



Sveučilište u Zagrebu

Fakultet šumarstva i drvne tehnologije

Nikola Zorić

**PRAĆENJE DINAMIKE OŠTEĆENJA HRASTA
LUŽNJAKA PROUZROČENIH HRASTOVOM
MREŽASTOM STJENICOM (*CORYTHUCHA
ARCUATA*) (HEMIPTERA; TINGIDAE) POMOĆU
BESPILOTNIH LETJELICA I HIBRIDNIH OPTIČKO-
EMPIRIJSKIH MODELA**

DOKTORSKI RAD

Zagreb, 2025. godina



Sveučilište u Zagrebu

Fakultet šumarstva i drvne tehnologije

Nikola Zorić

**PRAĆENJE DINAMIKE OŠTEĆENJA HRASTA
LUŽNJAKA PROUZROČENIH HRASTOVOM
MREŽASTOM STJENICOM (*CORYTHUCHA
ARCUATA*) (HEMIPTERA; TINGIDAE) POMOĆU
BESPILOTNIH LETJELICA I HIBRIDNIH OPTIČKO-
EMPIRIJSKIH MODELA**

DOKTORSKI RAD

Mentori: Izv.prof.dr.sc.Milivoj Franjević, Prof.dr.sc.Anita Šimić Milas

Zagreb, 2025. godina



Sveučilište u Zagrebu

Faculty of Forestry and Wood Technology

Nikola Zorić

**MONITORING THE DYNAMICS OF PEDUNCULATE
OAK DAMAGE CAUSED BY THE OAK LACE BUG
(CORYTHUCHA ARCUATA) (HEMIPTERA:
TINGIDAE) USING UNMANNED AERIAL VEHICLES
AND HYBRID OPTICAL-EMPIRICAL MODELS**

DOCTORAL DISSERTATION

Mentors: Izv. prof. dr. sc. Milivoj Franjević, Prof. dr. sc. Anita Šimić Milas

Zagreb, 2025. godine

PODACI O MENTORIMA

Izv. prof. dr. sc. Milivoj Franjević rođen je 22. svibnja 1977. godine u Zagrebu. Diplomirao je 18. ožujka 2003. godine diplomski rad: „Zdravstveno stanje divljeg kestena i napad kestenova moljca minera (Cameraria ohridella Deschka et Dimić) na području Zagreba u 2000. i 2001. godini“, mentor prof. dr. sc. Boris Hrašovec, a doktorirao je 15. lipnja 2012. godine doktorski rad: „Nove biotehničke metode integrirane zaštite hrastove oblovine“, mentor prof. dr. sc. Boris Hrašovec, područje biotehničke znanosti, polje šumarstvo, grana zaštita šuma. U zvanje docenta izabran je 03. veljače 2016. godine, a izvanrednog profesora izabran je 08. studenog 2022. godine. Od 3. travnja 2006. godine zaposlen je pri Zavodu za zaštitu šuma i lovno gospodarenje, Šumarskog fakulteta Sveučilišta u Zagrebu kao znanstveni novak na istraživačkom projektu Ministarstva znanosti, obrazovanja i športa: „Utjecaj kukaca i fitopatogenih gljiva na stabilnost šumskoga ekosustava - 0068115, Šumarski fakultet, MZT“. Akademске godine 2006/07. upisao je doktorski studij Šumarstvo, smjer Uzgajanje i uređivanje šuma s lovnim gospodarenjem. U znanstveno zvanje znanstvenog suradnika izabran je na 10. sjednici Matičnog odbora za područje biotehničkih znanosti održanoj 11. prosinca 2015. godine, U znanstveno-nastavno zvanje docenta izabran je 03. veljače 2016. godine. U znanstveno zvanje višeg znanstvenog suradnika izabran je na 17. sjednici Matičnog odbora za područje biotehničkih znanosti održanoj 9. travnja 2021. godine. Danas radi kao izvanredni profesor te mu je povjerena nastava, vježbe i terenska nastava iz kolegija Šumarska entomologija na preddiplomskom studiju Šumarstva i Primjenjena entomologija na preddiplomskom studiju Urbanog šumarstva zaštite prirode i okoliša, a u nastavi diplomskih studija iz predmeta Integrirana zaštita šuma, Fitofarmacija u šumarstvu i izbornom predmetu Gradacije i monitoring šumskih štetnika na diplomskom studiju Uzgajanje i uređivanje šuma s lovnim gospodarenjem predmetu, Integrirana zaštita šuma u zaštićenim područjima na diplomskom studiju Urbano šumarstvo, zaštita prirode i okoliša, te na predmetu Integrirana zaštita šuma i izbornom predmetu Šumski požari na diplomskom studiju Tehnike tehnologije i management u šumarstvu, na doktorskom studiju Šumarstvo idrvna tehnologija nositelj je predmeta Fluktuacije populacija šumskih kukaca na Šumarskom fakultetu Sveučilišta u Zagrebu. Sudjelovao je, u svojstvu voditelja ili suradnika, u znanstvenim projektima iz područja integrirane zaštite šuma i šumarske entomologije, uključujući istraživanja o utjecaju biotičkih čimbenika na vitalnost poljskog jasena, učincima invazivne hrastove mrežaste stjenice na šumske sastojine i klonske sjemenske plantaže te praćenju zdravstvenog stanja borovih kultura u NP Paklenica s obzirom na infestaciju borovim potkornjacima. Također, sudjeluje u istraživanju utjecaja klimatskih promjena na količinu i strukturu biomase obične jele i smreke. Član je Hrvatskog entomološkog društva, Hrvatskog šumarskog društva i Hrvatskog lovačkog saveza.

Prof. dr. sc. Anita Šimić Milas završila je preddiplomski studij znanosti o okolišu 1998. godine na Sveučilištu u Torontu. Magistarski rad iz geoinformacijskih znanosti obranjen 2002. godine na istom sveučilištu. Doktorat iz geoinformacijskih znanosti dovršen na Sveučilištu u Torontu 2009 godine.

Zaposlena je na Sveučilištu Bowling Green State (Ohio, SAD) od 2013. Najprije u zvanju docentice, zatim izvanredne profesorice i danas redovite profesorice geoinformacijskih znanosti. Gostujuća profesorica prostorne statistike bila je 2021. na Sveučilištu u Torontu. Iskustvo je stjecala i na Sveučilištu Victoria (Kanada), gdje je 2012. radila kao viša instruktorica geometrije. Na Sveučilištu u Torontu i Ryerson University u Torontu predavala je kolegije o daljinskim istraživanjima, GIS-u i hidrologiji. Gostujući predavač bila je i na Sveučilištu Wuhan (Kina). Kao poslijedoktorska istraživačica radila je u INRA institutu u Avignonu (Francuska), a kao znanstvenica za daljinska istraživanja u kanadskom Ministarstvu prirodnih resursa. Karijeru je započela kao stručnjakinja za geokemiju u tvrtki O'Connor Associates Environmental.

Istraživački interesi prof dr.sc. Šimić Milas usmjereni su na daljinska istraživanja u šumarstvu, preciznoj poljoprivredi i priobalnim te močvarnim ekosustavima, zatim na invertiranje modela prijenosa zračenja za proučavanje strukturalnih i biokemijskih svojstava vegetacije, kao i na upotrebu optičkih satelitskih snimaka za modele fizikalnih i kopnenih procesa te simulacije hidroloških komponenti. Koristi metode strojnog učenja za regresiju i klasifikaciju u istraživanjima vegetacije i kakvoće vode, s naglaskom na podatke različitih prostorno-spektralnih rezolucija. Dodatne teme uključuju primjenu daljinskih istraživanja za analizu vodenih tijela i kakvoće vode (sedimenti, alge), urbanu problematiku, slijeganje tla i kartiranje snijega, koristeći multispektralne i hiperspektralne senzore sa satelita ili bespilotnih letjelica te radarske podatke. Razvila je koncept inovativne fuzije podataka kojim se istodobno dobivaju strukturni i biokemijski parametri vegetacije kombiniranjem hiperspektralnih i višekutnih mjerena, a isto je prijavljeno kao patent u SAD-u.

Vodila je ili sudjelovala u brojnim međunarodnim projektima. U SAD-u je glavni istraživač NSF projekta o integriranju geoprostorne pismenosti u visoko obrazovanje, kao i višegodišnjih projekata agencije USGS/AmericaView za uspostavu državnog satelitskog programa za Ohio. U sklopu NOAA projekta proučavala je ekološku otpornost obalnih ekosustava jezera Erie. U Hrvatskoj surađuje na projektima Hrvatskoga šumarskog instituta o preciznoj inventuri šuma te primjeni 3D optičkih podataka, financiranim od Hrvatske zaklade za znanost. Sudjelovala je i u programu Svjetske banke i Ministarstva znanosti RH, istražujući daljinska istraživanja u vinogradima i maslinicima. U ranim fazama karijere provela je projekt Kanadske svemirske agencije o kombiniranju hiperspektralnih i višekutnih podataka za kartiranje vegetacije.

SAŽETAK

Hrastova mrežasta stjenica (*Corythucha arcuata*) predstavlja ozbiljan problem za hrastove šume, uzrokujući smanjenje fotosintetske aktivnosti, fiziološki stres i dugoročno narušavanje stabilnosti sastojina. Tradicionalne metode praćenja infestacija oslanjaju se na terenske preglede koji su često dugotrajni i podložni subjektivnim procjenama, stoga se daljinska istraživanja pomoću multispektralnih podataka prikupljenih bespilotnim letjelicama (UAV) ističu kao učinkovita metoda za preciznu i brzu procjenu zdravstvenog stanja šuma. Cilj ovog istraživanja bio je razviti i evaluirati metode za praćenje promjena u koncentraciji klorofila u krošnjama hrasta lužnjaka pod utjecajem infestacije hrastovom mrežastom stjenicom. Postavljene su dvije hipoteze: (1) da multispektralne UAV snimke mogu pouzdano detektirati fiziološke promjene u krošnjama uzrokovane infestacijom te (2) da kombinacija modela prijenosa radijacije (PROSAIL) i strojnog učenja može poboljšati preciznost procjene sadržaja klorofila u odnosu na samostalne regresijske modele strojnog učenja. Istraživanje je provedeno na dvije eksperimentalne plohe hrasta lužnjaka u Hrvatskoj – u Jastrebarskom, gdje je prisutna infestacija, i u Buzetu, koji je poslužio kao kontrolno područje bez infestacije. Terenska mjerena uključivala su određivanje koncentracije klorofila u listovima pomoću klorofilmetra i brojanje jajnih legla štetnika, dok su bespilotne letjelice opremljene multispektralnom kamerom Parrot Sequoia korištene za snimanje spektralnih karakteristika krošnji. Za modeliranje sadržaja klorofila korišteni su samostalni regresijski modeli strojnog učenja te hibridni pristup koji integrira model prijenosa radijacije (PROSAIL) sa strojnim učenjem, omogućujući bolju analizu spektralnih karakteristika krošnji. Rezultati su pokazali da multispektralne UAV snimke mogu pouzdano detektirati promjene u sadržaju klorofila i predvidjeti razinu oštećenja stabala uzrokovanoj infestacijom, čime je potvrđena prva hipoteza. Hibridni modeli, koji integriraju PROSAIL simulacije i algoritme strojnog učenja, dali su dodatne uvide u prostornu dinamiku promjena, no nisu značajno poboljšali ukupnu točnost predikcija u odnosu na samostalne modele strojnog učenja, čime druga hipoteza nije u potpunosti potvrđena. Analiza okolišnih faktora pokazala je da je temperatura ključan čimbenik u širenju štetnika, pri čemu klimatske promjene mogu pogodovati njegovoj ekspanziji. Ovo istraživanje potvrđuje kako kombinacija bespilotnih letjelica, multispektralne analize i strojnog učenja omogućuje brzu, preciznu i ekonomičnu procjenu utjecaja invazivnih kukaca na šumske ekosustave.

Ključne riječi: hrastova mrežasta stjenica, hrast lužnjak, bespilotne letjelice, multispektralne snimke, strojno učenje, model prijenosa radijacije, daljinska detekcija.

ABSTRACT

The oak lace bug (*Corythucha arcuata*) poses a serious threat to oak forests, causing a decrease in photosynthetic activity, physiological stress, and long-term stand instability. Traditional infestation monitoring methods rely on field inspections, which are often time-consuming and subject to observer bias. Therefore, remote sensing using multispectral data acquired by unmanned aerial vehicles (UAVs) emerges as an effective method for accurate and rapid forest health assessment. The aim of this study was to develop and evaluate methods for monitoring changes in chlorophyll concentration in *Quercus robur* canopies affected by oak lace bug infestation. Two hypotheses were tested: (1) that multispectral UAV imagery can reliably detect physiological changes in canopies caused by infestation, and (2) that combining a radiative transfer model (PROSAIL) with machine learning can improve the accuracy of chlorophyll estimation compared to standalone regression-based machine learning models. The research was conducted at two experimental *Q. robur* sites in Croatia—Jastrebarsko, where infestation was present, and Buzet, which served as a control area without infestation. Field measurements included determining chlorophyll concentration in leaves using a chlorophyll meter and counting the number of pest egg clusters, while UAVs equipped with a Parrot Sequoia multispectral camera were used to capture spectral characteristics of the tree canopies. For chlorophyll content modeling, both standalone regression-based machine learning models and a hybrid approach integrating the PROSAIL radiative transfer model with machine learning were applied to improve the analysis of spectral canopy characteristics. The results showed that multispectral UAV imagery can reliably detect changes in chlorophyll content and predict the level of tree damage caused by infestation, thus confirming the first hypothesis. Hybrid models that integrate PROSAIL simulations and machine learning algorithms provided additional insights into the spatial dynamics of changes but did not significantly improve overall prediction accuracy compared to standalone machine learning models, meaning the second hypothesis was not fully confirmed. Analysis of environmental factors indicated that temperature is a key driver in pest spread, with climate change potentially facilitating its expansion. This study confirms that the combination of UAVs, multispectral analysis, and machine learning enables a fast, accurate, and cost-effective assessment of the impact of invasive insects on forest ecosystems.

Keywords: oak lace bug, pedunculate oak, unmanned aerial vehicles, multispectral imagery, machine learning, radiative transfer model, remote sensing.

SADRŽAJ

PODACI O MENTORIMA	I
SAŽETAK	III
ABSTRACT.....	IV
KAZALO SLIKA.....	VII
KAZALO TABLICA.....	VIII
AKRONIMI.....	IX
1. UVOD.....	1
1.1. Infestacije šuma invazivnim vrstama kukaca	2
1.2. Hrastova mrežasta stjenica.....	4
1.3. Klorofil kao indikator stresa	6
1.4. Metode detekcije razine klorofila krošnje.....	10
1.5. Hibridni pristup modeliranja.....	14
2. CILJEVI I HIPOTEZE ISTRAŽIVANJA.....	15
3. MATERIJALI I METODE.....	16
3.1 Područje istraživanja.....	16
3.2 Prikupljanje terenskih podataka.....	18
3.2.1 Podaci prikupljeni bespilotnom letjelicom	20
3.2.2 Izmjera sadržaja klorofila	25
3.3 Metode integracije podataka i modeliranja.....	27
3.3.1. Povezanost broja jajnih legala i stupnja dana (SD)	27
3.3.2. Upotreba modela unutar ARTMO operatora	29
4. REZULTATI.....	35
4.1 Deskriptivna statistika terenskih mjerena.....	35
4.2. Rezultati utjecaja okolišnih parametara temperature i broj jajnih legalana klorofil lista	38
4.3. Rezultat analize samostalnih regresijskih algoritama strojnog učenja	40
4.4 Hibridni modeli.....	49
5. RASPRAVA	58

6. ZAKLJUČAK	63
7. POPIS LITERATURE	65
8.PRILOZI.....	74

KAZALO SLIKA

Slika 1. Prikaz širenja HMS Europom sa prikazom areala hrasta lužnjaka i hrasta kitnjaka.....	5
Slika 2. Lokacije ploha na karti Republike Hrvatske.....	17
Slika 3. Prikaz prostornog rasporeda podploha na području infestiranom HMS u šumariji Jastrebarsko. Crveno su označene lokacije gdje su postavljeni osjetnici za prikupljanje podataka o temperaturi.....	19
Slika 4. Prostorni razmještaj podploha na području bez infestacije HMS u šumariji Buzet.....	19
Slika 5. a) UAV sustav eBee SQ b) Prikupljanje terenskih kontrolnih točaka GNSS uređajem...	20
Slika 6. Prikaz sučelja eMotion AG programa sa vidljivim pozicijama prikupljanja scena na plohi (a) A i (b) B.....	22
Slika 7. Kreirane mape refleksije pomoću Pix4D.....	23
Slika 8. Oprema korištena za uzorkovanje listova.....	26
Slika 9. Jajna legla (crveno označeno) i nimfe (žuto označeno) na listu hrasta lužnjaka.....	27
Slika 10. Dijagram toka obrade podataka i modeliranja.....	32
Slika 11. Usporedba koncentracije klorofila u krošnji između ploha A i B.....	37
Slika 12. Regresijski model predikcije klorofila iz SD i broja jajnih legala.....	39
Slika 13. RF model predikcije klorofila iz SD i broja jajnih legala.....	39
Slika 14. GPR model za svibanj.....	41
Slika 15. a i b Primijenjen GPR model za svibanj na plohe A i B.....	42
Slika 16. GPR model za srpanj.....	44
Slika 17. a i b Primijenjen GPR model za srpanj na plohe A i B.....	45
Slika 18. GPR model za rujan.....	47
Slika 19. a i b Primijenjen GPR model za rujan na plohe A i B.....	48
Slika 20. Performanse hibridnog pristupa i primijenjeni model na plohe A i B za svibanj.....	51
Slika 21. Performanse hibridnog pristupa i primijenjeni model na plohe A i B za srpanj.....	54

Slika 22. Performanse hibridnog pristupa i primijenjeni model na plohe A i B za rujan.....57

KAZALO TABLICA

Tablica 1. Opis ploha istraživanja.....	16
Tablica 2. Pregled prikupljenih podataka te vremenskog perioda sakupljanja.....	20
Tablica 3. Centralne valne duljine i širina kanala Parrot Sequoia senzora.....	21
Tablica 4. Ulazni parametri za izračun modela prijenosa radijacije PROSAIL.....	30
Tablica 5. Statističke karakteristike korištenih MLRA.....	33
Tablica 6. Deskriptivna statistika okolišnih parametara	34
Tablica 7. Deskriptivna statistika koncentracije klorofila i LAI na plohama A i B.....	36
Tablica 8. Performanse različitih MLRA za svibanj.....	40
Tablica 9. Performanse različitih MLRA za srpanj.....	43
Tablica 10. Performanse različitih MLRA za rujan.....	46
Tablica 11. Rezultati metrike GPR hibridnog modela.....	49

AKRONIMI

AL – Aktivno učenje

ARTMO – Automated radiative transfer models operator

CCC – Koncentracija klorofila krošnje

CHM – *Canopy height model*

GPR – *Gaussian processes regression*

HMS- Hrastova mrežasta stjenica

KRR – *Kernel ridge regression*

LAI – Indeks lisne površine

LCC – Koncentracija klorofila u listu

LR - Linearna regresija

LUT – pregledne tablice

MLRA – Metode integracije podataka i modeliranja (*Machine learning regression algorithms*)

NDRE – *Normalized difference red edge index*

NDVI – *Normalized difference vegetation index*

NIR – Blisko infracrveno

NN- *Neural network*

PCA -*Principal component analysis*

PLSR – *Partial least squares regression*

RT -*Regression tree*

RTM – Model prijenosa radijacije

UAV- Bespilotne letjelice

1. UVOD

Šume su jedni od najvažnijih ekosustava na našem planetu, pružajući stanište brojnim vrstama, regulirajući globalni ugljikov ciklus i osiguravajući mnogobrojne ekološke usluge. Međutim, ovi ekosustavi suočavaju se s ozbiljnim prijetnjama, uključujući infestacije kukaca, koje mogu narušiti njihovu stabilnost i dugoročnu održivost. Iako su infestacije kukcima prirodni dio šumskih ekosustava, problem postaje izraženiji kada su uključene invazivne vrste. Ovi kukci dolaze izvan svojih prirodnih staništa i mogu izazvati nepredvidive i drastične posljedice za šume u novim područjima (Mack i dr. 2000; Hulme, 2009).

