizvodnje. Posebni cilj 1.1., Povećanje sudjelovanja javnih visokih učilišta i javnih znanstvenih instituta u kompetitivnom projektnom financiranju, ostvaruje se prijavom i provedbom ovog istraživačkog projekta unutar konkurentnog institucionalnog natječaja, čime se FERIT aktivno pozicionira kao relevantna istraživačka sastavnica u nacionalnom znanstvenom prostoru. Projektni tim predviđa objavu najmanje tri znanstvenih radova u časopisima

indeksiranim u bazama SCOPUS i WoS, uključujući A1 časopise, kao i sedam znanstvenih radova međunarodno recenziranim zbornicima znanstvenih skupova. Time se izravno ostvaruje pokazatelj uspješnosti, a doprinosi se i širenju znanstvene baze znanja u području digitalne enologije i pametne poljoprivrede.

Sadržaj, ciljevi i metodologija projekta u potpunosti su usklađeni sa Strategijom Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek, koja naglašava važnost digitalne transformacije, primijenjenog istraživanja, interdisciplinarnosti i internacionalizacije znanstvenog rada.

Opis projekta (opisati trenutno stanje istraživanja – eng. „state of the art", metodologiju, svrhu i opravdanost istraživanja i njegovu inovativnost, razradu projekta po radnim paketima, literaturu, upravljanje rizicima, uključivanje mladih istraživača i studenata)

Trenutno stanje istraživanja - State of the Art

Digitalizacija u proizvodnji vina podrazumijeva integraciju naprednih tehnologija za praćenje, upravljanje i optimizaciju različitih parametara tijekom cijelog proizvodnog procesa, s ciljem povećanja učinkovitosti, bolje kontrole kvalitete i održivosti. Implementacijom digitalnih alata omogućuje se prikupljanje i analiza podataka u stvarnom vremenu, čime se značajno unaprjeđuje donošenje odluka i upravljanje proizvodnim procesima. Posebno važnu ulogu imaju senzori koji se koriste za praćenje okolišnih i procesnih parametara u vinogradima i vinarijama, uključujući nadzor klime, stanja tla, procesa fermentacije i kontrole kvalitete (Pascoal et al., 2024; Tardáguila et al., 2021; Domínguez-Renedo et al., 2023). Tehnologije poput multispektralnog i hiperspektralnog snimanja te elektrokemijski i optoelektronički senzori koriste se za analizu ključnih enoloških parametara, poput koncentracije šećera, alkohola, fenolnih spojeva i kiselina (Hosnedlova et al., 2020; Vasilescu et al., 2019; Márquez et al., 2015, 2016).

Umjetna inteligencija (AI) i modeli strojnog učenja (ML) postaju sve značajniji alati u proizvodnji vina, s primjenjom u predviđanju kvalitete vina, optimizaciji proizvodnje te poboljšanju karakterizacije vina (Newlands, 2021, 2022; Florea et al., 2022). Korištenjem metoda poput Gradient Boosting Regressor (GBR), Support Vector Machine (SVM) i Extreme Gradient Boosting (XGB) moguće je objektivno i precizno predviđanje kvalitete vina na temelju kemijskih svojstava, nadmašujući tradicionalne metode subjektivnih procjena (Dahal i Gaire, 2021; Jindal i Gill, 2024; John et al., 2024; Gupta, 2018).

Spektroskopske metode kao što su bliska infracrvena (NIR), srednja infracrvena (MIR), zajedno s Fourier-transform infracrvenom spektroskopijom (FTIR), sve više se primjenjuju za brzo, neinvazivno i točno praćenje sastava grožđa i vina tijekom proizvodnje, čime se postiže bolja kontrola procesa i kvalitete (Santos et al., 2017; Thanasi et al., 2022; Yun et al., 2023; Fuentes et al., 2020). Integracija spektroskopije s naprednim AI alatima omogućuje učinkovitu i ranu detekciju procesa kvarenja vina, autentifikaciju proizvoda i preciznu klasifikaciju porijekla vina (Viejo i Fuentes, 2022; Yao et al., 2023).

Razvoj prijenosnih instrumenata i naprednih senzorskih tehnologija, kao što su uređaji bazirani na nanotehnologiji i miniaturizirani senzori, dodatno olakšava terensku primjenu te decentralizaciju analitičkih mogućnosti (Fursman et al., 2024; Coppey et al., 2020, 2023; Shrake et al., 2014; Gallego-Martínez et al., 2024). Nove generacije senzora omogućavaju precizniju analizu i optimizaciju ključnih procesa kao što su fermentacija i

skladištenje vina, a bežične komunikacije i IoT tehnologije osiguravaju kontinuirano praćenje uvjeta u stvarnom vremenu, čak i u zahtjevnim uvjetima vinskih podruma (Kaučić et al., 2023; Rimac-Drlje et al., 2023; Kovačević et al., 2021, 2022, 2023; Keser et al., 2024).

Nastavak istraživanja usmjeren je na daljnje unapređenje preciznosti spektroskopskih metoda i algoritama strojnog učenja, širenje opsega podataka uključenih u analizu te poboljšanje integracije senzorskih sustava s digitalnim platformama radi povećanja njihove primjenjivosti i učinkovitosti u vinskoj industriji.

Metodologija

Metodologija projekta WineAI temelji se na sustavnom i integriranom pristupu, kombinira spektroskopske metode, napredne senzorske tehnologije i algoritme strojnog učenja u svrhu optimizacije procesa proizvodnje vina. Metodološki pristup organiziran je kroz međusobno povezane radne pakete koji omogućuju učinkovito postizanje ciljeva projekta.

Koristit će se Fourier-transform infracrvena spektroskopija (FTIR) za detaljnu analizu spektralnih odziva različitih uzoraka vina. U radnom paketu 1, cilj je identificirati specifične valne duljine infracrvenog svjetla, specifične za određenu sortu vina kod određenog vinara, koje omogućuju pouzdanu detekciju ključnih enoloških parametara poput sadržaja šećera, alkohola, kiselina i drugih spojeva važnih za kvalitetu vina. Rezultati ove analize poslužit će kao temelj za daljnji razvoj optoelektroničkih senzora. Na temelju identificiranih spektralnih značajki slijedi razvoj inovativnog senzorskog sustava temeljenog na LED izvorima svjetla i fotodetektorima prilagođenim specifičnim valnim duljinama. Sustav će biti optimiziran za precizno mjerenje apsorpcije infracrvenog zračenja u realnim industrijskim uvjetima, uključujući odabir komponenti, projektiranje optičkog sklopa, izradu funkcionalnog prototipa te njegovu kalibraciju i validaciju.

Nakon izrade senzorskog sustava, u radnom paketu 2, prikupljat će se eksperimentalni podaci iz realnih uvjeta proizvodnje vina. Ti podaci poslužit će za treniranje naprednih modela strojnog učenja poput neuronskih mreža, Gradient Boosting Regressora i Support Vector Machine algoritama. Cilj ovog koraka je izgradnja robusnih prediktivnih modela sposobnih za precizno određivanje koncentracije ciljnih spojeva u vinima.

Razvijeni senzorski sustavi bit će integrirani s centraliziranom digitalnom platformom koja omogućava prikupljanje, pohranu i analizu podataka u stvarnom vremenu kroz radni paket 3. Platforma će koristiti IoT komunikacijske protokole poput MQTT i HTTP za učinkovito povezivanje senzora i sustava za pohranu podataka, omogućavajući automatizirano donošenje odluka i pružanje preporuka vinarima.

Kako bi se dodatno optimizirao proces analize, u radnom paketu 4 će se razvijati rješenje temeljeno na računalnom vidu za kvantitativno određivanje parametara poput pH vrijednosti vina korištenjem kolorimetrijskih trakica. Ova metoda koristi mikroupravljački sustav za snimanje te napredne algoritme digitalne obrade slike za pouzdano očitanje parametara u terenskim uvjetima.

Razvijeni senzorski sustavi i algoritamska rješenja će se validirati u radnom paketu 5, kroz laboratorijske i terenske eksperimente u suradnji s lokalnim vinarskim proizvođačima. Istovremeno, projekt će uključivati edukativne aktivnosti poput radionica, webinara te izradu završnih i diplomskih radova u svrhu prijenosa znanja na studente i

istraživače. Svi rezultati projekta bit će objavljeni u znanstvenim časopisima i prezentirani na konferencijama kako bi se omogućio širi znanstveni i industrijski utjecaj projekta.

Svrha i opravdanost istraživanja

Svrha projekta WineAI je odgovoriti na rastuće potrebe vinske industrije za učinkovitim, pristupačnim i preciznim metodama praćenja i optimizacije procesa proizvodnje vina. Tradicionalne metode kontrole kvalitete često su dugotrajne, skupe i zahtijevaju specijaliziranu laboratorijsku infrastrukturu, što ograničava njihovu primjenu, osobito kod manjih proizvođača. Projekt stoga ima za cilj razviti inovativne senzorske sustave temeljene na infracrvenoj spektroskopiji i naprednim algoritmima umjetne inteligencije, koje omogućuju brzu, pouzdanu i ekonomičnu analizu ključnih enoloških parametara kao što su koncentracije šećera, alkohola i kiselina. Korištenjem digitalne platforme i IoT tehnologija omogućit će se prikupljanje i analiza podataka u stvarnom vremenu, što će pridonijeti donošenju kvalitetnijih odluka tijekom cijelog procesa proizvodnje vina. Opravdanost istraživanja proizlazi iz potrebe za suvremenim digitalnim alatima koji su pristupačni manjim vinarijama, što će povećati njihovu konkurentnost, održivost i kvalitetu proizvoda te u konačnici doprinijeti jačanju cjelokupne vinske industrije u Hrvatskoj i šire.