Posebno zabrinjava činjenica da klimatske promjene dodatno pogoduju širenju invazivnih kukaca. Više temperature i blaže zime omogućuju ovim vrstama da prežive i razmnožavaju se na širim geografskim područjima (Jarošík i dr. 2015). Invazivni kukci uzrokuju gubitak biološke raznolikosti, smanjenje fotosintetske aktivnosti stabala, povećanu osjetljivost na bolesti i druge štetnike te, u konačnici, odumiranje velikih dijelova šuma (EFSA, 2010; Mota i dr. 2012).

Jedan od ključnih indikatora stresa biljaka uslijed infestacija je sadržaj klorofila. Klorofil, kao osnovni pigment odgovoran za fotosintezu, osjetljivo reagira na stresne uvjete poput napada kukaca (Chakhvashvili i dr. 2022; Moustaka i Moustakas, 2023). Smanjenje koncentracije klorofila u lišću izravno utječe na vitalnost stabala i može se koristiti kao pouzdan pokazatelj općeg zdravlja šuma (Bibin i dr. 2023). Napredne metode daljinskog istraživanja, poput multispektralnih i hiperspektralnih snimaka, omogućuju praćenje ovih promjena s visokom prostornom i vremenskom rezolucijom (Benko i Balenović, 2011; Bozzini i dr. 2023). Bespilotne letjelice i satelitski senzori, poput Sentinel-2 i Lisata, pružaju istraživačima alate za detekciju infestacija i procjenu njihovog intenziteta na velikim površinama (Kern i dr. 2021).

Razvoj novih tehnoloških rješenja, uključujući kombinaciju daljinskog istraživanja i metoda strojnog učenja, donosi značajne mogućnosti za bolje razumijevanje i upravljanje ovim izazovima. Regresijski modeli strojnog učenja i hibridni pristupi, koji integriraju fizičke modele prijenosa radijacije i metode strojnog učenja, omogućuju precizno modeliranje koncentracije klorofila u pogodenim šumama (Verrelst i dr. 2016b). Cilj ovog rada je analizirati utjecaj hrastove mrežaste stjenice (*Corythucha arcuata*), te istražiti mogućnosti primjene ovih novih tehnologija u praćenju i modeliranju promjena uzrokovanih infestacijama.

1.1. Infestacije šuma invazivnim vrstama kukaca

Infestacije kukcima odnose se na pojavu velikog broja kukaca koji napadaju i oštećuju šume. Ove su pojave neizbjegni dio prirodnog ciklusa šumskih ekosustava, no u određenim situacijama, osobito kada je riječ o invazivnim vrstama, mogu imati drastičan utjecaj. Kukci poput potkornjaka, cvilidreta, gusjenica i drugih vrsta hrane se tkivima biljaka, oštećuju koru i remete transport vode i hranjivih tvari. Posljedice takvih napada kreću se od smanjenja vitalnosti biljaka do njihova potpuna odumiranja, što može dovesti do promjene strukture šumskih zajednica, gubitka biološke raznolikosti te poremećaja u kruženju hranjivih tvari i ugljika (Jarošik i dr. 2015).

Dok se napadi kukaca prirodno događaju u šumama diljem svijeta, invazivne vrste kukaca predstavljaju posebnu prijetnju zbog činjenice da dolaze izvan svog prirodnog areala. One se često unose ljudskim aktivnostima, poput međunarodne trgovine ili transporta (Mack i dr. 2000; Hulme, 2009). Po dolasku u novu sredinu, invazivne se vrste mogu naglo proširiti jer nemaju prirodnih predatora ni drugih regulatornih čimbenika koji ih ograničavaju u matičnim ekosustavima. Posljedično, mogu potisnuti autohtone vrste i narušiti ravnotežu šumskih ekosustava. Invazivne vrste karakterizira viši donji prag razvoja, što znači da im je potrebna minimalna temperatura ispod koje razvoj ne može započeti. S druge strane, ukupna količina toplinske akumulacije (zbroj efektivnih temperatura) potrebna za dovršetak njihovog životnog ciklusa je niža u usporedbi s domaćim vrstama. Takva situacija može djelovati kontradiktorno – unatoč nižim ukupnim temperaturnim zahtjevima, trenutačne niske temperature u nekim područjima sprječavaju prelazak tog višeg minimalnog praga. Stoga, klimatske promjene, podizanjem prosječnih temperatura, mogle bi omogućiti prelazak kritične granice, čime se olakšava širenje invazivnih vrsta.(Jarošik i dr. 2015).

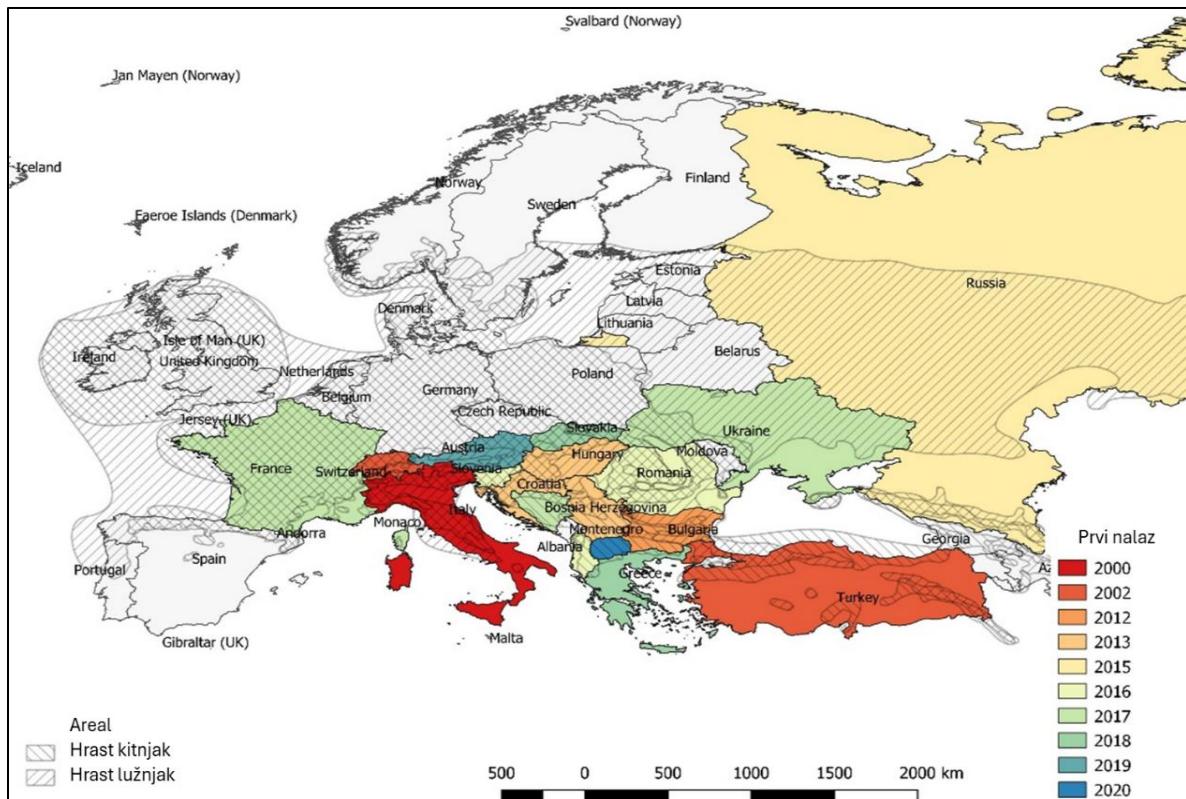
Kada govorimo o konkretnim primjerima u Europi, posebno su zanimljivi slučajevi kojima se dokazuje koliko široke i trajne posljedice invazivne vrste kukaca mogu imati na lokalne šume i gospodarstvo. Na primjer, kestenova osa šiškarica (*Dryocosmus kuriphilus*), porijeklom iz Azije, imala je razoran utjecaj na populacije pitomog kestena u Italiji, Francuskoj i drugim europskim zemljama (EFSA, 2010). Osim što je nanijela velike ekološke štete smanjivanjem bioraznolikosti, došlo je i do ozbiljnih ekonomskih gubitaka za lokalne proizvođače kestena. Slične negativne posljedice bilježi i borova nematoda (*Bursaphelenchus xylophilus*), koja je proširena u Portugalu

i Španjolskoj te uzrokuje brzo sušenje borovih šuma, uz značajne troškove kontrole i suzbijanja (Mota i dr.2012).

Ukupni ekonomski gubici povezani s kontrolom invazivnih kukaca te oporavkom narušenih ekosustava dosežu milijarde dolara godišnje (Pimentel i dr. 2005). Primjerice, borov potkornjak (*Dendroctonus ponderosae*) u Sjevernoj Americi pokazuje koliko su mjere suzbijanja i sanacije kompleksne i dugotrajne, a jasenov krasnik (*Agrilus planipennis*) u mnogim je dijelovima Sjeverne Amerike ostavio goleme površine šuma gotovo bez jasena. Upravo zbog ovakvih posljedica, prevencija unošenja i kontrola širenja invazivnih vrsta predstavljaju ključne korake u očuvanju biološke raznolikosti i održivosti ekosustava. Rano otkrivanje i brza reakcija, potkrijepljeni međunarodnom suradnjom i javnom edukacijom, mogu značajno smanjiti rizik od daljnog širenja invazivnih kukaca (Lockwood i dr. 2013; Simberloff i dr. 2013). Isto tako, kroz strože mjere kontrole na granicama, pregled uvezenog materijala (npr. drvene ambalaže) te kontinuirano znanstveno praćenje, moguće je preduhitriti velike gubitke u šumskom bogatstvu i izbjegći katastrofalne posljedice za gospodarstvo i ekosustave.

1.2. Hrastova mrežasta stjenica

Hrastova mrežasta stjenica (HMS) (*Corythucha arcuata*, Say, 1832) invazivna je vrsta koja pripada redu *Hemiptera* i porodici *Tingidae*. Prirodno je rasprostranjena u Sjevernoj Americi, gdje obitava u južnim dijelovima Kanade i nekoliko istočnih saveznih država SAD-a. (Horn i dr. 1979). U Europi je prvi put zabilježena 2000. godine u Italiji (Bernardinelli i Zandigiacomo 2000) a od tada se brzo širi cijelim kontinentom (Paulin i dr. 2020; Csóka i dr. 2020). U Hrvatskoj je prvi put primijećena u istočnom dijelu zemlje (Hrašovec i dr. 2013), a danas je prisutna gotovo u svim područjima gdje raste hrast, uključujući i sastojine hrasta lužnjaka u Istri (Zorić i dr. 2023). Brzina širenja, visok invazivan potencijal i sposobnosti prilagodbe HMS različitim klimatskim uvjetima predstavljaju ozbiljnu prijetnju sastojinama hrasta (Csepelényi i dr. 2017; Csóka i dr. 2020). U svom prirodnom arealu primarno se razvija na bijelim hrastovima (Connell i Beacher 1947, Drake i Ruhoff 1965). Međutim, u Europi pokazuje širi spektar domaćina, uključujući različite vrste hrasta te ostale vrste bjelogorice (Csóka i dr. 2019) (Slika 1). Csepelényi i suradnici u istraživanju iz 2017 navode da HMS prvenstveno napada termofilne šume hrasta te se lako prilagođava novim uvjetima (Csepelényi i dr. 2017). HMS u svom prirodnom arealu razvija dvije generacije (Drake i Ruhoff 1965), dok su u Europi zabilježene i tri generacije godišnje (Bălăcenoiu i dr. 2023) što značajno doprinosi brzini širenja. Svojim usnim ustrojem prilagođenim za bodenje i sisanje, adulti i nimfe probijaju epidermu lišća kako bi isisavali biljne sokove. To dovodi do promjene boje, klorotičnosti i žućenja lišća, smanjenja fotosintetske aktivnosti, a ponekad i preuranjenog opadanja lišća. Uzastopni napadi dodatno mogu povećati osjetljivost biljke domaćina na infestaciju drugih kukaca i razvoj bolesti (Connell i Beacher, 1947).



Slika 1. Prikaz širenja HMS Europom sa prikazom areala hrasta lužnjaka i hrasta kitnjaka

Ekološke karakteristike uključuju značajnu otpornost na različite klimatske uvjete i sposobnost preživljavanja u različitim staništima, što omogućava ovoj vrsti da napada razne vrste hrastova. Njeno širenje unutar Europe također je potpomognuto klimatskim promjenama, koje omogućavaju preživljavanje i reprodukciju ove vrste u širim geografskim područjima (Stancă-Moise i dr. 2023). Paulini i dr. (2020) su primijetili da prezimljavanje u europskim uvjetima ne predstavlja prepreku za ovu vrstu, što dodatno objašnjava njezino uspješno širenje. Ciceu i dr. (2024) naglašavaju kako se širenje vrste ubrzalo u balkanskim zemljama zbog povoljnih uvjeta i nedostatka prirodnih neprijatelja. Rezultati istraživanja provedenih u Rumunjskoj u razdoblju od 2019. do rujna 2020. godine ukazuju na to da se populacijski vrhunci hrastove mrežaste stjenice (HMS) javljaju tijekom srpnja i kolovoza. Uobičajeno je da je najintenzivnija dnevna aktivnost odraslih jedinki zabilježena oko podneva (Bălăcenoiu i dr. 2021b). Prisutnost i aktivnost HMS-a značajno su uvjetovane meteorološkim čimbenicima. Ključnu ulogu imaju viša temperatura i niža relativna vlažnost, pod uvjetom da temperaturne vrijednosti ne prelaze prag termalnog stresa za promatranu

vrstu. Uz navedene meteorološke uvjete, niže nadmorske visine i blizina prometnica identificirani su kao važni čimbenici koji doprinose širenju HMS-a. (Maciej Serda i dr. 2024).

Istraživanja na bijelom hrastu (*Quercus alba*) pokazuju da se najviše odraslih jedinki HMS nalazi na stablima s otvorenijim krošnjama, pri čemu listovi sadržavaju više vode i mekše su strukture, što im olakšava ishranu (Barber, 2010). Mikroklima pritom igra ključnu ulogu, pa se u rjeđim sastojinama ili na rubnim stablima, koja primaju više svjetla, HMS brže razmnožava i stvara veće kolonije. Najveće štete uočene su u čistim hrastovim sastojinama, dok mješovite šume pokazuju blaže oblike infestacije (Marjanović i Kern, 2021; Hoch i dr. 2024). Ipak, ni one ne mogu u potpunosti zaustaviti širenje, a višegodišnji napadi mogu dovesti do slabljenja stabala i slabe otpornosti prema drugim štetnicima. Stoga, razumijevanje interakcije HMS s okolišnim čimbenicima i strukturonim šuma predstavlja temelj za učinkovito upravljanje ovom prijetnjom i očuvanje zdravlja šumskih ekosustava.

1.3. Klorofil kao indikator stresa

Infestacija HMS uzrokuje smanjenje sadržaja klorofila i karotenoida u lišću, što smanjuje fotosintetsku aktivnost i vitalnost biljaka.. Osim toga, lišće postaje tanje zbog smanjenja veličine parenhimskih stanica, što dodatno narušava njegovu funkcionalnost (Bibin i dr. 2023). Klorofil u listovima, ključna komponenta fotosintetskog aparata, odavno je prepoznat kao jedan od pigmenta lista koji najviše reagira na vanjske uvjete. Djeluje kao glavni pokazatelj zdravlja i produktivnosti biljaka, utječući na fotosintezu, unos hranjivih tvari i reakcije na stres (Chakhvashvili i dr. 2022; Moustaka i Moustakas, 2023). Agathokleous i dr. (2020) su pokazali da niska razina stresa može potaknuti proizvodnju klorofila, dok ga visoka razina stresa inhibira. Zato je praćenje biokemijskih sastojaka, poput klorofila u lišću, ključno je za procjenu stresa u šumama pogodenima infestacijama kukcima. Snimanje fluorescencije klorofila omogućuje rano otkrivanje stresa, često prije pojave vidljivih simptoma, dok su promjene spektralne refleksije, osobito oko 700 nm, povezane s promjenama u sadržaju klorofila uzrokovanim stresom (Zarco-Tejada i dr. 2002).

Mjerenje sadržaja klorofila lista moguće je pomoći prijenosnih uređaja kao što su klorofilmetri. Ovi alati procjenjuju razine klorofila mjerenjem svojstava apsorpcije i refleksije svjetlosti na listovima biljaka. Pružaju brza, izravna mjerenja i posebno su korisni za istraživače koji trebaju podatke u stvarnom vremenu, bez potrebe za složenim laboratorijskim analizama. Jedan od alata

za nedestruktivno utvršivanje klorofila je SPAD klorofil metar (Shibaeva i dr. 2020). Odnos između SPAD vrijednosti i sadržaja klorofila je specifičan za svaku vrstu te varira tokom vegetacijske sezone i odnos je obично izrazen nelinearnim modelima (Xiong i dr. 2015; Wakiyama 2016). U istraživanju osam listopadnih vrsta, koje je provedeno različitim uređajima, nakon kalibracije prema destruktivno određenim vrijednostima koncentracije klorofila u listu, pokazala se usporediva točnost ovog uređaja, pri čemu su razvijene kalibracijske funkcije za precizno određivanje koncentracije klorofila (Brown i dr. 2022). Satelitski podaci omogućuju praćenje zdravstvenog stanja šuma na razini krajolika, no za preciznu kvantifikaciju promjena u sadržaju klorofila neophodna su terenska mjerena. Korištenje uređaja poput klorofilmetara na terenu omogućuje direktno određivanje koncentracije klorofila u listovima. Ova mjerena služe kao osnova za kalibraciju i validaciju regresijskih modela koji povezuju koncentraciju klorofila s reflektiranim svjetlom zabilježenim na satelitskim snimkama (Gitelson i dr. 1996; Daughtry i dr. 2000) Integracijom satelitskih podataka visoke rezolucije i terenskih mjerena koncentracije klorofila značajno se povećava točnost i pouzdanost procjene zdravstvenog stanja i vitalnosti šumskih ekosustava (Richardson i dr. 2001; Zarco-Tejada i dr. 2018).

Kako bi točno pratili razinu klorofila, znanstvenici primjenjuju napredne tehnike analize, kao što su daljinsko istraživanje i alati temeljeni na strojnim učenju. Korištenjem podataka o refleksiji svjetlosti iz različitih dijelova elektromagnetskog spektra, znanstvenici mogu procijeniti količinu klorofila u biljkama i detektirati eventualna oštećenja. Daljinska istraživanja postala su ključni alat za upravljanje šumskim resursima, omogućavajući detaljan i sveobuhvatan uvid u stanje, dinamiku i procese unutar šumskih ekosustava. Tehnologije daljinskog istraživanja, kao što su satelitske snimke, snimke prikupljene zrakoplovima ili bespilotnim letjelicama opremljenim različitim senzorima (multispektralni, hiperspektralni ili LIDAR), pružaju korisnicima alate za praćenje promjena u šumama s visokom prostornom, vremenskom i spektralnom rezolucijom (Benko i Balenovic, 2011, Jovanović i dr. 2021).

Različite satelitske optičke platforme, uključujući MODIS, Lisat i Sentinel-2, koriste se za otkrivanje i mapiranje šteta od insekata (Dalponte i dr. 2022; Bozzini i dr. 2023). Na primjer, primjenom MODIS podataka razvijena je metoda za razdvajanje meteoroloških utjecaja od učinaka HMS na vegetacijski indeks normalizirane razlike (NDVI), koja je pokazala da je intenzitet oštećenja proporcionalan udjelu hrasta u sastojini. NDVI se izračunava se kao omjer između crvene (R) i bliske infracrvene (NIR) vrijednosti, a koristi se za razumijevanje zdravlja

biljaka. Mapirani su izvori infestacije i brzina širenja HMS, što omogućuje preciznije praćenje i upravljanje štetnikom u pogodjenim područjima. (Kern i dr. 2021).

Zahvaljujući dugom vremenskom nizu (od 1970-ih godina nadalje), Lisat predstavlja dragocjen izvor za retrospektivnu analizu infestacija štetnika u šumama. Primjerice, Townsend i Foster (2002) pratili su defolijaciju uzrokovano gubarom (*Lymantria dispar*) kombinirajući LISAT podatke i terenska mjerena. Townsend i dr. (2012) su isto tako potvrdili korisnost LISAT podataka u temporalnom praćenju višegodišnjeg tijeka napada. Usporedbom različitih indeksa (npr. NDVI) upotrebom LISAT snimaka mogu se relativno rano detektirati veće promjene u strukturi krošnje i stres biljaka.

U novije vrijeme, Sentinel-2 postaje sve popularniji zbog kraće vremenske rezolucije (10 i 5 dana, ovisno da li se radi o jednom ili dva satelita (Sentinel-2A i 2B)) i više prostorne rezolucije (10 i 20 m), što omogućuje detaljnije i češće praćenje šumske štete. Osim klasičnih *red-blue-green* (RGB) i NIR kanala, Sentinel-2 posjeduje *red-edge* kanale (npr. 705 nm, 740 nm), koji su posebno korisni za praćenje koncentracije klorofila te otkrivanje ranih znakova stresa u vegetaciji. Studije su pokazale da *red-edge* indeksi mogu pouzdano razlikovati zdrava i oštećena stabla, pa čak i prije značajnijeg gubitka lisne mase (Senf i dr. 2017). U šumama srednje Europe, gdje su česte infestacije potkornjaka i stjenica, primjena Sentinel-2 podataka olakšava bliskovremensko (*near real-time*) praćenje. Kod defolijacije uzrokovane kukcima poput gubara, potkornjaka ili mrežastih stjenica, Sentinel-2 omogućuje otkrivanje oštećenja (npr. na rubnim stablima ili manjim žarištima) te znatno pomaze planiranje ciljanih terenskih pregleda i mjera suzbijanja.

Spomenuti optički sateliti, iako korisni za praćenje šumske infestacije, imaju nekoliko nedostataka koji ograničavaju njihovu učinkovitost u takvim situacijama. Jedan od glavnih problema je njihova prostorna rezolucija slika (>10 m), koja može biti previše niska za precizno otkrivanje manjih infestacija ili promjena u šumama. Postoji nekoliko komercijalnih optičkih satelita koji se koriste za praćenje vegetacije (e.g., PlanetScope, Worldview 2/3/4, or GeoEye) koji imaju znatno bolju prostornu rezoluciju slika (do 30 cm) i dobru spectralnu rezoluciju, ali nisu lako dostupni i besplatni. Drugu problem, koji uključuje sve optičke satelite je sto se svi oni oslanjaju se na vidljivu i blisku infracrvenu svjetlost, što znači da su podaci osjetljivi na vremenske uvjete kao što su oblačnost i magla, koji mogu ometati kvalitetu snimaka. Zato je upotreba zrakoplova i bespilotnih letjelica posebno prakticna, jer se podaci mogu sakupljati ispod oblaka i

uz upotrebu razlicitih senzora. Daljinska detekcija zrakoplovima intenzivno je korištena za otkrivanje i praćenje infestacija insekata u šumama (Hall i dr. 2016) Ovi sustavi omogućuju brzo prikupljanje podataka s kratkim vremenom obrade, snimanje cijelih područja odjednom te postupak koji je znatno jeftiniji od terenskih istraživanja (Tueller, 1987; Everitt i dr. 1991; Pia i dr. 2024)

Bespilotnim letjelicama (UAV) možemo prikupiti podatke visoke prostorne rezolucije, što omogućuje precizno praćenje stanja šuma i pravovremeno otkrivanje znakova infestacija. UAV također mogu letjeti na nižim visinama i u stvarnom vremenu prenositi podatke, što omogućuje brže reakcije i učinkovitije donošenje odluka. S obzirom na to da bespilotne letjelice lete ispod oblaka, mogu zaobići problem naoblake koja ometa prikupljanje podataka satelitima. Osim toga, UAV su fleksibilnije u pokrivanju manjih, specifičnih područja, jer se mogu usmjeriti na precizne lokacije u šumi pogodjene infestacijama, za razliku od satelita koji pokrivaju veće površine. Sve ove karakteristike čine bespilotne letjelice korisnim alatom za precizno i brzo praćenje šumske infestacije. Ovi sustavi pružaju isto tako i fleksibilnost, isplativost te visoku vremensku rezoluciju daljinskih prikupljenih podataka (Guimarães i dr. 2020; Duarte i dr. 2022). Dash i dr. (2018) su pokazali da su multispektralne slike prikupljene bespilotnim letjelicama znacajno osjetljivije od satelitskih slika u praćenju stanja šuma. Cardil i dr. (2019) su uspjesno koristili multispektralne UAV slike prikupljene Parrot Sequoia senzorom za automatsko određivanje defolijacije stabala uzrokovane borovim četnjakom u mješovitim šumama bora i hrasta, s točnošću od 81,8%.

Metodološkim pristupom koji koristi multispektralne UAV snimke uspješno je detektiran stres stabala uzrokovani potkornjakom te su identificirani ključni spektralni kanali i vegetacijski indeksi za praćenje različitih kategorija poremećaja (Minařík i Langhammer, 2016). Multispektralnim UAV snimkama precizno je detektirana šteta uzrokovana štetnikom *Phoracantha semipunctata* (Fabricius) u eukaliptusovim sastojinama, korištenjem metoda thresholdinga i random forest klasifikacije za izradu karte gustoće šuma (Duarte i dr. 2020). Luan i dr. (2024) su koristili UAV snimke i UAV-generiran model visine krosnje za procjenu klorofila krosnje južnog bora (*Pinus elliottii*) kako bi pratili stanje sume. Wei i dr. (2024) su koristili UAV podatke za procjenu koncentracije klorofila i stanje urbanih šuma. Za usporedbu, multispektralne UAV slike se slično koriste i u poljoprivredi. Na primjer, za detekciju stresa izazvanog sojinim lisnim ušima na sojnim poljima, rezultati su pokazali da se refleksija u NIR spektru smanjila s povećanjem populacije insekta. Ova promjena u NIR refleksiji rezultat je fizioloških promjena u

biljci, uključujući oštećenje strukture i smanjenje vodnog sadržaja listova uslijed stresa izazvanog lisnim ušima(Marston i dr. 2020).Simic Milas i dr. (2018) su istakli važnost indexa lisne površine u procjeni klorofila krošnje za praćenje fizioloških promjena na poljima kukuruza. Ovi nalazi naglašavaju važnost praćenja fizioloških promjena u biljkama kroz spektralne analize i praćenje koncentracije klorofila, jer takve metode omogućuju ranu detekciju stresa i potencijalno pravovremenu reakciju u različitim kulturama.

1.4. Metode detekcije razine klorofila krošnje

Dva ključna pristupa omogućuju procjenu klorofila u krošnjama temeljenom na podacima prikupljenim daljinskim istraživanjem: (1) statističke regresijske metode, (2) primjena modela prijenosa radijacije (Baret i Buis, 2008). Posljednjih godina, spajanje modela prijenosa zračenja sa statističkim regresijskim metodama strojnog učenja u hibridne modele pokazalo se kao vrlo obećavajuće rješenje za procjenu klorofila u krošnjama. Hibridni pristupi iskorištavaju prednosti oba svijeta: omogućuju uvođenje fizičkih principa (kroz RTM-ove) zadržavajući fleksibilnost i računalnu učinkovitost metoda strojnog učenja, te uzimaju u obzir lokalno prikupljene podatke (Verrelst i sur., 2016a; Verrelst i sur., 2019).

Statističke (empirijske) metode regresije temeljene na strojnom učenju

Strojno učenje u daljinskom istraživanju temelji se na korištenju algoritama koji omogućuju računalnim sustavima da uče iz podataka, automatski prepoznaju obrasce i donose odluke. Iako su ovi algoritmi inicijalno razvijeni i programirani od strane stručnjaka, njihova ključna prednost leži u sposobnosti da se prilagode i poboljšaju svoje performanse s novim podacima, često bez potrebe za daljnijim, eksplicitnim programiranjem od strane krajnjeg korisnika za svaku specifičnu primjenu. Drugim riječima, nakon što je algoritam strojnog učenja obučen na odgovarajućem skupu podataka, on može samostalno obrađivati nove, neviđene podatke i davati rezultate. U kontekstu daljinskih istraživanja, algoritmi strojnog učenja koriste kombinaciju podataka prikupljenih pomoću različitih senzora (npr., multispektralni i hiperspektralni senzori na satelitima, bespilotnim letjelicama (UAV) ili zrakoplovima) i in situ terenskih mjerena (npr., laboratorijska mjerena sadržaja klorofila u listovima). Spektralni podaci sa senzora daju informaciju o reflektanciji ili emitiranju elektromagnetskog zračenja s površine Zemlje u različitim valnim duljinama. Terenski podatci služe kao referenca. Ova kombinacija podataka omogućuje algoritmima strojnog učenja da analiziraju spektralne značajke snimaka i izvrše precizne

regresijske analize, procjenjujući kvantitativne vrijednosti parametara okoliša, kao što je sadržaj klorofila u krošnjama (što je cilj ovog istraživanja), biomasa, indeks lisne površine (LAI) itd. Regresija uspostavlja vezu između spektralnih podataka i terenskih mjerena. Algoritmi strojnog učenja se također koriste u klasifikacijama, gdje razvrstavaju piksele slike u različite kategorije (klase), kao što su različite vrste vegetacije, tipovi tla, vodene površine, izgrađena područja itd. (Camps-Valls i Bruzzone, 2009). Jedan od ključnih doprinosa strojnog učenja u daljinskim istraživanjima jest njegova sposobnost učinkovite analize ogromnih količina podataka (često se govori o "velikim podacima" ili big data) i prepoznavanja suptilnih, složenih obrazaca i veza koje bi ljudskim analitičarima lako promakle ili bi ih bilo izuzetno teško i vremenski zahtjevno otkriti. Algoritmi strojnog učenja mogu otkriti nelinearne odnose i interakcije između stotina ili tisuća spektralnih kanala i različitih biofizičkih i biokemijskih varijabli (kao što su sadržaj klorofila, vode, suhe tvari, struktura krošnje, itd.). Ovo omogućuje ne samo dublje i detaljnije razumijevanje složenih odnosa između izmjerениh spektralnih refleksija i stanja okoliša, već i razvoj poboljšanih, preciznijih alata za kartiranje (mapiranje) i praćenje (monitoring) stanja okoliša, promjena u okolišu i različitim procesima u ekosustavima. (David i Mathew, 2019).

Statističke metode za procjenu sadržaja klorofila obuhvaćaju jednostavne tehnike poput linearne regresije, ali i sofisticirane pristupe temeljene na algoritmima regresije strojnog učenja, kojisu osobito učinkoviti u prepoznavanju složenih, nelinearnih odnosa u podacima daljinskih istraživanja. Metode strojnog učenja, poput random forest, support vector machines ili neural network, treniraju se na izdvojenim podacima iz podataka daljinskog istraživanja i odgovarajućim terenskim mjerjenjima klorofila (Bozzini i dr. 2023; Ye i dr. 2022). Nakon treniranja, modeli se testiraju i validiraju na novim podacima, omogućujući sveobuhvatano mapiranje i praćenje distribucije klorofila u vegetaciji različitih šumskih ekosustava.

Priprema podataka u analizi daljinskog istraživanja i terenskih mjerena uključuje ekstrakciju šumskih područja pomoću vegetacijskih indeksa i klasifikacijskih metoda, interpolaciju prostornih i vremenskih podataka radi popunjavanja praznina te standardizaciju kroz normalizaciju vrijednost. Nadalje, spektralne vrijednosti slika u različitim spektralnim područjima se često matematički transformiraju u različite spektralne indekse poput već spomenutog NDVI (nomalizirani omjer između R i NIR vrijednosti) ili drugih spektralnih omjera radi naglašavanja

specifičnih biofizičkih karakteristika. Treniranje modela uključuje ulazne varijable, poput refleksije, spektralnih indeksa i ciljne varijable, kao što su koncentracije klorofila. Složeniji algoritmi, poput dubokih neuronskih mreža, koriste se za prepoznavanje složenih nelinearnih obrazaca koji nisu očiti u jednostavnijim modelima. Nakon obuke, modeli se testiraju i evaluiraju pomoću skupa podataka za testiranje, koji se razlikuje od skupa korištenog za treniranje. Evaluacija modela uključuje mjerjenje točnosti, preciznosti i drugih metrika izvedbe. Metode poput unakrsne validacije često se koriste kako bi se osigurala pouzdanost rezultata i smanjila pristranost modela. Kada model postigne zadovoljavajuće performanse, koristi se za analizu novih podataka refleksije, omogućujući predikciju ili procjenu koncentracije klorofila krosnje. (Simic i dr. 2011; Croft i dr. 2013; Verrelst i dr. 2019; Alam i dr. 2024).

Najčešće korišteni regresijski modeli u daljinskom snimanjima za procjenu razine klorofila krošnje ili drugih biokemijskih svojstava uključuju linearne modele, jezgreno-bazirane algoritme, algoritme bazirane na stablima odlučivanja i neuronske mreže. Modeli često predhodno zahtijevaju redukciju dimenzionalnosti, kao što je *Principal Component Analysis* (PCA) ili *Partial Least Squares Regression* (PLSR), kako bi se ublažila kolinearnost spektralnih refleksija u jednom datasetu daljinskih mjerena (e.g., hiperspektralni podaci) i omogućilo učinkovito modeliranje (Ye i dr. 2007; Arenas-Garcia i dr. 2013).

Model prijenosa radijacije

Za razliku od statističkih regresijskih modela, koji su empirijske prirode, modeli prijenosa radijacije (RTM) predstavljaju fizičke modele koji koriste algoritme za izražavanje fizičkih odnosa između prijenosa svjetlosti (svjetlosne radijacije) kroz različite medije, poput atmosfere, vode ili vegetacije koju koristimo u ovom istraživanju (García-Soria i dr. 2024; Sahoo i dr. 2023).

RTM uključuju različite nivoe kompleksnosti kada su u pitanju fizičke pojave. Tako se ovi modeli, koji mogu biti na nivou lista ili na nivou krošnje, često kombiniraju što rezultira većom preciznosti predikcija. Ova integracija RTM-ova za listove i krošnje prisutna je već nekoliko desetljeća (Jacquemoud i dr. 2009). Dok RTM-ovi za listove simuliraju optička svojstva listova na temelju njihovih biokemijskih sastojaka, poput klorofila, karotenoida i parametara strukture lista (Jacquemoud i Baret 1990), RTM-ovi za krošnje simuliraju interakcije između elektromagnetskog zračenja (radijacije) i vegetacijskih krošnji, uzimajući u obzir faktore arhitekture krošnje poput raspodjele kuta listova, indeksa površine lista (LAI), i pozadinskog tla (Verhoef 1984). Ova integracija omogućava sveobuhvatnije prikazivanje refleksije vegetacije uzimajući u obzir i biokemijske komponente pojedinih listova i strukturne karakteristike krošnje. PROSAIL model (Jacquemoud i dr. 2009) je jedan od najšire korištenih integriranih RTM-ova; kombinira optička svojstva na razini lista koja simulira PROSPECT model (Jacquemoud i Baret 1990) s interakcijama izmedju listova na razini krošnje koje su simulirane SAIL modelom (Verhoef 1984). PROSPECT model simulira optička svojstva listova biljaka koristeći parametre kao što su struktura mezofila lista, koncentracija pigmenata i sadržaj vode, učinkovito rekonstruirajući refleksiju i transmisiju lista u spektralnom rasponu od 400 do 2500 nm (Jacquemoud i Baret 1990). SAIL model simulira refleksiju krošnje uključujući varijable kao što su LAI i raspodjela nagiba listova, pružajući realistične kutne profile refleksije na temelju kuta gledanja i solarnog zenitnog kuta (Verhoef 1984). Kombiniranjem ova dva modela, PROSAIL model može preciznije i realističnije simulirati spektralnu refleksiju vegetacijskih krošnji. Tijekom godina, napredak u razumijevanju optičkih svojstava listova i krošnji doveo je do usavršavanja algoritama i parametrizacija modela (Verhoef i dr. 2007). Iako se ovaj model uspjesno upotrebljava koristeci multispectralne sateliteske podatke, pokazao se vrlo prikladnim za analizu hiperspektralnih podataka, pružajući snažnu podršku za različite tehnike dobivanja podataka u proučavanju vegetacije (Berger i dr. 2018). Rezultati validacije pokazali su da PROSAIL uspješno simulira oblik spektra za sve pozicije gledanja, uključujući i pozicije "hotspot" i "dark spot" (Barman i dr. 2010).

Inverzija PROSAIL modela omogućuje procjenu ključnih parametara, poput sadržaja klorofila, vode i suhe tvari, čime se otvaraju nove mogućnosti za praćenje ekosustava i procjenu rizika, poput požara ili defolijacije. Tehnike inverzije RTM najčešće se oslanjaju na pristupe temeljenje na tablicama za pretragu (LUT) (Darvishzadeh i dr. 2008; Vicent i dr. 2020) i metode strojnog učenja, poput umjetnih neuronskih mreža (Ai i dr. 2019; He i dr. 2021) PROSAIL je postao široko korišten u istraživačkoj zajednici zbog svoje jednostavnosti, točnosti i dostupnosti, no unatoč svojoj korisnosti ima ograničenja, posebno u simulaciji heterogenih krošnji, što zahtijeva daljnji razvoj i dodatne varijable za realističnije simulacije (Jacquemoud i dr. 2009).

1.5. Hibridni pristup modeliranja

Hibridni modeli koji kombiniraju RTM i metode strojnog učenja predstavljaju značajan napredak u daljinskom istraživanju vegetacije. Ovi modeli spajaju fleksibilnost i prilagodljivost fizičkog modeliranja i strojnog učenja koje koristi podatke iz područja gdje se obavlja istraživanje, omogućujući precizniju procjenu biofizičkih i biokemijskih parametara vegetacije (Verrelst i dr. 2016). Ključna prednost hibridnih modela leži u njihovoj sposobnosti integracije simuliranih RTM podataka sa stvarnim podacima daljinskih snimanja (npr. satelitski ili UAV podaci) te drugim terenskim mjerjenjima. Aktivno učenje, kao sastavni dio ovog pristupa, omogućuje selektivno biranje najinformativnijih uzoraka za obuku modela, čime se smanjuje potreba za velikim količinama podataka, dok se istovremeno povećava učinkovitost i točnost modela (Tuia i dr. 2011).

Integracija RTM i metoda strojnog učenja implementirana je u Automated Radiative Transfer Models Operator (ARTMO) alat, razvijen u MATLAB okruženju. Ova platforma omogućuje primjenu metoda strojnog učenja kao samostalnih modela, PROSAIL modela kao samostalnog RTM, i hibrid modela PROSAIL+modeli regresije (Caicedo i dr. 2014). Hibridni PROSAIL model, ugrađen unutar ARTMO okruženja, kombinira PROSPECT (za simulaciju optičkih svojstava listova na temelju njihovih biokemijskih karakteristika, poput sadržaja klorofila i vode) s SAIL modelom (za simulaciju interakcija elektromagnetskog zračenja s krošnjom, uključujući arhitekturu krošnje i pozadinsko tlo). Ovaj model je detaljno opisan u sekciji Materiali i Metode.