Inovativnost istraživanja

Projekt WineAI odlikuje se visokom razinom inovativnosti kroz integraciju naprednih metoda umjetne inteligencije s infracrvenom spektroskopijom u kontekstu proizvodnje vina. Glavna inovacija projekta leži u razvoju prilagođenog, pristupačnog senzorskog sustava temeljenog na diskretnim optoelektroničkim komponentama (LED emiteri i fotodetektori). Oni omogućuje ciljanu i selektivnu analizu kemijskih parametara vina u stvarnom vremenu. Nadalje, implementacija algoritama strojnog učenja (npr. Gradient Boosting, neuronske mreže) omogućuje visok stupanj automatizacije i preciznosti analize, smanjujući troškove te povećavajući dostupnost ovakvih tehnologija manjim i srednjim vinarijama. Osim tehnoloških inovacija, projekt uključuje razvoj otvorene digitalne platforme koja povezuje senzorske sustave s AI modelima, omogućavajući kontinuirano unaprjeđenje enoloških procesa kroz aktivno korištenje podataka u operativnim uvjetima.

Radni paketi

Radni paket 1. Spektroskopska analiza i selekcija valnih duljina za razvoj diskretnog optoelektroničkog senzora

Cilj ovog radnog paketa je identificirati ključne valne duljine u infracrvenom spektru koje omogućuju pouzdanu detekciju relevantnih enoloških parametara (npr. šećera, alkohola, kiselina, i sl.) pomoću FTIR spektroskopije na uzorcima specifičnih vina pojedinih vinara. Na temelju dobivenih rezultata razvijat će se inovativni spektrometrijski senzor za selektivno mjerenje apsorpcije zračenja na tim valnim duljinama.

U okviru aktivnosti provest će se priprema uzoraka i standardizacija uvjeta mjerenja, FTIR analiza vina različitih karakteristika te statistička obrada spektralnih podataka (npr. PCA, korelacijska analiza, i sl.). Nakon određivanja optimalnih valnih duljina, slijedi tehnički razvoj senzora koji uključuje odabir i testiranje komponenti (LED

emitera i fotodetektora), projektiranje optičkog sklopa, izrada prototipa te kalibracija i elektroničko testiranje. U završnoj fazi planirana je mehanička integracija, uključujući izradu kućišta i optimizaciju optičke geometrije.

Aktivnosti:

- Identifikacija optimalnih valnih duljina na temelju FTIR spektralne analize
- Odabir LED emitera, fotodetektora i pojačala za ciljana spektralna područja
- Projektiranje i izrada prototipa inovativnog spektrometrijskog uređaja
- Kalibracija i testiranje elektroničkih i optičkih komponenti
- Mehanička integracija: kućište, leće, optička stabilnost

Isporučivo:

- Izvještaj o spektralnoj karakterizaciji vina
- Popis prioritetnih valnih duljina po tipu vina
- Funkcionalni prototip senzorskog sustava
- Tehnička dokumentacija izrađenog sklopa

Radni paket 2. Razvoj AI modela za interpretaciju podataka

Razvoj i implementacija modela strojnog učenja za procjenu kemijskih parametara vina na temelju snimljenih podataka.

Aktivnosti:

- Prikupljanje podataka za treniranje modela
- Odabir algoritama strojnog učenja i umjetnih neuronskih mreža
- Evaluacija performansi (RMSE, MAE, R^2, i sl.)
- Implementacija modela u digitalno sučelje

Isporučivo:

- Validirani AI modeli
- Izvještaj o evaluaciji modela

Radni paket 3. Digitalna platforma i integracija podataka

Razvoj centralizirane digitalne platforme otvorenog pristupa za prikaz i analizu mjerenja u realnom vremenu.

Aktivnosti:

- Dizajn web sučelja i baze podataka
- Implementacija IoT komunikacijskih protokola
- Integracija senzora, AI modela i vizualizacija
- Sigurnosna i funkcionalna testiranja

Isporučivo:

- Digitalna platforma spremna za upotrebu
- Izrada dokumentiranog korisničkog priručnika

Radni paket 4. Digitalna obrada slike za kvantifikaciju pH vrijednosti vina

Cilj ovog radnog paketa je razvoj i validacija metode za kvantitativno određivanje pH vrijednosti vina korištenjem kolorimetrijskih trakica i digitalne obrade slike. Ova metoda omogućuje vizualno očitavanje pH bez potrebe za klasičnim pH metrom, čime se pojednostavljuje terensko i automatizirano mjerenje.

Tehnička realizacija temelji se na korištenju mikroupravljačkog sustava sa ugrađenom kamerom za snimanje kolorimetrijskih trakica nakon kontakta s vinskim uzorkom. Razvijat će se algoritmi za obradu slike koji uključuju segmentaciju, identifikaciju boje indikatorskog polja i konverziju RGB podataka u numeričku pH vrijednost. Poseban naglasak bit će na standardizaciji uvjeta osvjetljenja, pozadinske korekcije te korekcije boje radi postizanja konzistentnih rezultata u različitim vanjskim uvjetima. Sustav će se validirati usporedbom s referentnim pH mjerenjima.