2. CILJEVI I HIPOTEZE ISTRAŽIVANJA

Ciljevi ovoga istraživanja su:

Razvoj i validacija hibridnih optičko-empirijskih modela strojnog učenja za modeliranje koncentracije klorofila u listovima i krošnjama hrasta lužnjaka napadnutih od hrastove mrežaste stjenice

Utvrđiti pouzdanost multispektralnih snimaka u određivanju smanjenja koncentracije klorofila u odnosu na terestrička mjerena.

Analizirati i kvantificirati prostorni raspored i stupanj smanjenja koncentracije klorofila koristeći multispektralne snimke iz bespilotne letjelice.

Hipoteze

1. Multispektralne snimke prikupljene bespilotnim letjelicama mogu se uspješno koristiti za identifikaciju i kvantifikaciju oštećenja uzrokovanih hrastovom mrežastom stjenicom. Na temelju multispektralnih snimaka može se odrediti stupanj zaraze koji je u visokoj korelaciji sa stupnjem zaraze određenim terenskim prikupljanjem podataka.
2. Korištenjem podataka prikupljenih na terenu, okolišnih parametara i snimaka bespilotne letjelice moguće je uz pomoć regresijskih modela i strojnog učenja modelirati koncentraciju klorofila u listovima i krošnjama hrasta lužnjaka.

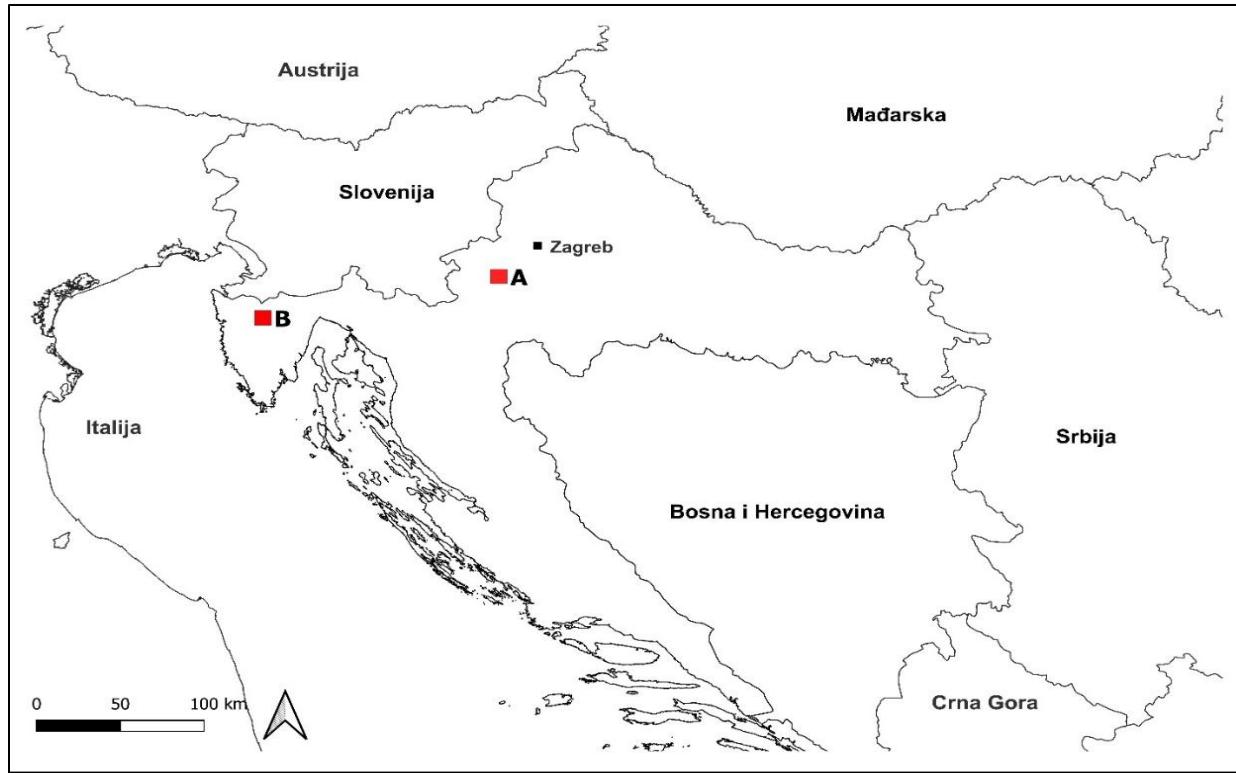
3. MATERIJALI I METODE

3.1 Područje istraživanja

Za ovo istraživanje odabrane su dvije pokusne plohe u sastojinama hrasta lužnjaka (*Quercus robur L.*) sličnih strukturnih karakteristika (Tablica 1). Za identifikaciju odgovarajućih sastojina koristili smo bazu Hrvatskih šuma te filtracijom odabrali one s odgovarajućim strukturnim elementima. Prva ploha nalazi se na području Uprave šuma Karlovac (šumarija Jastrebarsko), gdje je prisutna HMS, dok je druga na području Uprave šuma Buzet (šumarija Buzet), gdje HMS nije zabilježena (Slika 2)

Tablica 1 Opis ploha istraživanja

	<i>Ploha</i>	<i>Starost</i>	<i>Omjer smjese</i>	<i>Broj h.lužnjak</i>	<i>Tlo stabala (%)</i>	<i>Ostale vrste</i>
A		50 god.	53	270	Euglej amfiglej	Poljski jasen, Obični grab, OTB
B		65 god.	56	271	Aluvijalno	Poljski jasen, OTB



Slika 2 Lokacije ploha na karti Republike Hrvatske

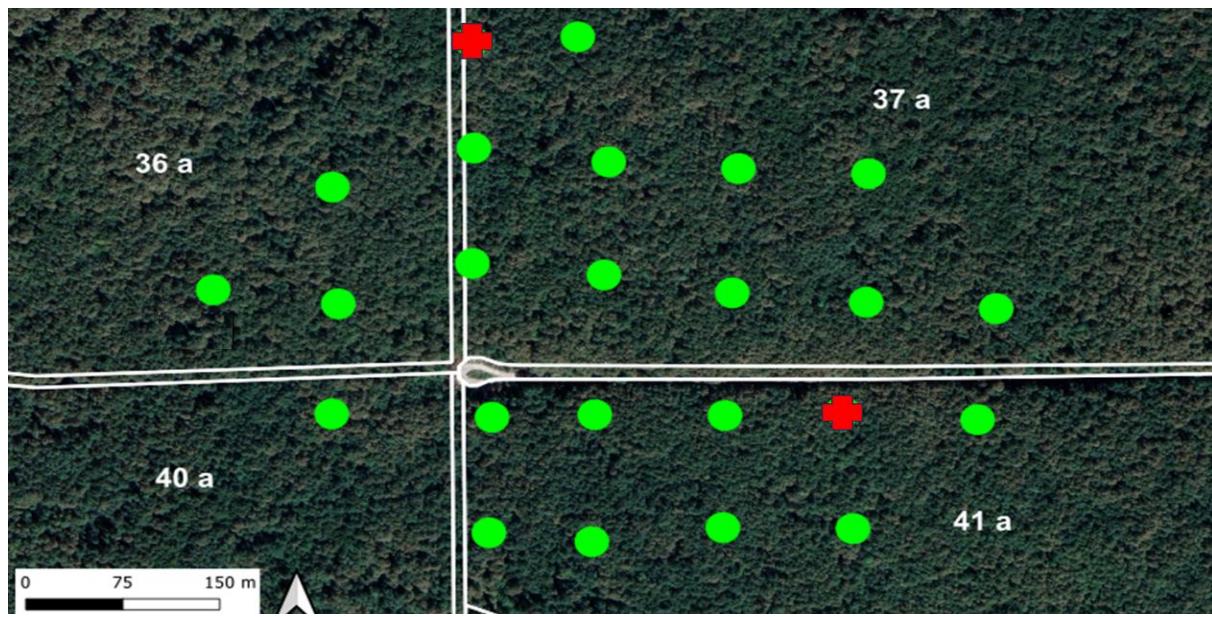
Ploha u Jastrebarskom (Ploha A) (HTRS 96 436668.44 E, 5053604.67 N). dio je dugotrajne plohe u sklopu koje se prate izmjene CO₂ između šume i atmosfere te su na njoj uspostavljene 23 trajne podplohe. Ploha se nalazi u gospodarskoj jedinici Jastrebarski lugovi, na području 4 odsjeka. Ploha je prema Köppenovoj klasifikaciji, okarakterizirana kao umjereni toplo vlažni s vrućim ljetima (Cfa). Ovu klimu karakterizira ravnomjerna raspodjela oborina tijekom godine, bez izrazito sušnih razdoblja, te srednja temperatura najtoplijeg mjeseca iznad 22 °C. Ploha A obuhvaća četiri odsjeka (36A, 37A, 40A, 41A) ukupne površine 107,38 ha. Šumski predjel pripada gospodarskom uređajnom razredu sjemenjača hrasta lužnjaka s ophodnjom od 140 godina. Tlo je pseudoglej, močvarni glej (euglej) i amfiglej, dok je fitocenoza šuma lužnjaka i velike žutilovke s drhtavim ili rastavljenim šašem. Bonitet je II, a ekspozicija raznolika s ravnim terenom bez nagiba. Nadmorska visina iznosi od 109 do 112 m, dok je sklop varijabilan, od nepotpunog do potpunog (obrast 0,66–0,95). Glavne vrste u sastojini su hrast lužnjak, koji čini dominantnu vrstu s drvnom zalihom do 170,54 m³/ha, zatim poljski jasen sa zastupljeničću do 30% i drvnom zalihom do 35,65 m³/ha, te obični grab, koji zauzima 10–25% s drvnom zalihom do 37,26 m³/ha. Uz njih su prisutne i crna

joha, nizinski briješt te euroamerička topola.

Ploha na području Uprave šuma Buzet, šumarija Buzet, GJ Motovun (ploha B) odabrana je kao što je i prethodno navedeno iz razloga što tamo štetnik još nije detektiran. Odabrana je i uspostavljena u drugoj godini pokusa jer smo uvidjeli da postoji potreba za kontrolom. S obzirom na položaj u unutrašnjosti Istre, ploha je također okarakterizirana prema Koppenovoj klasifikaciji kao umjereno toplo vlažna s vrućim ljetima (Cfa). Odsjek se nalazi u uređajnom razredu sjemenjače lužnjaka s ophodnjom od 140 godina. Površina iznosi 12,8 ha, s potpunim sklopom (obrast 0,96) i starosti sastojine od 65 godina. Nadmorska visina područja je 19-20 m, s ravnom ekspozicijom i minimalnim nagibom ($0-1^\circ$). Tlo je aluvijalno, mineralno-močvarno, karbonatno, s mikrodepresijama. Fitocenozu čini šuma poljskog jasena i hrasta lužnjaka s visećim šašem, što pripada stanišnom tipu E.3.1. Mješovite hrastovo-grabove i čiste grabove šume. Prema Kyotskom protokolu kategorizirano je kao F1 KP 3.4. U sloju drveća prevladavaju hrast lužnjak i poljski jasen, uz prisutnost klena, briješta i običnog graba. Grmlje je slabo razvijeno, a čine ga glog, crni trn, kalina, svib, drijen i kupina. U prizemnom sloju dominiraju mezofilne biljne vrste. Južni rub odsjeka prati staro korito rijeke Butonige.

3.2 Prikupljanje terenskih podataka

U okviru svake plohe odabrane su podplohe sastavljene od 30 stabala hrasta lužnjaka (*Quercus robur*) za uzorkovanje. Precizne GNSS koordinate svakog stabla zabilježene su pomoću uređaja STONEX S900 GNSS (vidi slike 3 i 4). Na plohi A, koja obuhvaća 23 postojeće podplohe, na određenim podplohama dodana su dodatna stabla kako bi se osigurao isti uzorak kao na plohi B. Na plohi B, kako bi se osigurao ravnomjeran prostorni raspored podploha, razmještaj je kreiran uz pomoć QGIS softvera. Dobivene točke korištene su kao polazišta za uspostavu podploha na terenu. Mjerenja su provedena tijekom tri uzastopne vegetacijske sezone, u mjesecima svibnju, srpnju i rujnu, s ciljem praćenja dinamike zaraze tijekom cijelog vegetacijskog razdoblja. Prikupljeni podaci uključuju broj jajnih legala i koncentraciju klorofila na svakom izmјerenom listu, kao i podatke dobivene snimanjem UAV.



Slika 3 Prikaz prostornog rasporeda podploha na području infestiranom HMS u šumariji Jastrebarsko. Crveno su označene lokacije gdje su postavljeni osjetnici za prikupljanje podataka o temperaturi



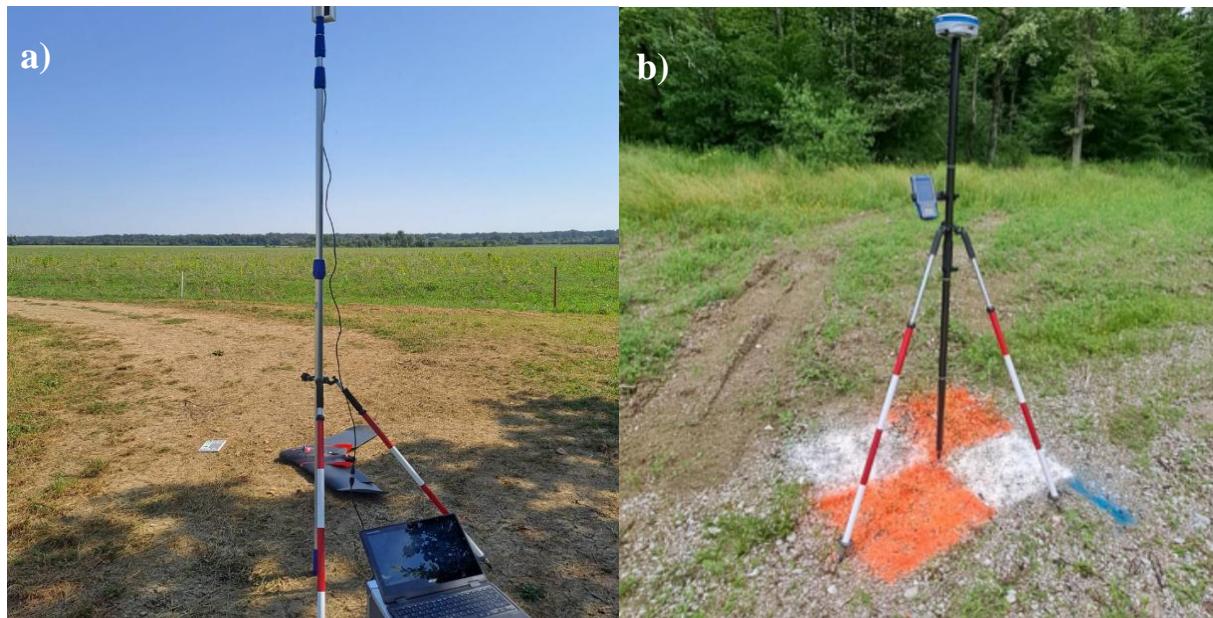
Slika 4 Prostorni razmještaj podploha na području bez infestacije HMS u šumariji Buzet

Tablica 2 Pregled prikupljenih podataka te vremenskog perioda sakupljanja

<i>Godina</i>	<i>2021</i>	<i>2022</i>	<i>2023</i>			
<i>Lokacija</i>	<i>Lugovi</i>	<i>Mirna</i>	<i>Lugovi</i>	<i>Mirna</i>	<i>Lugovi</i>	<i>Mirna</i>
Svibanj	17.-21.	9.-13.	16.-20.	15.-19.	22.-26.	
Srpanj	12.-16.	11.-15.	18.-22.	10.-14.	17.-21.	
Rujan	13.-17.	12.-16.	19.-23.	11.-15.	18.-22.	

3.2.1 Podaci prikupljeni bespilotnom letjelicom

Tijekom tjedna terenskog prikupljanja podataka (Tablica 2), neposredno prije uzorkovanja lišća, provedeno je snimanje bespilotnom letjelicom. Za snimanje je korištena bespilotna letjelica tip fiksno krilo eBee SQ (Slika 5a), opremljena multispektralnom kamerom Parrot Sequoia s četiri spektralna kanala i RGB senzorom (Tablica 3).

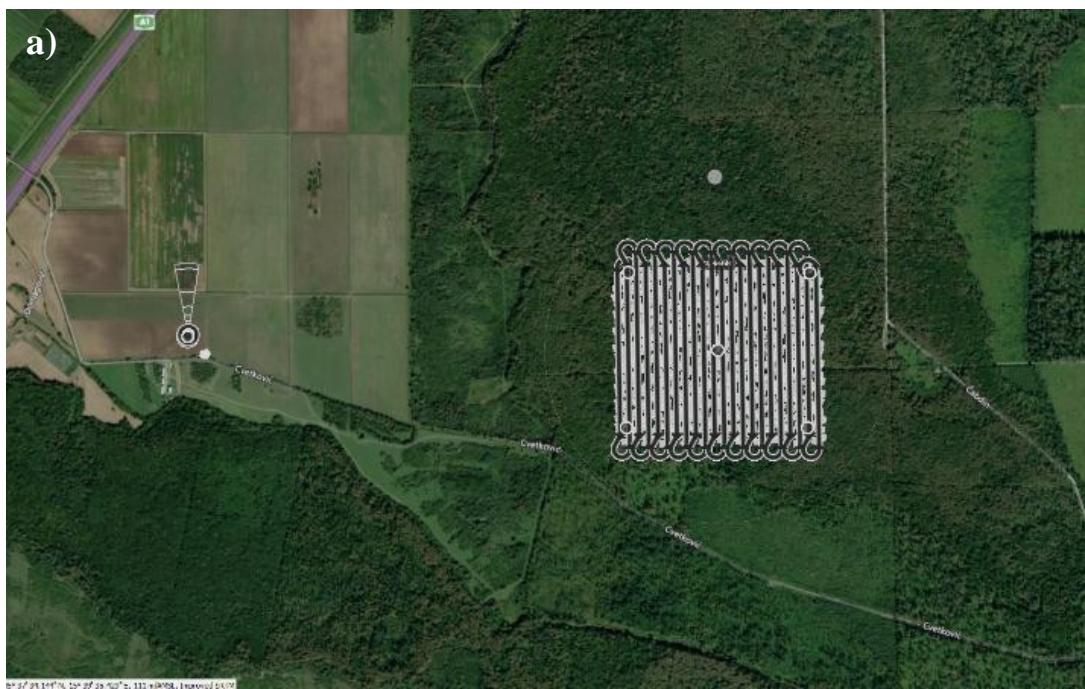


Slika 5 a) UAV sustav eBee SQ b) Prikupljanje terenskih kontrolnih točaka GNSS uređajem

Tablica 3 Centralne valne duljine i širina kanala Parrot Sequoia senzora

Kanal	Centralna valna duljina (nm)	Širina kanala (nm)
Zeleni (G)	550	40
Crveni (R)	668	40
Crveni rub (Red Edge)	735	10
Bliski infracrveni	790	40

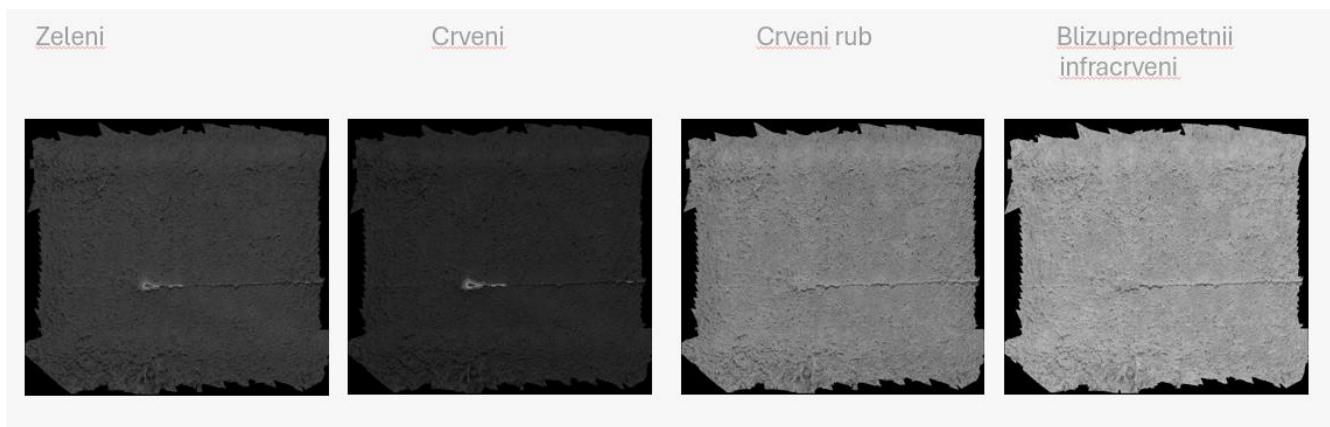
Prije početka snimanja, na terenu su postavljene terenske kontrolne točke (Slika 5b) čije su koordinate precizno izmjerene Stonex S900 GPS GNSS uređajem i korištene za georeferenciranje snimaka. Prije leta je isto tako snimljen kalibracijski panel, a dobiveni podaci su kasnije upotrijebljeni za radiometrijsku kalibraciju snimaka. Planiranje i provedba leta izvršeni su pomoću softvera eMotion AG, pri čemu su definirani ključni parametri leta kako bi se osigurala preciznost i usporedivost prikupljenih podataka. Tijekom svakog leta, UAV je održavao konstantnu visinu od 100 m iznad razine tla, uz zadani poprečni preklop od 75% i uzdužni preklop od 80%. Ovi parametri postavljeni su kako bi se osigurala visoka pokrivenost i ista prostorna resolucija od 10 cm na obje plohe. Ploha A obuhvaćala je površinu od 39 ha, dok je ploha B bila manja, s površinom od 15,4 ha. Manja površina plohe B rezultat je činjenice da obuhvaća samo jedan odsjek, koji je, kao što je ranije navedeno, odabran zbog sličnih karakteristika s plohom A.



Slika 6 Prikaz sučelja eMotion AG programa sa vidljivim pozicijama prikupljanja scena na plohi
(a) A i (b) B

Podaci prikupljeni bespilotnom letjelicom obrađeni su korištenjem softverskog alata Pix4D (verzija 4.9.0), koji primjenjuje metodu *Structure from Motion* (SfM) za rekonstrukciju 3D modela iz 2D slika. Tijekom obrade generirane su mape refleksije za svaki pojedini spektralni kanal (Slika 7).

Prije same obrade, na snimkama su označene terenske kontrolne točke kako bi se osiguralo precizno georeferenciranje podataka. Unutar programske podrške izvršena je i radiometrijska kalibracija, koja korigira varijacije u osvjetljenju i senzorskim postavkama, osiguravajući konzistentnost i točnost reflektivnih vrijednosti.



Slika 7 Kreirane mape refleksije pomoću Pix4D

Mape refleksije su potom uvezene u programsku podršku QGIS, gdje je korištenjem alata "Zonal Statistics" i ručno delineiranih krošanja za svaki poligon, tj projekciju krošnje pojedinog stabla na slici, izračunata aritmetička sredina, standardna devijacija te maksimalne i minimalne vrijednosti refleksije određenog spektralnog kanala.

Kako bismo uklonili utjecaj tla na refleksijske vrijednosti, vrijednosti unutar poligona su izračunate maskiranjem tla korištenjem modela visine krošnje na visini od 10 m (CHM). CHM pruža informacije o visini vegetacijskog pokrova iznad površine tla i dobiva se oduzimanjem digitalnog modela terena od digitalnog modela površine, čime se izolira visina vegetacije.

Primjenom CHM-a omogućeno je precizno fokusiranje na krošnje drveća, eliminirajući potencijalne smetnje koje bi tlo ili niži slojevi vegetacije mogli unijeti u analizu refleksije. Time smo osigurali da prikupljeni podaci reflektiraju isključivo karakteristike krošnji, što je od presudne važnosti za točnu procjenu utjecaja štetnika, stresnih uvjeta ili drugih faktora na vegetaciju.

Izračun indeksa površine lista putem vegetacijskog indeksa i CHM

Indeks površine lista (LAI) je bezdimenzionalna veličina koja predstavlja ukupnu jednostranu zelenu lisnu površinu po jedinici površine tla (m^2/m^2). LAI je ključni parametar u ekološkim i biofizičkim modelima jer služi kao pokazatelj gustoće vegetacije, strukture krošnje i fotosintetske aktivnosti (Watson 1947).

Na temelju metodologije opisane od strane Moon i dr. (2018) indirektnom metodom izračunat je LAI za obje plohe. Procjena LAI bila je neophodna jer je isti jedan od ključnih parametara PROSAIL modela koji nije bio direktno izmjerena na terenu, a vazan je za racunanje razine klorofila krošnje i sluzi kao 'scaling' faktor od 'lista do krošnje'.

$$LAI = 1.837 + 0.836 \times (NDRE \times CHM) \quad (1)$$

Gdje je LAI – indeks površine lista; NDRE - *Normalized Difference Red Edge Index* i CHM – model visine krošnje.

Normalized Difference Red Edge Index (NDRE) je vegetacijski indeks koji koristi refleksiju u crvenom rubnom području spektra, a posebno je osjetljiv na sadržaj klorofila i dušika u vegetaciji. Za razliku od NDVI, NDRE ostaje osjetljiv i u područjima s gustom vegetacijom i visokim vrijednostima LAI, čime se izbjegava problem zasićenja karakterističan za NDVI.

Formula za NDRE glasi:

$$NDRE = \frac{NIR - RED\ EDGE}{NIR + RED\ EDGE} \quad (2)$$

Kombinacijom NDRE i CHM u formuli za izračun LAI integriraju se spektralne informacije u spektru vaznim za detekciju kvalitete vegetacijskih listova (NDRE) i strukturne informacije o visini drveća te ujedno kolicinom listova (CHM). Koristeci UAV snimke, NDRE i CHM mape su prvo kreirane, te LAI vrijednosti ocitane na mjestima terenskih mjerena klorofila lista.

3.2.2 Izmjera sadržaja klorofila

Za određivanje relativne količine prisutnog klorofila korišten je klorofilmetar Konica Minolta SPAD 502, koji mjeri apsorpciju lista u dva valna područja (plavo i crveno). Koristeći ove dvije apsorpcije, uređaj izračunava numeričku SPAD vrijednost koja je proporcionalna količini klorofila prisutnog u listu. Uređaj ima preciznost od ± 1 SPAD. Viša SPAD vrijednost ukazuje na veću koncentraciju klorofila, što je naravno povezano s boljim fiziološkim stanjem biljke (Uddling i dr. 2007). Kako bismo iz SPAD vrijednosti dobili koncentraciju klorofila u listu (LCC) (izraženu u $\mu\text{g}/\text{cm}^2$), koristili smo prilagođenu eksponencijalnu jednadžbu izvedenu iz kalibracijskog skupa podataka specifičnog za hrast lužnjak koji je predmet ovog istraživanja. Formula za konverziju je:

$$LCC = 0.1719e^{0.0355SPAD} \quad (3)$$

gdje su 0.1719 i 0.0355 koeficijenti dobiveni regresijskom analizom iz kalibracijskih podataka, dok je SPAD vrijednost izmjerena pomoću uređaja Konica Minolta SPAD-502Plus (Brown i dr. 2022). Dobivene vrijednosti su u gramima po metru kvadratnom (g/m^2) te smo izvršili konverziju u mikrograme po centimetru ($\mu\text{g}/\text{cm}^2$) kvadratnom radi lakše interpretacije u modelu.

Svaki list je izmјeren na tri različita mjesta radi povećanja točnosti mјerenja, pri čemu su izbjegnute glavne žile i moguća jajna legla. Dobiveni rezultati zabilježeni su kao aritmetička sredina tih mјerenja. Uzorkovanje listova provedeno je pomoću prilagođene arborističke praćke i pripadajuće opreme (Slika 8), dizajnirane za jednostavno prikupljanje uzoraka s različitih visina krošnje. Listovi su uzorkovani s tri strane svijeta (sjever, jug, i istok) kako bi se obuhvatile varijacije u izloženosti svjetlosti. Ova metoda omogućila je reprezentativnost uzoraka za svaki pojedinačni uzorak krošnje

Izmjera koncentracije klorofila omogućila je procjenu zdravstvenog stanja vegetacije te pružila potrebne ulazne podatke u modele za praćenje i razumijevanje dinamike zaraze HMS-om. Također, podaci su korišteni za usporedbu koncentracije klorofila između zaražene i kontrolne plohe, u kojoj nema zaraženosti, te za validaciju modela korištenih u ovom istraživanju.



Slika 8 Oprema korištena za uzorkovanje listova

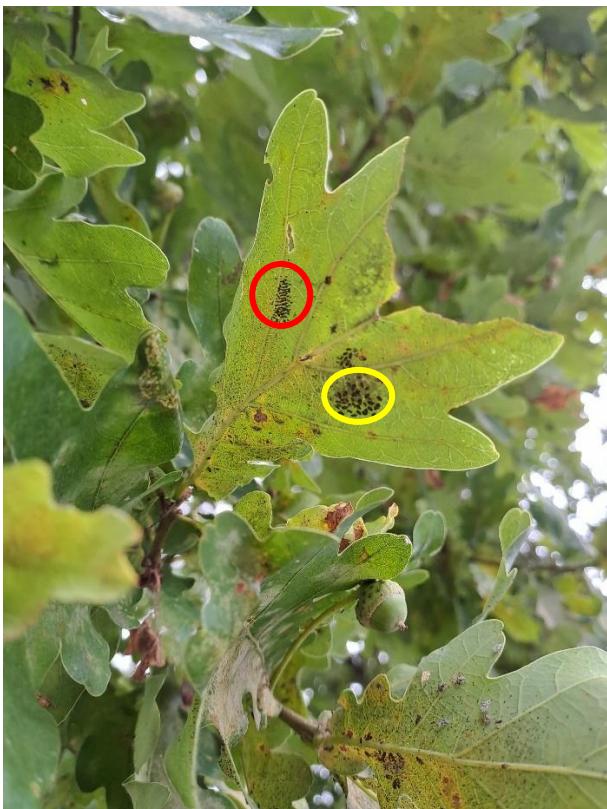
Na temelju podataka o koncentraciji klorofila u listu i listovnom indeksu površine (LAI), izračunali smo koncentraciju klorofila u krošnji (CCC). Ova metodologija omogućuje precizniju procjenu ukupne količine klorofila na razini krošnje jer integrira pojedinačna mjerena listova s prostornim rasporedom lisne mase, čime pruža sveobuhvatan uvid u fiziološko stanje stabala.

CCC predstavlja ukupnu količinu klorofilnih pigmenata (klorofil-a i klorofil-b) u krošnji po jedinici površine tla. Njegova vrijednost ovisi o koncentraciji klorofila u listu i ukupnoj lisnoj površini predstavljenu kroz LAI. Budući da klorofil ima ključnu ulogu u fotosintezi i apsorpciji fotosintetski aktivnog zračenja (PAR), njegova raspodjela unutar krošnje izravno utječe na produktivnost vegetacije i ekološke procese u šumskim ekosustavima.(Gitelson i dr. 2005)

3.3 Metode integracije podataka i modeliranja

3.3.1. Povezanost broja jajnih legala i stupnja dana (SD)

Prisutnost jajnih legala HMS na listovima (Slika 9) mjerena je kako bi se kvantificirala razina napada ovih insekata. Budući da je brojanje odraslih jedinki nepraktično zbog načina uzorkovanja, broj jajnih legla korišten je kao indikator veličine populacije. Na svakom listu evidentiran je broj jajnih legla, pri čemu su identificirana na temelju njihovog karakterističnog morfološkog izgleda.



Slika 9 Jajna legla (crveno označeno) i nimfe (žuto označeno) na listu hrasta lužnjaka

Istovremeno, mikroklimatski podaci prikupljani su pomoću osjetnika za mjerjenje temperature postavljenih ispod vrhova krošnji na istraživanim ploham (Slika 2). Korišteni su osjetnici proizvođača Hobo, model Pendant, s točnošću od $\pm 0.53^{\circ}\text{C}$. Podaci su prikupljeni u vremenskim razmacima od jednog sata, a osjetnici su raspoređeni tako da su dvije lokacije na plohi A pokrivale ključne dijelove istraživanog područja. Dobiveni temperaturni podaci interpolirani su kako bi se osigurala procjena dnevnih temperatura između mjerjenja.

Na temelju tih podataka izračunati su stupnjevi-dani (SD) koristeći standardnu metodologiju opisanu od strane Bălăcenoiu i dr. (2021):

$$SD = \left(\frac{T_{max} + T_{min}}{2} \right) - Tb \quad (4)$$

gdje su kao ključni parametri korišteni maksimalna dnevna temperatura (Tmax), minimalna dnevna temperatura (Tmin) i bazna temperatura za promatranu vrstu (Tb), koja iznosi 10°C.

Kako bi se analizirala povezanost između napada HMS, klimatskih uvjeta i koncentracije klorofila, provedena je regresijska analiza s ciljem ispitivanja utjecaja broja jajnih legla i akumuliranih stupanj-dana (SD) na promjene u koncentraciji klorofila u narednom razdoblju. Konkretno, ispitivano je kako broj jajnih legla i vrijednosti stupanj-dana izmjereni u svibnju utječu na koncentraciju klorofila u srpnju. Analiza je provedena na skupu podataka koji obuhvaća 360 mjerena broja jajnih legla i pripadajućih SD vrijednosti.

Za izgradnju ovih regresijskih modela korišteni su algoritmi implementirani u programskom jeziku Python, uključujući biblioteke *scikit-learn*. Linearni regresijski modeli generirani su pomoću modula *sklearn.linear_model*, dok dok je za random forest korišten modul iz *sklearn.ensemble*. Ove metode omogućuju modeliranje složenijih odnosa između ulaznih varijabli i koncentracije klorofila u budućem razdoblju. Performanse modela procijenjene su pomoću metrika iz *sklearn.metrics*, uključujući koeficijent determinacije (R^2) i korijen srednje kvadratne pogreške (RMSE). Predviđene vrijednosti koncentracije klorofila, dobivene primjenom modela *Random Forest*, korištene kao ulazni podaci u PROSPECT 4 model PROSAIL-a. Ova integracija omogućila je poboljšanje simulacija refleksije listova, uzimajući u obzir stvarne podatke o utjecaju HMS i klimatskih faktora na klorofil. Time se osigurao precizniji opis fiziološkog odgovora stabala na napad štetnika.

Vizualizacija rezultata provedena je pomoću matplotlib biblioteke, pri čemu su izrađeni grafički prikazi regresijskih linija, distribucije podataka te usporedba predviđenih i stvarnih vrijednosti koncentracije klorofila.

3.3.2. Upotreba modela unutar ARTMO operatora

Automated Radiative Transfer Models Operator (ARTMO)(ver.3.31), alatna platforma unutar programskog jezika MATLAB (ver.9.8.0), je korišten za modeliranje razine klorofila krošnje koristeći (1) šest modela regresivnog strojnog učenja (MLRAs); (2) hibridni pristup (PROSAIL + MLRAs) gdje je PROSAIL integriran sa MLRAs koji su se pokazali pouzdanim u prethodnom koraku, kada su samostalno implementirani.

ARTMO pruža sveobuhvatan softverski paket koji pojednostavljuje korisničku interakciju, postavljanje modela, njihovo izvršavanje i analizu spektara u rasponu od vidljivog (RGB) do NIR spektra (400 – 2500 nm). ARTMO je prvotno razvijen kao alat za modeliranje prijenosa radijacije (RTM) koristeci podatke is daljinskih snimanja kako bi olakšao generiranje i analizu spektra listova i krošnji te putem inverzije modela omogućio procjenu biofizičkih parametara (Verrelst i dr. 2012). Tek u poslijednjih 12-tak godina razvoj ARTMO-a se temelji na integraciji PROSAIL s naprednim MLRAs u hibridne modele (PROSAIL + MLRAs), uključujući metode za interpretaciju podataka daljinskog istraživanja i rezultata kao sto su razina klorofila krošnje.

PROSAIL model u ovom istraživanju kombinira PROSPECT-4, koji simulira optička svojstva listova, s 4SAIL, modelom prijenosa radijacije za krošnje. Ova kombinacija omogućuje preciznu simulaciju dvosmjerne refleksije krošnje, tj. refleksije kao funkcije kutova osvjetljenja i promatranja. Ulazni parametri u PROSAIL su parametri poput pigmenata, proteina i sadržaja vode, zajedno s biofizičkim ulaznim parametrima kao što su LAI, prosječni kut nagiba lista, spektralna pozadina tla i geometrije gledanja, kao što je vidljivo u Tablici 4. U korisničkom sučelju ARTMO alatnog okvira za RTM definirali smo raspon vrijednosti i generirali dva uzorka za svaki ulazni parametar. Ostali parametri usvojeni su iz relevantne literature ili prilagođeni specifičnostima istraživane lokacije i vremenskog razdoblja. Parametri poput strukture lista, sadržaja vode i suhe tvari uzeti su iz dostupnih izvora (Tagliabue i dr. 2022; Sun i dr. 2021; Berger i dr. 2020), dok su parametri specifični za lokalitet, poput koeficijenta svjetline tla, relativnog azimuta i efekta žarišne točke, prilagođeni stvarnim uvjetima istraživane lokacije. Dodatno, faktori koji ovise o sezonskim uvjetima, poput prosječnog kuta lista, solarnog zenitnog kuta te difuzne radijacije, prilagođeni su prema vremenskom periodu u kojem su se provodila mjerena, kako bi se osigurala točnost generiranih podataka za analizu. Na taj način model je optimiziran da reflektira stvarne uvjete

šumske vegetacije i njen odgovor na promjenjive okolišne faktore.