Aktivnosti:

- Dizajn mikroupravljačkog sustava za snimanje kolorimetrijskih trakica
- Razvoj algoritama za segmentaciju slike i ekstrakciju RGB/HSV vrijednosti
- Kalibracija metode s pomoću standardnih pH otopina i referentnih trakica
- Korekcija osvjetljenja i boje pozadine radi robusnosti metode
- Usporedba rezultata s klasičnim laboratorijskim metodama (pH metar)

Isporučivo:

- Funkcionalni prototip sustava za digitalno očitavanje pH vrijednosti
- Softverski modul za obradu slike i izračun pH
- Izvještaj o točnosti i reproducibilnosti metode

Radni paket 5. Validacija, edukacija i diseminacija

Validacija sustava u stvarnim uvjetima, organiziranje radionica i edukacija, diseminacija rezultata znanstvenoj i stručnoj zajednici.

Aktivnosti:

- Terensko testiranje kod vinara
- Usporedba s referentnim metodama
- Organizacija radionica i webinara
- Priprema znanstvenih i stručnih publikacija

Isporučivo:

- Izvještaj o validaciji sustava
- Održane radionice i edukacijski materijali
- Objavljeni znanstveni i stručni radovi

Literatura

Fursman, H. et al. (2024) "Development and evaluation of portable NIR technology for the identification and quantification of Australian illicit drugs," Forensic Science International, 362, p. 112179.

Gallego-Martínez, J.J. et al. (2024) "Devices for monitoring oenological processes: A review," Measurement, 235, p. 114922.

Izquierdo-Bueno, I. et al. (2024) "Smart Viniculture: Applying Artificial Intelligence for Improved Winemaking and Risk Management," Applied Sciences, 14(22). Available at:

Jindal, A. and Singh Gill, K. (2024) "From Vineyard Data to Flavour Profiles: Machine Learning Predicts Wine Quality," in 2024 12th International Conference on Internet of Everything, Microwave, Embedded, Communication and Networks (IEMECON), pp. 1–6.

John, A. et al. (2024) "Understanding Red Wine Quality with Feature Importance in Machine Learning and Explainable AI," in 2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT), pp. 1–6.

Keser, T. et al. (2024) "Automated Titration of SO2 in the Winery Environment: Conceptual Design and Proof of Concept," in T. Keser et al. (eds.) 32nd International Conference on Organization and Technology of Maintenance (OTO 2023). Cham: Springer Nature Switzerland, pp. 122–133.

Kovačević, I., Orić, M., et al. (2024) "Predicting the Specific Gravity of Must During Fermentation Using Machine Learning Models," in T. Keser et al. (eds.) 32nd International Conference on Organization and Technology of Maintenance (OTO 2023). Cham: Springer Nature Switzerland, pp. 351–363.

Kovačević, I., Matić, T., et al. (2024) "RS485 Network Design and Maintenance in Food Processing Industry: A Winery Application," in T. Keser et al. (eds.) 32nd International Conference on Organization and Technology of Maintenance (OTO 2023). Cham: Springer Nature Switzerland, pp. 134–142.

Pascoal, D. et al. (2024) "A technical survey on practical applications and guidelines for IoT sensors in precision agriculture and viticulture," Sci. Rep., 14(1), p. 29793.

Coppey, F. et al. (2023) "Cloud-Enabled Handheld NIR Spectroscopy: A Transformative Approach for Real-Time Forensic Analysis of Cannabis Specimens," Helvetica Chimica Acta, 106(8), p. e202300052.

Domínguez-Renedo, O. et al. (2023) "Current state of electrochemical sensors in wine analysis for early diagnosis," TrAC Trends in Analytical Chemistry, 168, p. 117349.

Kaučić, L. et al. (2023) "A low-cost buoyant force measurement device for monitoring sugar concentration in water solution," in 2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME), pp. 1–6.

Rimac-Drlje, S. et al. (2023) "Propagation of Radio Waves in Wine Cellars," in 2023 30th International Conference on Systems, Signals and Image Processing (IWSSIP), pp. 1–5.

Yao, J. et al. (2023) "Wine Characterisation with Spectral Information and Predictive Artificial Intelligence," in M. Tanveer et al. (eds.) Neural Information Processing. Singapore: Springer Nature Singapore, pp. 247–259.

Florea, A., Sipos, A. and Stoisor, M.-C. (2022) "Applying AI Tools for Modeling, Predicting and Managing the White Wine Fermentation Process," Fermentation, 8(4). Available at:

Gonzalez Viejo, C. and Fuentes, S. (2022) "Digital Assessment and Classification of Wine Faults Using a Low-Cost Electronic Nose, Near-Infrared Spectroscopy and Machine Learning Modelling," Sensors, 22(6). Available at:

Kovačević, I., Keser, T. and Miling, R. (2022) "Winery Monitoring System: A Semi-automated Solutions for Product Quality Maintenance and Production Assistance," in H. Glavaš et al. (eds.) 30th International Conference on Organization and Technology of Maintenance (OTO 2021). Cham: Springer International Publishing, pp. 414–424.