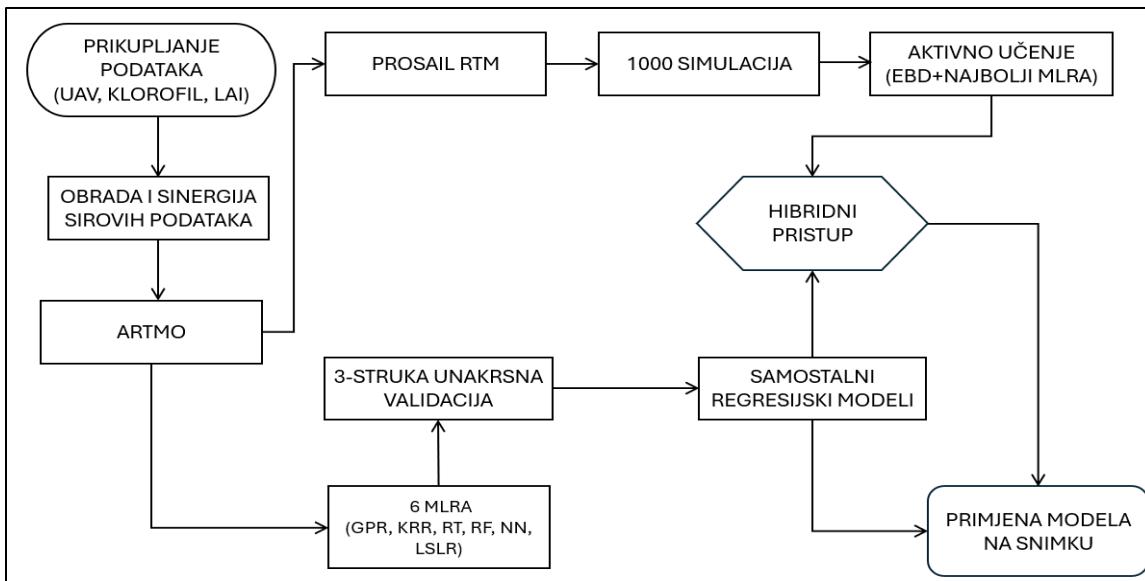
Tablica 4 Ulazni parametri za izračun modela prijenosa radijacije PROSAIL

PROSPECT4	Raspored n	Mjerna jedinic a	Parametri ploha A			Parametri ploha B		
			Svibanj	Srpanj	Rujan	Svibanj	Srpanj	Rujan
<i>Struktura lista</i>	1-4	N	1-1.5	1.5-2	1.2-1.7	1.5-2	2-2.5	1.5-2
<i>Koncentracija klorofila</i>	0-100	$\mu\text{g}/\text{cm}^2$	20-40	30-50	10-30	30-50	50-70	20-40
<i>Voda u listu</i>	0-0.05	g/cm^2	0.012-0.018	0.008-0.0015	0.006-0.012	0.015-0.020	0.01-0.018	0.008-0.015
<i>Suha tvar</i>	0-0.05	g/cm^2	0.006-0.012	0.012-0.018	0.012-0.020	0.005-0.01	0.01-0.015	0.01-0.018
4SAIL								
<i>LAI</i>	0-15		2-3	4-6	3-4	2-3	4-6	3-4
<i>Efekt žarišne točke</i>	0-1		0.0015-0.0035	0.006	0.005	0.0015-1	0.006	0.0051
<i>Prosječan kut lista</i>	0-90	$^\circ$	30-40	20-30	25-35	30-40	20-30	25-35
<i>Kut zenita sunca</i>	0-90	$^\circ$	36-37	33-34	50-51	36-37	34-35	54-55
<i>Difuzna direktna radijacija</i>	0-100		30-50	25-40	35-55	30-50	25-40	35-55
<i>Zenitni kut promatrača</i>	0-90	$^\circ$	0-10	0-10	0-10	0-10	0-10	0-10
<i>Koeficijent svjetline tla</i>	0-1		0.10-0.15	0.15	0.15	0.1-0.25	0.2	0.2-0.4
<i>Relativni azimut</i>	0-180	$^\circ$	129-130	123-124	141-142	124-125	122-123	141-142

U procesu utemeljene tehnike inverzije koristeći LUT metodu, PROSAIL stvara baze podataka gdje iteracijama računanja ujedinjuje sve kombinacije parametara vegetacije (u rasponu ulaznih parametara, Tablica 4) sa simulacijama odgovarajućih spektralnih refleksija koje proračunava za svaku ulaznu kombinaciju (Weiss i dr. 2000, Sinha i dr. 2020, Impollonia i dr. 2022). U kontekstu inverzije, LUT se zatim koristi za "pretraživanje" najboljih ulaznih parametara vegetacije koji odgovaraju stvarnim promatranim spektralnim refleksijama daljinskih mjerjenja (npr. satelit ili UAV snimke). Problem vezan uz ove mnogobrojne simulacije u LUT u sklopu pretraživanja je "problem slabo postavljenih sustava" (*ill-posed problems*), kada imamo slučaj gdje neke različite kombinacije parametara vegetacije proizvedu istu simulaciju refleksije. Da bi se taj efekt umanjio ili spriječio, ARTMO uključuje uzorkovanje početnih uzoraka i takozvano aktivno učenje (AL), koje koristi algoritme strojnog učenja kako bi optimizirao procjenu biokemijskih varijabli poput LAI i sadržaja klorofila.

Za generiranje početnih uzoraka smo koristili metodu *Latin Hypercube Sampling* (LHS) s 1000 uzoraka, čime smo osigurali reprezentativnu pokrivenost varijabilnosti ulaznih parametara. Ova metoda omogućila je smanjenje suvišnih podataka, čime je optimizirano korištenje podataka i povećana računalna učinkovitost za daljnju analizu (Tuia i dr. 2011). Nakon što LHS generira početne uzorke, koristi se AL za daljnju optimizaciju. Implementacijom različitih AL metoda, ovaj pristup omogućuje odabir najinformativnijih uzoraka iz velikih skupova podataka generiranih PROSAIL simulacijama čime se poboljšava točnost procjena uz manju potrebnu količinu trening podataka u odnosu na nasumično uzorkovanje (Verrelst i dr. 2016). AL za optimizaciju modela odabriom najboljih uzoraka iz simulacija temeljen je na Euclidovoj udaljenosti (EBD) i Gaussian procesnih regresiji (GPR). Nakon toga, dobiveni uzorci korišteni su za treniranje MLRA u sklopu hibridne metode (PROSAIL + MLRAs), povećavajući točnost regresijskih algoritama (Verrelst i dr. 2021) tako što smo iz LUT odabrali broj uzoraka koji ima najmanji RMSE, čije su vrijednosti određene unutar artmo platforme na grfičkim prikazima (PRILOG 1). Parametri senzora su ručno postavljeni za MLRAs kako bi odgovarali četirima kanalima UAV kamere korištene u istraživanju.

Proces metoda modeliranja je prikazan na Slici 10.



Slika 10 Dijagram toka obrade podataka i modeliranja

Metode regresijskih algoritama stojnjog ucenja (MLRA)

Jedan od alata ARTMO softverskog paketa je algoritmi regresije strojnim učenjem (Machine Learning Regression Algorithms - MLRA), odnosno alat za regresijske algoritme temeljen na strojnome učenju (Caicedo Rivera i dr. 2014). Podaci za korištenje u MLRA pripremljeni su na temelju zonalne statistike izračunate za svaki poligon. Za svaki poligon izračunate su srednje, maksimalne i minimalne vrijednosti. Na temelju tih vrijednosti formiran je reprezentativan uzorak, pri čemu je uzeto 50% srednjih vrijednosti, 40% maksimalnih i 10% minimalnih vrijednosti kako bi se osigurala ravnoteža između dominantnih i ekstremnih vrijednosti u podacima.

Osim toga, dodano je 10 vrijednosti za samo tlo kako bi se povećala heterogenost skupa podataka. Šest MLRA korišteno je u ovom istraživanju u izravnom (samostalnom) regresijskom pristupu, to su *Gaussian processes regression* (GPR), *Kernel ridge regression* (KRR), *Least squares linear regression*, *Neural network*, *Random forest* i *Regression tree*. Njihove osnovne karakteristike prikazane su u Tablici 5. MLRA s najboljim prediktivnim karakteristikama u ovom procesu korišteni su u hibridnom PROSAIL modeliranju kako bi se ispitala učinkovitost hibridnog PROSAIL+MLRAs modeliranja u usporedbi sa samostalnim regresijskim modeliranjem.

Tablica 5 Statističke karakteristike korištenih MLRA

<i>Algoritam</i>	<i>Opis</i>	<i>Referenca</i>
<i>Gaussian processes regression (GPR)</i>	Temelji se na Bayesovom pristupu, gdje se sve moguće funkcije koje povezuju ulazne i izlazne varijable modeliraju kao slučajni procesi s unaprijed definiranom distribucijom	(Rasmussen i Williams 2006)
<i>Kernel ridge regression (KRR)</i>	Proširenje linearne regresije koje omogućuje modeliranje nelinearnih odnosa primjenom jezgrenih funkcija. U ovom algoritmu, regularizacija se koristi kako bi se izbjegla prevelika prilagodba (<i>overfitting</i>) podacima, dok jezgra transformira ulazni prostor u prostor viših dimenzija, gdje linearni model može bolje odgovarati nelinearnim uzorcima.	Suykens i Viewalle 1999
<i>Least squares linear regression (LSLR)</i>	Osnovna metoda regresije koja modelira linearni odnos između ulaznih značajki i ciljne varijable minimiziranjem zbroja kvadrata odstupanja između predviđenih i stvarnih vrijednosti. Ovaj algoritam koristi jednostavnu formulu za procjenu parametara modela (koeficijenata) i lako se implementira	(Watson 1967)
<i>Neural network (NN)</i>	Temelje se na strukturama inspiriranim ljudskim mozgom, s više slojeva povezanih čvorova (neurona) koji transformiraju ulazne podatke prema ciljnim vrijednostima. Regresijske neuronske mreže koriste kontinuirane aktivacijske funkcije u izlaznom sloju kako bi se generirale kontinuirane predikcije	Haykin 1999
<i>Random forest</i>	Ensemble metoda učenja koja koristi skup stohastički generiranih regresijskih stabala za donošenje predikcija.	Breiman 2001

<i>(RF)</i>	Svako pojedinačno stablo trenira se na nasumično odabranom podskupu podataka i značajki, čime se smanjuje osjetljivost na šum i preprilagodbu. Konačna predikcija dobiva se prosjekom predikcija svih stabala u šumi
<i>Regression tree</i>	Jednostavna metoda koja se temelji na rekursivnoj podjeli ulaznog prostora na manje, homogene podprostore, na temelju značajki koje minimiziraju varijabilnost u ciljnim vrijednostima. Svaki list stabla sadrži predikciju koja odgovara prosječnoj vrijednosti ciljne varijable unutar tog podprostora.
<i>(RT)</i>	Loh 2011

4. REZULTATI

4.1 Deskriptivna statistika terenskih mjerena

Utjecaj okolišnih parametara

Za analizu utjecaja okolišnih parametara uključeni su stupnjevi-dana (SD) i broj jajnih legala na plohi A tijekom sezonskih mjerena. Podaci su predstavljeni u tablici 6 i popraćeni osnovnim statističkim indikatorima.

Tablica 6 Deskriptivna analiza okolišnih parametara

Mjesec	Svibanj	Srpanj
mean_stupanj_dani	205.9798	751.8706
min_stupanj_dani	196.0405	685.4262
max_stupanj_dani	220.627	779.9828
sd_stupanj_dani	7.799537	31.42081
mean_jajna_legla	8.95	9.094444
min_jajna_legla	0	0
max_jajna_legla	41	37
sd_jajna_legla	5.999325	7.213192

Vidljivo je da prosječne vrijednosti stupnjeva-dana u svibnju iznose oko 206, s rasponom od minimalnih 196 do maksimalnih 221. Standardna devijacija (7,80) pokazuje umjerenu varijabilnost. U srpnju je, očekivano, prosjek stupnjeva-dana značajno veći (oko 752), dok raspon ide od 685 do 780, uz nešto veću standardnu devijaciju (31,42).

Broj jajnih legala također bilježi blagi porast od svibnja do srpnja. Prosječna vrijednost u svibnju je 8,95, a u srpnju 9,09. Maksimalne vrijednosti iznose 41 u svibnju i 37 u srpnju. Standardna devijacija broja jajnih legala (5,99 u svibnju te 7,21 u srpnju) upućuje na razmjerno raspršene vrijednosti, iako u prosjeku nema velike razlike među mjesecima.

U svibnju se pojavilo nekoliko iznimno visokih vrijednosti broja jajnih legala, dok je u srpnju raspon bio veći, što se može pripisati razlikama u vremenskim (toplinskim) uvjetima ili biološkom ritmu populacije na istoj lokaciji.

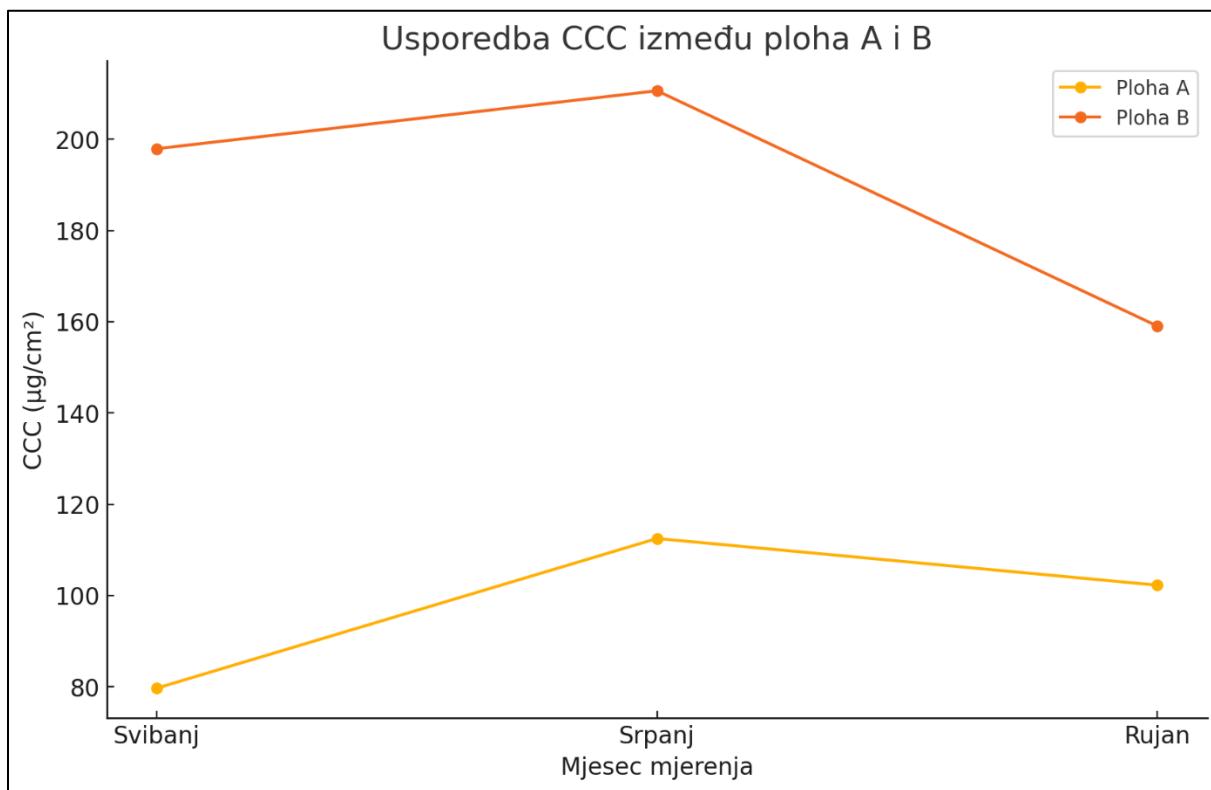
U tablici 7 prikazani su rezultati terenskih LCC mjerjenja na zaraženoj plohi A koristeći SPAD i izračunate LAI vrijednosti za iste poligone na kojima je provedena terenska izmjera SPAD vrijednosti terenskog mjerjenja. Kako je ranije u metodologiji opisano, za LAI vrijednosti koristili smo index vegetacije NDRE i CHM, jer nismo uspeli obaviti terenska LAI mjerjenja .

U svibnju (LCC_05) prosječna koncentracija izmjerene klorofila iznosi 29,41 (SD 10,24), uz minimalnu vrijednost od 1,67 i maksimalnu od 51,88, dok je LAI (LAI_05) u prosjeku 2,71 (SD 0,46) i kreće se između 1,91 i 4,57. U srpnju (LCC_07) dolazi do porasta prosječnog LCC-a na 37,88, dok se LAI povećava na 2,97 (SD 0,60), a najveća izmjerena vrijednost iznosi 5,45. U rujnu (LCC_09) opažamo blagi pad LCC-a (34,32) te stabilnu vrijednost LAI-a (2,98) u odnosu na srpanj, iako je u tom terminu zabilježen značajno veći raspon LAI-a (od 0,73 do 8,11), što upućuje na povećanu raznolikost u vitalnosti vegetacije na plohi A potkraj vegetacijske sezone.

Tablica 7 Deskriptivna statistika koncentracije klorofila i LAI na plohama A i B

	PLOHA A					PLOHA B				
	N	MEAN	SD	MIN	MAX	N	MEAN	SD	MIN	MAX
LCC_05	249	29.41	10.24	1.67	51.88	90	53.35	8.38	34.84	69.62
LAI_05	249	2.71	0.46	1.91	4.57	90	3.71	1.22	2.23	7.86
LCC_07	249	37.88	11.36	9.21	66.00	180	60.70	15.08	34.96	101.79
LAI_07	249	2.97	0.60	1.98	5.45	180	3.47	1.14	2.07	7.64
LCC_09	270	34.32	11.21	7.88	94.25	180	52.50	14.87	25.67	84.03
LAI_09	269	2.98	0.92	0.73	8.11	180	3.03	0.78	1.70	6.80

U svibnju (LCC_05) prosječni LCC iznosi 53,35 (SD 8,38), s rasponom od 34,84 do 69,62, a LAI (3,71) ukazuje na veći indeks lisne površine (SD 1,22) za plohu B u odnosu na plohu A (Tablica 7). U srpnju (LCC_07) prosječni LCC raste na 60,70 (SD 15,08), a maksimalna izmjerena vrijednost doseže 101,79; LAI je tada 3,47 (SD 1,14). U rujnu (LCC_09) LCC pada na 52,50, dok se LAI dodatno smanjuje na 3,03 (SD 0,78), ali i dalje ostaje viši od zabilježenih vrijednosti na plohi A u istom razdoblju.



Slika 11 Usporedba koncentracije klorofila u krošnji između ploha A i B

Grafikon prikazuje promjene CCC (Canopy Chlorophyll Content, izražen u $\mu\text{g}/\text{cm}^2$) na ploham A i B tijekom svibnja, srpnja i rujna. Vrijednosti CCC izračunate su kao umnožak izmjerenih vrijednosti LCC (Leaf Chlorophyll Content) i LAI (Leaf Area Index), čime se procjenjuje ukupna količina klorofila u krošnji po jedinici površine.

Na plohi A, CCC u svibnju ima najnižu vrijednost i bilježi porast u srpnju, nakon čega slijedi blagi pad u rujnu. Ploha B u svibnju pokazuje više početne vrijednosti CCC-a u odnosu na plohu A te nastavlja rasti u srpnju, pri čemu postiže najveću izmjerenu vrijednost. U rujnu dolazi do smanjenja CCC-a na obje plohe, no vrijednosti na plohi B i dalje ostaju više nego na plohi A.

U svim vremenskim točkama, ploha B ima više vrijednosti CCC-a u usporedbi s plohom A. Razlika između ploha prisutna je u svim fazama vegetacije, a najveća se razlika bilježi u svibnju i srpnju. Sezonska dinamika CCC-a na obje plohe pokazuje trend povećanja u srpnju i smanjenja u rujnu, s time da su izmjerene vrijednosti na plohi A niže u svim vremenskim periodima.

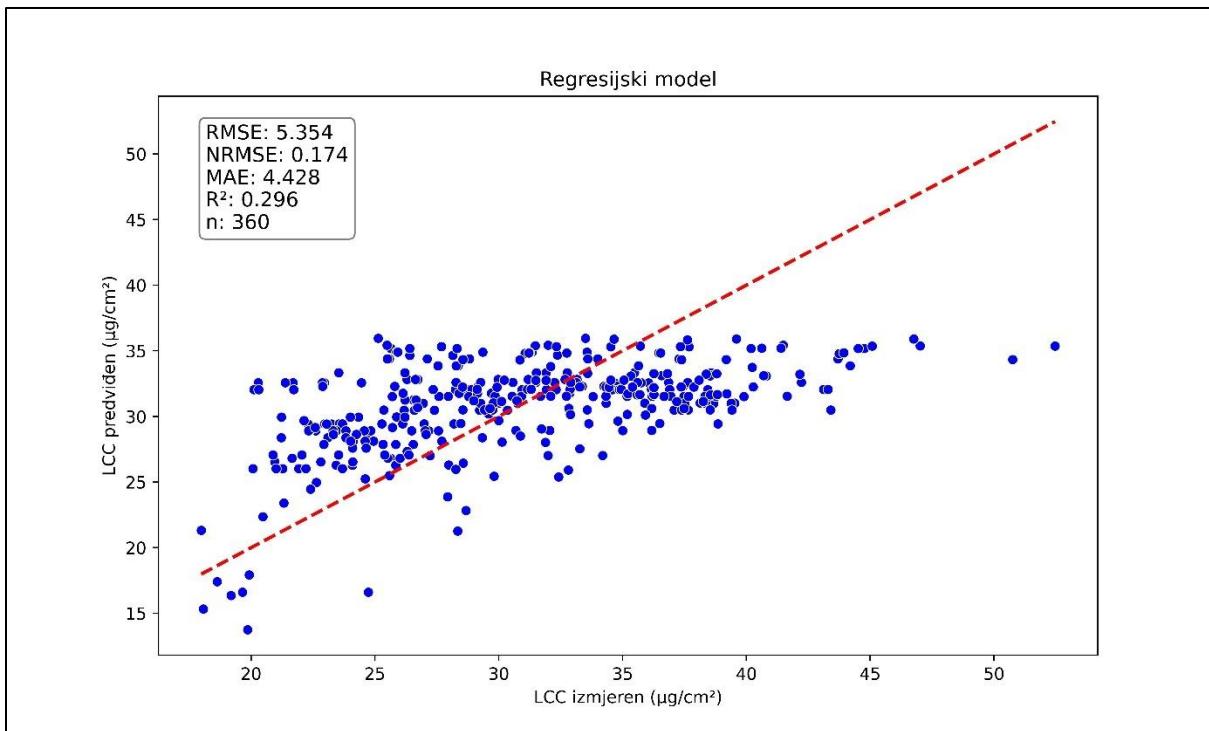
4.2. Rezultati utjecaja okolišnih parametara temperature i broj jajnih legalana klorofil lista

Rezultati analize pokazali su da je na temelju broja jajnih legla i akumuliranih stupanj-dana moguće predvidjeti koncentraciju klorofila u listu, iako s ograničenom točnošću.

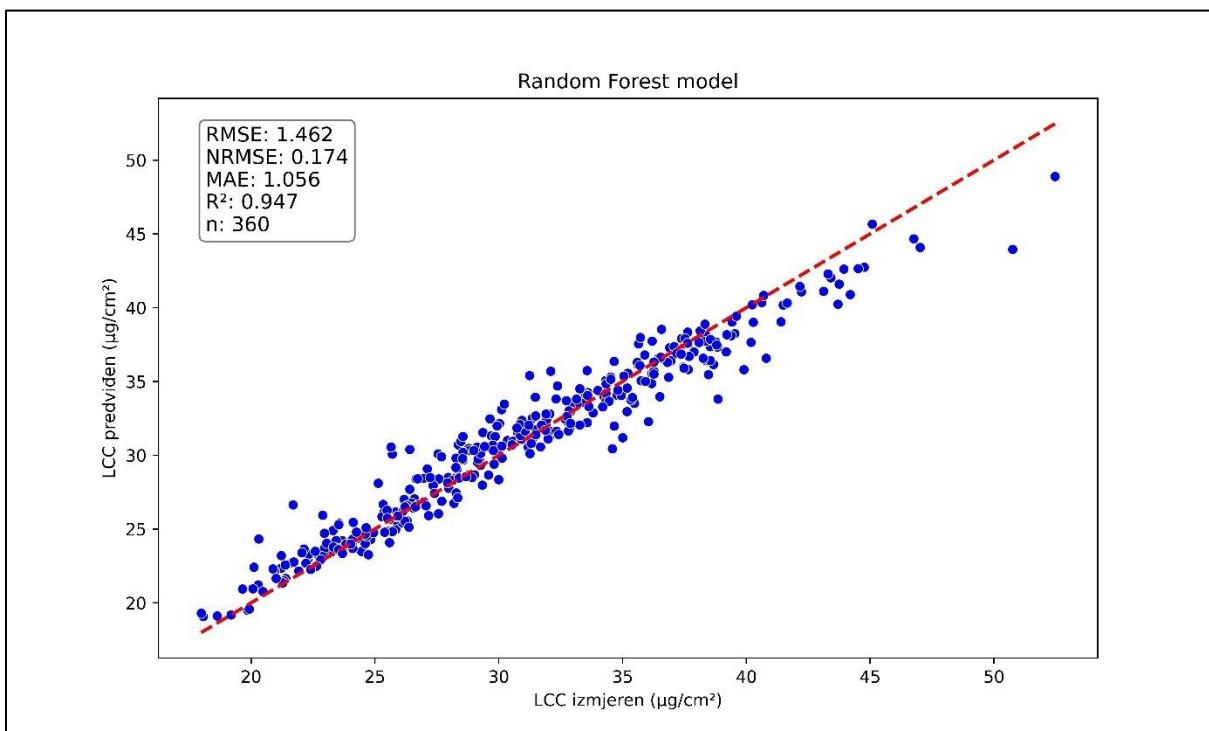
Linearni regresijski model pokazao je relativno slabu sposobnost objašnjavanja varijance u koncentraciji klorofila, s koeficijentom determinacije (R^2) od 0.296. Procijenjena vrijednost korijena srednje kvadratne pogreške (RMSE) iznosila je 5.354, što ukazuje na značajnu razliku između predviđenih i stvarnih vrijednosti koncentracije klorofila.

Random Forest model ostvario je bolju prediktivnu sposobnost u odnosu na linearnu regresiju. Ovaj model bolje je obuhvatio nelinearne odnose između ulaznih varijabli i koncentracije klorofila, što je rezultiralo višim koeficijentom determinacije i nižim RMSE vrijednostima.

Predviđene vrijednosti koncentracije klorofila dobivene primjenom Random Forest modela korištene su kao ulazni podaci u PROSPECT 4 modelu, čime je poboljšana simulacija refleksije listova. Time je omogućeno preciznije modeliranje fiziološkog odgovora stabala na napad štetnika, uzimajući u obzir stvarne utjecaje klimatskih faktora i infestacije HMS-om.



Slika 12 Regresijski model predikcije klorofila iz SD i broja jajnih legala



Slika 13 RF model predikcije klorofila iz SD i broja jajnih legala

4.3. Rezultat analize samostalnih regresijskih algoritama strojnog učenja

Vizualne opservacije (ne) oštećeniji područja i prostorni raspored koncentracije klorofila sa terena se relativno dobro slazu sa generiranim mapama koristeći samostalne regresijske algoritme u ARTMO toolbox. Razlike u koncentraciji klorofila vidljive su na generiranim mapama iz svibnja, srpnja i rujna, pri čemu je upravo ovakav vremenski raspored odabran jer štete uzrokovane HMS-om nisu jednako uočljive u svim fazama vegetacije. U narednim paragrafima, detalji analize su prikazani za svaki mjesec. Odabran je pristup gdje su kombinirani podaci sa obje plohe kako bi se dodalo varijabilnosti podacima. U Prilogu 2 vidljiv je samostalni pristup gdje su plohe odvojene.

Predikcija sadržaja klorofila krošnje za svibanj

U svibnju, rezultati prikazani u tablici 8 upućuju na to da GPR model postiže najbolje rezultate, s najnižom RMSE vrijednošću ($46,35 \mu\text{g}/\text{cm}^2$) i najvišim koeficijentom determinacije ($R^2 = 0,642$), potvrđujući njegovu sposobnost modeliranja složenih nelinearnih odnosa u podacima. Ova vrijednost koeficijenta determinacije ukazuje da oko 64% varijacije u sadržaju klorofila može biti objašnjeno ovim modelom.

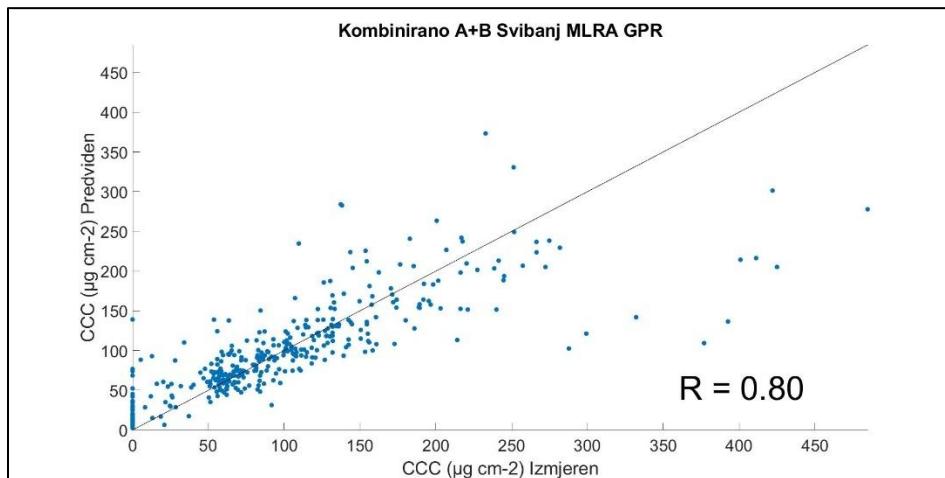
Tablica 8 Performanse različitih MLRA za svibanj

MLRA	RMSE	NRMSE	R2
	($\mu\text{g}/\text{cm}^2$)	(%)	
GPR	46.3533	9.5631	0.642
KRR	53.2235	10.9804	0.5303
RF	55.5117	11.4525	0.4861
RT	65.988	13.6138	0.3556
NN	67.2031	13.8645	0.2578
LSLR	70.3424	14.5122	0.1739

Iako su se KRR i RF modeli također pokazali relativno učinkovitim, KRR ostvaruje nešto lošije rezultate od GPR-a ($\text{RMSE} = 53,22 \mu\text{g}/\text{cm}^2$, $R^2 = 0,5303$), dok RF postiže još niži R^2 od 0,4861. RT (Random Trees) i NN (Neural Network) modeli pokazuju slabiju prediktivnu moć, sa znatno višim RMSE vrijednostima ($RT = 65,98 \mu\text{g}/\text{cm}^2$, $NN = 67,20 \mu\text{g}/\text{cm}^2$), dok njihov R^2 pada ispod

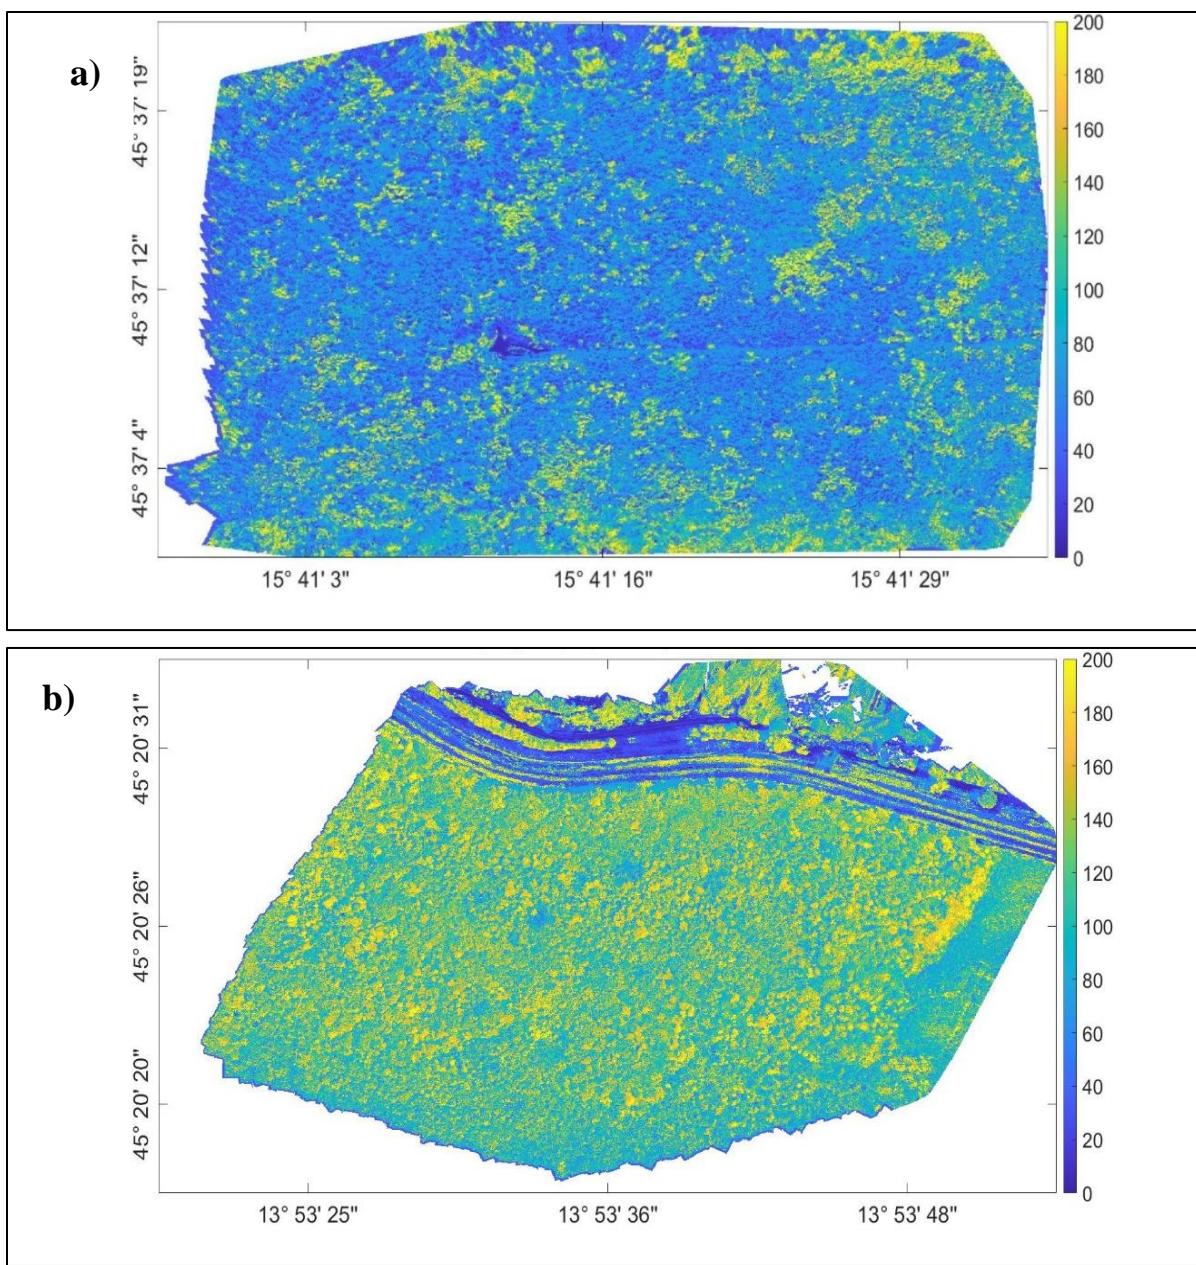
0,36, ukazujući na značajna odstupanja od stvarnih vrijednosti klorofila. Najslabije performanse ima linearni LSLR model, koji dostiže RMSE od $70,34 \mu\text{g}/\text{cm}^2$ i najniži R^2 (0,1739), što jasno potvrđuje ograničenja linearne regresije u složenim prostornim podacima.

Na temelju grafičkog prikaza izmjerениh naspram predviđenih vrijednosti klorofila, vidljivo je da GPR model pokazuje relativno dobru usklađenost s stvarnim podacima. Podaci su raspoređeni uz regresijsku liniju, ali uz određenu raspršenost, osobito na rubnim vrijednostima klorofila, gdje model pokazuje veće odstupanje. Korelacija između izmjerениh i predviđenih vrijednosti iznosi $R = 0.80$, što upućuje na snažnu pozitivnu povezanost. Ova vrijednost ukazuje na to da model u velikoj mjeri uspješno rekonstruira varijacije u sadržaju klorofila, iako postoje slučajevi gdje su predviđene vrijednosti nešto niže ili više od stvarnih.



Slika 14 GPR model za svibanj

GPR model postiže RMSE od $46.35 \mu\text{g}/\text{cm}^2$, što je najmanja pogreška u usporedbi s ostalim modelima, no i dalje postoje odstupanja koja su vidljiva na grafu. U nekim slučajevima model podcjenjuje izmjerene vrijednosti klorofila, dok u drugima precjenjuje, što može ukazivati na ograničenja u sposobnosti modela da precizno zahvati složene prostorne varijacije.



Slika 15 a i b Primijenjen GPR model za svibanj na plohe A i B

Na zaraženoj plohi A (15a) vidljive su niže vrijednosti CCC, što ukazuje na smanjenje fotosintetske aktivnosti uslijed početne faze oštećenja uzrokovaniog HMS. Ova smanjenja su prostornih karakteristika, s većim varijacijama između različitih dijelova krošnje. Oštećeni dijelovi pokazuju znatno niže koncentracije klorofila, dok su pojedini segmenti krošnje s manjim stresom zadržali relativno više vrijednosti.

Uz smanjenje CCC vrijednosti, na plohi A su vidljive i povišene vrijednosti ostale vegetacije, što znači da su neki istraživanog područja a na kojima su prisutne druge vrste kao npr. obični grab s višim spektralnim refleksijama od lisne mase hrastova.

Za razliku od toga, kontrolna ploha B (15b) pokazuje homogenu raspodjelu klorofila, bez značajnih prostorno različitih vrijednosti. CCC vrijednosti su relativno visoke i ujednačene u cijeloj plohi, što ukazuje na zdravu i stabilnu fotosintetsku aktivnost krošnja stabala. Nedostatak značajnih varijacija potvrđuje da na plohi B nema vidljivih znakova vegetacijskog stresa.

Predikcija sadržaja klorofila krošnje za srpanj

U tablici 9 vidljivo je da GPR model postiže najbolje rezultate, s najnižom pogreškom RMSE od $44.26 \mu\text{g}/\text{cm}^2$ i najvišim koeficijentom determinacije $R^2 = 0.7764$, što ukazuje na visoku preciznost u predviđanju vrijednosti klorofila. KRR također pokazuje solidne performanse s RMSE od $48.78 \mu\text{g}/\text{cm}^2$ i $R^2 = 0.7247$, no nešto je manje precizan od GPR.

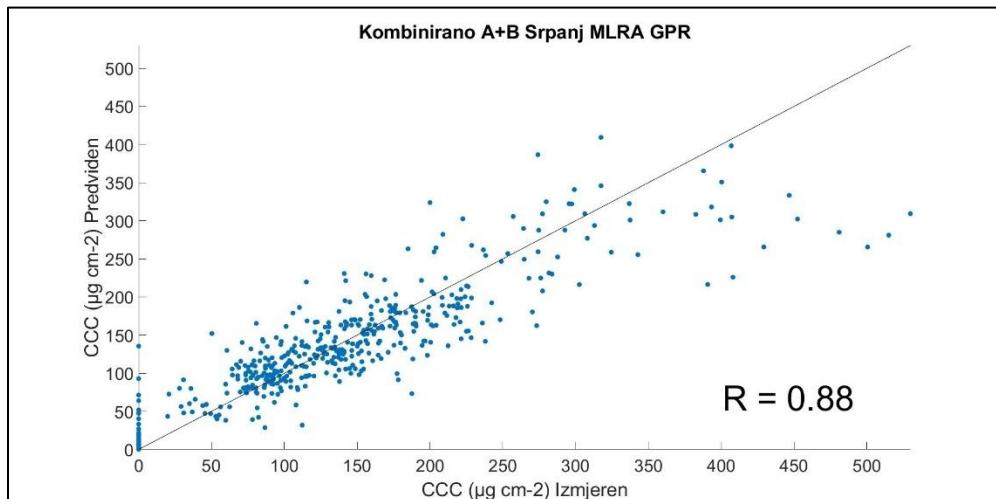
LSLR ostvaruje RMSE od $54.02 \mu\text{g}/\text{cm}^2$, a RF i NN modeli pokazuju vrlo slične rezultate s RMSE vrijednostima oko 54.87 – $54.95 \mu\text{g}/\text{cm}^2$ i R^2 vrijednostima oko 0.65. Ovi modeli imaju nešto veću pogrešku i slabiju sposobnost objašnjavanja varijacija u klorofilu u usporedbi s GPR i KRR.