Kubat, T. et al. (2022) "Sugar/ethanol level measurement in liquids using analog refractometer and digital image processing," in 2022 International Symposium ELMAR, pp. 153–157.

Thanasi, Vasiliki, Catarino, Sofia and Ricardo-da-Silva, Jorge (2022) "Fourier transform infrared spectroscopy in monitoring the wine production," Ciência Téc. Vitiv., 37(1), pp. 79–99.

Gaire, S. (2021) "Prediction of Wine Quality Using Machine Learning Algorithms," Open Journal of Statistics, 11, pp. 278–289.

Newlands, N.K. (2021) Artificial Intelligence and Big Data Analytics in Vineyards: A Review. Edited by A. Morata, I. Loira, and C. González. Rijeka: IntechOpen.

Tardaguila, J. et al. (2021) "Smart applications and digital technologies in viticulture: A review," Smart Agricultural Technology, 1, p. 100005.

Coppey, F. et al. (2020) "Providing illicit drugs results in five seconds using ultra-portable NIR technology: An opportunity for forensic laboratories to cope with the trend toward the decentralization of forensic capabilities," Forensic Science International, 317, p. 110498.

Hosnedlova, B. et al. (2020) "Application of nanotechnology based-biosensors in analysis of wine compounds and control of wine quality and safety: A critical review," Critical Reviews in Food Science and Nutrition, 60(19), pp. 3271–3289.

Vasilescu, A. et al. (2019) "Progress in Electrochemical (Bio)Sensors for Monitoring Wine Production," Chemosensors, 7(4). Available at:

Gupta, Y. (2018) "Selection of important features and predicting wine quality using machine learning techniques," Procedia Computer Science, 125, pp. 305–312.

dos Santos, C.A.T., Páscoa, R.N.M.J. and Lopes, J.A. (2017) "A review on the application of vibrational spectroscopy in the wine industry: From soil to bottle," TrAC Trends in Analytical Chemistry, 88, pp. 100–118.

Jiménez-Márquez, F. et al. (2016) "Optoelectronic sensor for measuring ethanol content during grape must fermentation using NIR spectroscopy," Microsystem Technologies, 22(7), pp. 1799–1809.

Jiménez-Márquez, F. et al. (2015) "Optoelectronic sensor device for monitoring ethanol concentration in winemaking applications," in José Luis Sánchez-Rojas and R. Brama (eds.) Smart Sensors, Actuators, and MEMS VII; and Cyber Physical Systems. International Society for Optics and Photonics, p. 95171P.

Jiménez-Márquez, F., Vázquez, J. and Sánchez-Rojas, J.L. (2015) "Optoelectronic sensor device for monitoring the maceration of red wine: Design issues and validation," Measurement, 63, pp. 128–136.

Shrake, N.L. et al. (2014) "In-Line Measurement of Color and Total Phenolics during Red Wine Fermentations Using a Light-Emitting Diode Sensor," American Journal of Enology and Viticulture, 65(4), pp. 463–470.

Upravljanje rizicima

Istraživački tim ima iskustva s upravljanjem kompleksnim projektima, što dodatno umanjuje vjerojatnost negativnih utjecaja navedenih rizika na rezultate projekta.

Rizik	Stupanj vjerojatnosti	Učinak na projekt	Mjere za ublažavanje i izbjegavanje rizika
Kašnjenje u nabavi specijalizirane opreme	Srednja vjerojatnost	Srednji učinak	Detaljan plan nabave sa specifikacijama opreme i rokovima isporuke. Otvorena komunikaciju s dobavljačima o rokovima isporuke.
Moguće tehničke poteškoće pri integraciji senzorskih komponenti	Niska vjerojatnost	Nizak učinak	Redovita i pravovremena revizija te iterativno testiranje. Projektiranje na modularan način radi jednostavne zamjene problematičnih dijelova bez utjecaja na ostale komponente.
Nedostatnu točnost ili stabilnost algoritama u terenskim uvjetima	Srednja vjerojatnost	Srednji učinak	Uspostava jasnih procedura za kalibraciju i održavanje opreme te kontinuirana evaluacija i iterativno unaprjeđenje AI modela.

Uključivanje mladih istraživača i studenata

U istraživanje će se uključiti Lukrecia Vulić, mag.ing.comp., radno mjesto: asistent, 100% zaposlena na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek [poveznice: CroRis, GoogleScholar]. Lukrecia Vulić je stručnjak u području ugrađenih računalnih sustava i mikroupravljača s mogućnošću obrade podataka primjenom umjetne inteligencije, a u suradnji sa tvrtkom Infineon posebno je specijalizirana za primjenu PSOC™ Edge E84 sustava na čipu (SoC) za primjenu umjetne inteligencije.

U istraživačke aktivnosti bit će uključeni studenti kroz izradu najmanje pet završnih i diplomskih radova tematski povezanih s projektom. Osim toga, studenti će aktivno sudjelovati u organizaciji i provedbi edukativnih radionica te terenskih ispitivanja. Kao dio diseminacijskih aktivnosti, prezentirat će vlastite prototipove i makete razvijenih rješenja na izložbama i sajmovima inovacija, čime će se poticati njihovo istraživačko usmjerenje i razvoj praktičnih vještina.

Uključivanje vanjskih suradnika i administrativnog osoblja

U istraživanje će se uključiti Prof.dr.sc. Željko Hocenski, radno mjesto: vanjski suradnik na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Poveznice: CroRis, GoogleScholar].
Kompetencije: Prof.dr.sc. Željko Hocenski je prethodno vodio nacionalne i europske projekte s kojima se naš istraživački tim usavršio u području ugradbenih računalnih sustava, senzorskim sustavima sa ultra-niskom potrošnjom energije za praćenje parametara proizvoda u opskrbnom lancu dostave. U posljednjih pet godina ima h-index 14 te 750 citiranih radova.
Uloga u projektu: Željko Hocenski će sudjelovati u odabiru senzora, dizajnu računalnih sustava za prikupljanje i obradu podataka te primjeni inovativnih metoda za digitalnu obradu i analizu mjernih podataka. Njegova uloga obuhvaća radne pakete 1 i 5.

U istraživanje će se uključiti Miroslav Antunović, ing., radno mjesto: viši tehnički suradnik - viši laborant, 100% zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Kompetencije: Miroslav Antunović ima dugogodišnje iskustvo u održavanju laboratorijske, nastavne i istraživačke opreme.
Uloga u projektu: Bit će odgovoran za instalaciju, korištenje i održavanje nove računalne i laboratorijske opreme, sudjelovanje u edukacijama, kao i za razvoj i održavanje web aplikacija za prikupljanje i prikaz mjernih podataka. Njegova uloga obuhvaća radne pakete 3 i 5.

U istraživanje će se uključiti Marko Šarić, mag. ing. comp., radno mjesto: laborant, zaposlen na ustanovi: Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek.
Kompetencije: Marko Šarić ima iskustvo u održavanju tehničke i istraživačke opreme te programiranju aplikacija.
Uloga u projektu: Sudjelovat će u instalaciji, primjeni i održavanju nove računalne i laboratorijske opreme, pohađati relevantne edukacije te razvijati web aplikacije za vizualizaciju i upravljanje podacima dobivenim mjerenjem. Njegova uloga obuhvaća radne pakete 3 i 5.

Mjerljivi pokazatelji ostvarenja rezultata projekta (navesti popis očekivanih rezultata i mjerljivih pokazatelja uspješnosti provedenih istraživanja, objasniti njihov doprinos programskim pokazateljima navedenima u Uputama za prijavu i poveznicu s ciljevima i radnim planom projekta)

Znanstvene publikacije

- Objavljeno najmanje 3 izvorna znanstvena rada u znanstvenim časopisima indeksiranima u WoS/SCOPUS bazama

- Objavljivanje najmanje 7 znanstvenih radova na međunarodnim znanstvenim konferencijama

Razvoj prototipa senzorskog sustava

- Razvoj i validacija najmanje 2 funkcionalna prototipa senzorskog sustava za praćenje jednog ili više ključnih enoloških parametara, kao što su šećer, alkohol, pH i sl.

Digitalna platforma i baza podataka

- Uspostavljena digitalna platforma za prikupljanje, analizu i dijeljenje podataka.

Suradnja s gospodarstvom i industrijska primjena

- Provedena validacija razvijenog senzorskog sustava u najmanje jednoj vinariji
- Uspostavljena najmanje 1 trajna suradnja s industrijskim partnerima za daljnju primjenu rezultata

Uključivanje studenata i prijenos znanja

- Najmanje 5 završenih diplomskih ili završnih radova tematski povezanih s projektom
- Održane najmanje 2 radionice ili webinara za studente, istraživače i gospodarstvenike

Potrebna infrastruktura za provedbu projekta (navesti resurse potrebne za provedbu istraživanja, npr. laboratorije, instrumente, uređaje i ostalu opremu)

Postojeća oprema koja će se koristiti tijekom rada na projektu

- Postojeća računala i računalne radne stanice
- Specijalizirana industrijska računala za rad u industrijskim uvjetima
- Uređaj za lemljenje i odlemljivanje elektroničkih komponenti
- Digitalna mikroskopska lupa za lemljenje malih elektroničkih komponenti
- Laboratorijski izvor napajanja, osciloskop, funkcijski generator
- Logički analizator digitalnih elektroničkih sklopova
- Uređaj za precizno mjerenje iznimno malih struja radi mjerenja u području ultra-niske potrošnje električne energije
- Laserski rezač i 3D printer za izradu kućišta

Postojeća računalna infrastruktura i industrijska računala koristit će se za razvoj i testiranje softverskih aplikacija te integraciju AI algoritama. Osciloskopi, logički analizatori i uređaji za precizno mjerenje struja omogućit će detaljnu karakterizaciju senzora, dok će oprema za lemljenje i izradu prototipa (digitalni mikroskop, laserski rezač, 3D printer) biti ključna za brzu izradu i testiranje prototipnih komponenti i kućišta u laboratorijskim uvjetima.

Nova oprema koja je u planu nabave

- FTIR uređaj za dobivanje detaljnog infracrvenog spektra uzorka

- Laboratorijske propipete za precizno doziranje tekućine uzorka
- Vrhovi za propipete i ostali laboratorijski pribor potreban za doziranje tekućine
- Precizna digitalna vaga
- LED izvori diskretnih valnih duljina
- LED osjetnici za detekciju svjetla određene valne duljine
- Elektroničke komponente potrebne za izradu prototipa
- Računalne radne stanice
- Prijenosne računalne radne stanice
- Prijenosne mobilne radne stanice za testiranje mobilnih aplikacija
- Licence za računalne programe za pomoć pri pisanju znanstvenih radova
- Potrošne kemikalije za umjeravanje (glukoza, fruktoza, etanol, i sl.)
- Potrošni materijal za izradu prototipa (tinol, flux, filament, pleksiglas ploče, i sl.)
- Ostali potrošni laboratorijski materijal te sitna znanstvena oprema potrebna za realizaciju projekta

Nabava planirane opreme izravno je povezana s aktivnostima projekta i ključna je za uspješnu provedbu istraživačkih ciljeva unutar svih radnih paketa. FTIR spektrometar osigurat će analizu uzoraka određene sorte vina, kod određenog vinara, kako bi se napravila selekcija specifičnih valnih duljina za razvoj novog optoelektroničkog senzora, dok će laboratorijska oprema poput propipeta, vaga i potrošnih kemikalija (glukoza, fruktoza, etanol) omogućiti preciznu pripremu i standardizaciju uzoraka. LED izvori i fotodetektori koristiti će se za izradu prototipa senzora temeljenog na apsorpciji specifičnih valnih duljina, a elektroničke komponente i potrošni materijal potrebni su za sklapanje i testiranje funkcionalnih sklopova. Računalne radne stanice i prijenosna oprema omogućit će razvoj algoritama strojnog učenja, obradu spektroskopskih podataka, te implementaciju IoT sustava i digitalne platforme. Prijenosne mobilne radne stanice koristit će se u terenskim uvjetima za testiranje sustava i razvoj mobilnog sučelja za krajnje korisnike. Računalne licence za provjeru engleskog jezika te pretraživanje baza znanstvenih radova. Sva oprema nabavlja se u skladu s vremenskim okvirom projekta kako bi se osigurala pravovremena realizacija aktivnosti, validacija sustava u laboratorijskim i realnim uvjetima te osigurao visoki stupanj funkcionalnosti i primjenjivosti razvijenih rješenja.

Održivost rezultata (opisati plan za održavanje i korištenje rezultata projekta nakon njegovog završetka)

Održivost rezultata projekta temelji se na planiranoj diseminaciji, vidljivosti rezultata, stvaranju uvjeta za transfer tehnologije te uspostavi modela koji omogućuje tehničku, financijsku i institucionalnu održivost nakon završetka projektnih aktivnosti. Projektni tim osigurat će primjenjivost i dostupnost razvijenih rješenja putem znanstvene i industrijske diseminacije, uključujući objavu rezultata u otvorenim repozitorijima i održavanje web stranice koja će služiti kao središnja platforma za pristup podacima, dokumentaciji i softverskim rješenjima.

Tehnička održivost rezultata ostvarit će se uspostavom strukturiranog sustava za pohranu i upravljanje rezultatima istraživanja, uključujući pohranu spektralnih baza, modela strojnog učenja i tehničke dokumentacije u institucijskim i međunarodnim otvorenim repozitorijima. Time se osigurava dugoročna dostupnost podataka i njihova ponovna upotrebljivost u budućim istraživanjima i industrijskoj primjeni. Digitalna platforma razvijena u sklopu projekta bit će održavana i nadograđivana od strane tima kroz postojeću istraživačku infrastrukturu, čime se osigurava njezina primjenjivost i nakon završetka projekta.

Financijska održivost bit će osigurana kroz planirano prijavljivanje na dodatne nacionalne i europske pozive za financiranje istraživačko-razvojnih aktivnosti, s naglaskom na programe koji podržavaju transfer tehnologije i komercijalizaciju inovacija. Dodatno, dio aktivnosti održavanja i razvoja bit će podržan iz vlastitih institucionalnih sredstava te potencijalnih partnerstava s gospodarstvom. Predviđa se i evaluacija potencijala za zaštitu intelektualnog vlasništva i komercijalizaciju razvijenih rješenja kroz licenciranje ili pokretanje spin-off subjekata, čime se dodatno jača tržišna i ekonomska održivost projekta.

Institucionalna održivost ogleda se u unapređenju tehničkih i organizacijskih kapaciteta prijavitelja kroz nabavu suvremene istraživačke opreme, jačanje međusektorske suradnje te podizanje znanstvenih i stručnih kompetencija svih članova tima. Kroz integraciju projektnih rezultata u nastavne i istraživačke aktivnosti, uključujući studentske radove, stručne radionice i seminare, osigurava se kontinuiran prijenos znanja i stvaranje temelja za buduće istraživačke inicijative. Time se rezultati projekta trajno ugrađuju u istraživačko-obrazovnu misiju ustanove i osigurava njihov dugoročni učinak.

Ukupno tražena sredstva (EUR)

104.000,00 EUR
(3250 x 8 x 4)

Doprinos digitalnim istraživanjima (*opišite konkretne mjere ili aktivnosti digitalnih istraživanja koje će se provesti u okviru projekta* poput *korištenje digitalnih alata i tehnologija*).

1. Razvoj i implementacija digitalne platforme za centralizirano upravljanje distribuiranim senzorskim sustavima u vinogradarstvu i enologiji
Izradit će se centralizirana digitalna web platforma koja omogućuje daljinsko prikupljanje parametara vina s prikazom na mobilnom uređaju. Platforma će integrirati podatke iz različitih elektroničkih senzora te će omogućiti analizu prikupljenih podataka u realnom vremenu, s ciljem optimizacije procesa fermentacije, skladištenja i kvalitete vina. Sustav će biti dizajniran s podrškom za skalabilnost, omogućujući proširenje na više vinarskih lokacija i sustava.

2. Primjena naprednih algoritama umjetne inteligencije i strojnog učenja za automatizirano donošenje odluka
Inovativni prototip koristit će algoritme umjetne inteligencije i strojnog učenja za analizu prikupljenih podataka. AI algoritmi će procjenjivati parametre vina u realnom vremenu i time će pomoći vinaru da na jednostavan način izvodi potrebne radnje. Sustav će kontinuirano učiti i poboljšavati svoj model temeljen na stvarnim terenskim podacima.

3. Korištenje računalnog vida i digitalne obrade slike za kvantitativnu procjenu kemijskih parametara vina
Primijenit će se digitalna obrada slike u analizi pH vrijednosti vina korištenjem kolorimetrijskih trakica. Tehnologija digitalne obrade slike omogućuje objektivnu kvantifikaciju pH vrijednosti eliminirajući subjektivnost tradicionalne vizualne procjene. Prototipni sustav temeljen je na mikroupravljačkom sustavu, opremljenom integriranom kamerom i algoritmima za segmentaciju i analizu boje.

4. Digitalizacija, pohrana i analiza kompleksnih skupova podataka u cilju optimizacije enoloških procesa
Svi podaci prikupljeni tijekom terenskih eksperimenata (slike, senzorska mjerenja, zapisi o radu prototipa) sustavno će se pohranjivati u digitalnu bazu podataka. Razvijat će se specijalizirani alati za vizualizaciju i višedimenzionalnu analizu podataka, uključujući vremenske serije, toplinske mape i grafove ovisnosti između parametara. Analitička obrada omogućit će identificiranje kritičnih točaka u proizvodnom procesu i dati uvid u učinkovitost digitalnih sustava u stvarnim uvjetima. Rezultati će se koristiti za diseminaciju i znanstveno izvještavanje, kao i za donošenje odluka o daljnjem razvoju tehnologije i procesa.

5. Edukacija i prijenos znanja putem digitalnih alata
Organizirat će se tematski usmjerene radionice, online seminari (webinari) i edukativni video materijali namijenjeni studentima, istraživačima i praktičarima u sektoru vinogradarstva i enologije. Kroz upotrebu digitalnih platformi za e-učenje, sudionicima će biti omogućen pristup praktičnim znanjima o korištenju senzorskih sustava, interpretaciji podataka i primjeni umjetne inteligencije u poljoprivredi. Edukacija će uključivati primjere iz stvarnog okruženja, interaktivne simulacije te pristup kodovima i uputama za korištenje razvijenih alata. Na taj će se način osigurati prijenos znanja i povećanje digitalne pismenosti u ruralnim i stručnim zajednicama.

Uključuje li projekt istraživanja koja zahtijevaju odobrenje Etičkog povjerenstva?
DA ☐ NE ☒

Ako je odgovor DA opišite istraživanja koja zahtijevaju odobrenje Etičkog povjerenstva

Voditelj projekta	Čelnik sastavnice
_____	
_____	
izv.prof.dr.sc. Ivan Aleksi	prof.dr.sc. Tomislav Matić