Najslabiji model je RT koji postiže najveću pogrešku RMSE = $63.58 \mu\text{g}/\text{cm}^2$ i najniži R^2 od samo 0.5625, što upućuje na njegovu ograničenu sposobnost u preciznoj predikciji

Tablica 9 Performanse različitih MLRA za srpanj

MLRA	RMSE	NRMSE	R2
	($\mu\text{g}/\text{cm}^2$)	(%)	
GPR	44.2579	8.3529	0.7764
KRR	48.7768	9.2057	0.7247
LSLR	54.0249	10.1962	0.6612
RF	54.8746	10.3566	0.6506
NN	54.9467	10.3702	0.6502
RT	63.582	12	0.5625

Na Slici 16 je prikazan odnos između izmjerena i predviđena vrijednosti klorofila za srpanj, pri čemu je primijenjen GPR model. Graf prikazuje korelaciju između stvarnih i modeliranih podataka,

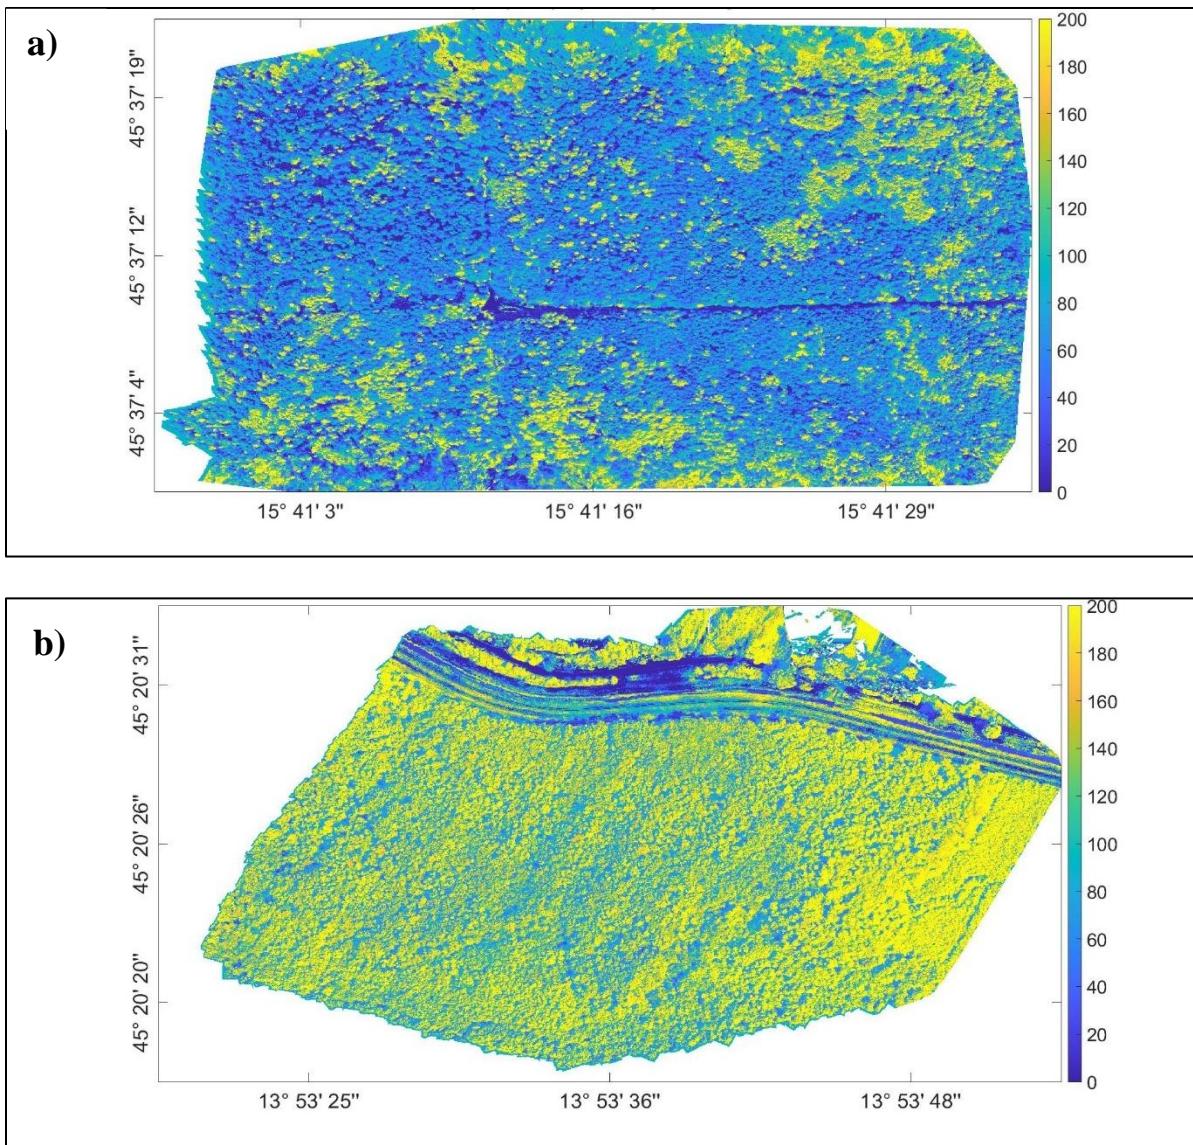


Slika 16 GPR model za srpanj

Pearsonova korelacija od $R = 0.88$ pokazuje snažnu povezanost između izmjerena i predviđena vrijednosti klorofila, potvrđujući da GPR model precizno rekonstruira prostorne varijacije sadržaja klorofila u srpnju. Točnost predikcije vidljiva je kroz koncentraciju podataka uz regresijsku liniju, što ukazuje na visoku usklađenost modeliranih i stvarnih vrijednosti, uz minimalna odstupanja.

Manja raspršenost podataka ukazuje na dobru generalizaciju modela, dok su vidljive razlike ovisne o rasponu vrijednosti. U nižim koncentracijama klorofila model povremeno precjenjuje stvarne vrijednosti, dok kod viših vrijednosti dolazi do podcenjivanja, pri čemu predviđeni sadržaj klorofila ostaje nešto niži od izmjerene. Ova razlika može biti posljedica ograničene prisutnosti visokih vrijednosti u skupu podataka, što može utjecati na točnost modela pri predviđanju ekstremnih slučajeva.

Iako postoji manji pad preciznosti u najvišim koncentracijama klorofila, GPR model se pokazao kao najpouzdaniji pristup za procjenu sadržaja klorofila, precizno prepoznajući ključne obrasce u podacima i omogućujući pouzdanu analizu promjena u vegetaciji.



Slika 17 a i b Primijenjen GPR model za srpanj na plohe A i B

U srpnju, primjena GPR modela na snimke jasno ističe razlike u sadržaju klorofila između istraživanih ploha, pri čemu se na plohi B očituju više i homogenije vrijednosti, dok ploha A i dalje pokazuje niže koncentracije, što ukazuje na nastavak utjecaja HMS-a.

U odnosu na svibanj, prostorna raspodjela klorofila u srpnju pokazuje još izraženije razlike između ploha, s time da na plohi A (17 a) dolazi do daljnog smanjenja vrijednosti klorofila, ali i neujednačenosti unutar same plohe. Oštećenja su sada vidljivija i izraženija u pojedinim dijelovima krošnje, što ukazuje na progresivno djelovanje HMS, dok neki dijelovi vegetacije još uvijek zadržavaju određene vrijednosti klorofila, stvarajući heterogenu raspodjelu unutar plohe.

Na plohi B (17 b), vrijednosti klorofila ostaju stabilne i ravnomjerno raspoređene, potvrđujući da u tom području nema značajnih promjena ili znakova stresa. GPR model pouzdano razlikuje ovu uniformnost od varijabilnosti prisutne na plohi A, što dodatno naglašava njegovu sposobnost preciznog mapiranja razlika u vegetaciji. Ovi rezultati potvrđuju da u srpnju oštećenja uzrokovana HMS-om postaju izraženija nego u ranijim mjesecima, dok zdrava stabla održavaju stabilnu fotosintetsku aktivnost.

Predikcija sadržaja klorofila krošnje za rujan

U rujnu GPR i dalje pokazuje najbolje performanse (Tablica 10) s najnižim RMSE ($49.70 \mu\text{g}/\text{cm}^2$) i najvišim R^2 (0.521), potvrđujući svoju superiornost u predikciji sadržaja klorofila. KRR slijedi s nešto slabijim rezultatima (RMSE = $50.49 \mu\text{g}/\text{cm}^2$, R^2 = 0.5061), dok RF postiže još nižu preciznost (RMSE = $52.95 \mu\text{g}/\text{cm}^2$, R^2 = 0.4583).

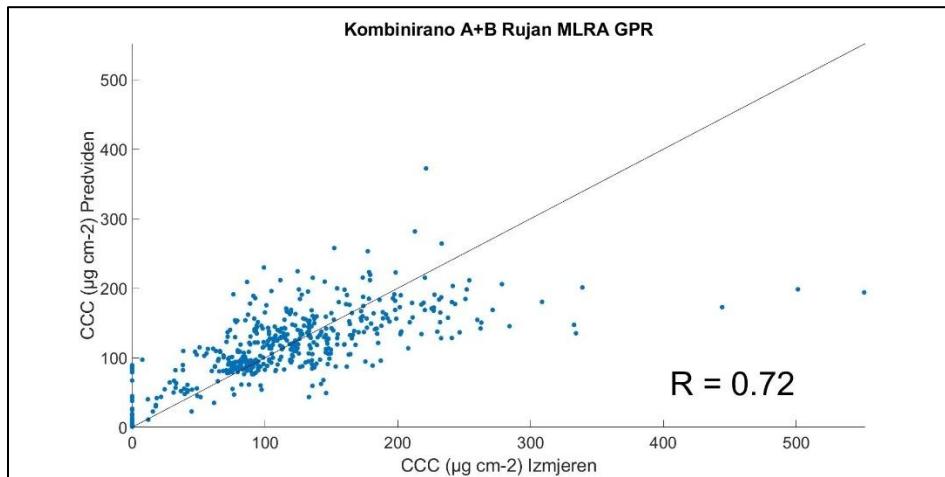
Tablica 10 Performanse različitih MLRA za rujan

MLRA	RMSE <i>($\mu\text{g}/\text{cm}^2$)</i>	NRMSE <i>(%)</i>	R2
GPR	49.7035	9.0125	0.521
KRR	50.493	9.1556	0.5061
RF	52.9566	9.6023	0.4583
NN	56.2833	10.2055	0.3956
LSLR	61.1252	11.0835	0.286
RT	62.1518	11.2696	0.3561

NN pokazuje pad u prediktivnoj sposobnosti s većom pogreškom (RMSE = $56.28 \mu\text{g}/\text{cm}^2$, R^2 = 0.3956), dok LSLR i RT imaju najlošije performanse, s najvišim RMSE vrijednostima (61.12 i $62.15 \mu\text{g}/\text{cm}^2$) i najnižim R^2 (0.286 i 0.3561).

Općenito, svi modeli pokazuju slabiju prediktivnu preciznost u usporedbi s prethodnim mjesecima, no GPR ostaje najpouzdaniji izbor, dok su LSLR i RT najmanje precizni.

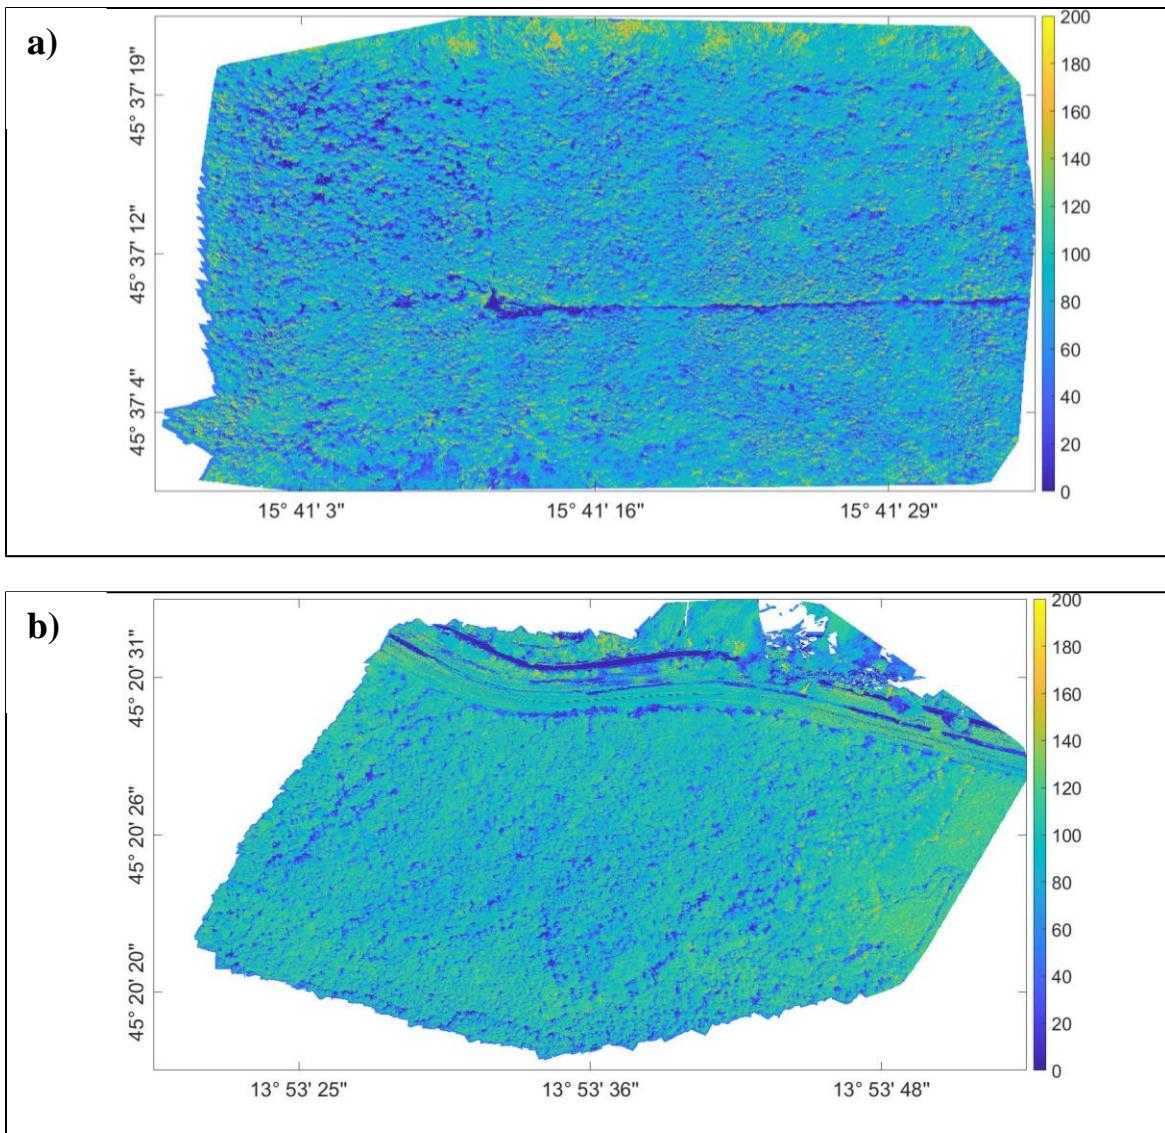
Slika 18 prikazuje odnos između izmjerениh i predviđenih vrijednosti klorofila za rujan, pri čemu je $R = 0.72$, što ukazuje na umjerenu povezanost između modeliranih i stvarnih podataka.



Slika 18 GPR model za rujan

Najveće odstupanje vidljivo je kod viših vrijednosti klorofila, koje su značajno podcijenjene. Model sustavno predviđa niže koncentracije klorofila od izmjerениh, što može biti posljedica nedovoljne zastupljenosti visokih vrijednosti u podacima za treniranje ili povećane varijabilnosti vegetacijskih uvjeta u rujnu. Ovo podcjenjivanje može ukazivati na ograničenja modela u hvatanju ekstremnih vrijednosti, dok u srednjem rasponu model pokazuje bolju usklađenost.

Raspršenost podataka pri nižim vrijednostima također sugerira određene nesigurnosti u predikcijama, ali su ona manje izražena u odnosu na podcjenjivanje visokih koncentracija klorofila. Unatoč ovim odstupanjima, $R = 0.72$ i dalje potvrđuje da model prepozna ključne obrazce u podacima, iako s nižom preciznošću nego u prethodnim mjesecima.



Slika 19 a i b Primijenjen GPR model za rujan na plohe A i B

Primjenom modela na snimke u rujnu, jasno je vidljivo opće smanjenje koncentracije klorofila na obje plohe, što upućuje na sezonske promjene u vegetaciji i mogući nastavak utjecaja HMS-a na plohu A.

Na plohi A, smanjenje je izraženije i nepravilnije raspoređeno, pri čemu su pojedini dijelovipokazali značajan pad vrijednosti klorofila, dok su drugi zadržali nešto više razine. Ova heterogenost sugerira da utjecaj HMS-a nije jednolikoraspoređen te da su neki segmenti stabala i dalje pod jačim stresom. Prostorna analiza otkriva jasne zone s niskim vrijednostima, gdje je fotosintetska aktivnost znatno smanjena.

Na plohi B, iako je također došlo do općeg pada koncentracije klorofila, razina klorofila je vidljivo viša u odnosu na plohu A i raspoređena homogenije, što upućuje na stabilnije stanje vegetacije. Odsutnost značajnijih stresnih faktora na ovoj plohi omogućila je ujednačeniju degradaciju klorofila, u skladu s očekivanim sezonskim promjenama.

Ova analiza potvrđuje da model uspješno detektira razlike u dinamici vegetacije između ploha, jasno prikazujući izraženiji stres i degradaciju na plohi A u odnosu na kontrolnu plohu B

4.4 Hibridni modeli

Rezultati hibridnog pristupa koji kombinira PROSAIL model s algoritmima regresije strojnim učenjem (MLRAs) detaljno su prikazani u sljedećim paragrafima za tri promatrana mjeseca na oba lokaliteta (ploha A - zaražena HMS-om i ploha B - nezaražena). Rezultati pokazuju varijabilne performanse ovisno o mjesecu i plohi, čime se mogu uočiti razlike u složenosti uvjeta unutar šumskih krošnji kroz različite faze vegetacije. U ovom hibridnom pristupu smo koristili PROSAIL+GPR, jer smo zaključili da je GPR, uz KRR, imao najbolje rezultate u samostalnim regresijskim modeliranjima. U tablici 11 su prikazani regresijski rezultati ovog hibridnog modela za svaki mjesec za plohe A i B.

Tablica 11. Rezultati metrike GPR hibridnog modela

	RMSE	NRMSE	R2
SVIBANJ_A	30.5314	19.2287	0.4983
SVIBANJ_B	280.7940	57.9301	0.3759
SRPANJ-A	80.1426	29.3246	0.1833
SRPANJ-B	110.8158	20.9145	0.4922
RUJAN-A	165.3252	49.6401	0.0611
RUJAN-B	105.3880	19.1215	0.2101

U svibnju, rezultati metrike za hibridni GPR model (PROSAIL + GPR) pokazuju umjerenu prediktivnu sposobnost, pri čemu je RMSE na plohi A ($30.53 \mu\text{g}/\text{cm}^2$) znatno niži nego na plohi B ($280.79 \mu\text{g}/\text{cm}^2$), dok su vrijednosti R^2 relativno niske za obje plohe (0.4983 i 0.3759). Ovi rezultati ukazuju na određenu varijabilnost modelskih predikcija, pri čemu se hibridni model nije pokazao superiornim u odnosu na klasične regresijske pristupe.

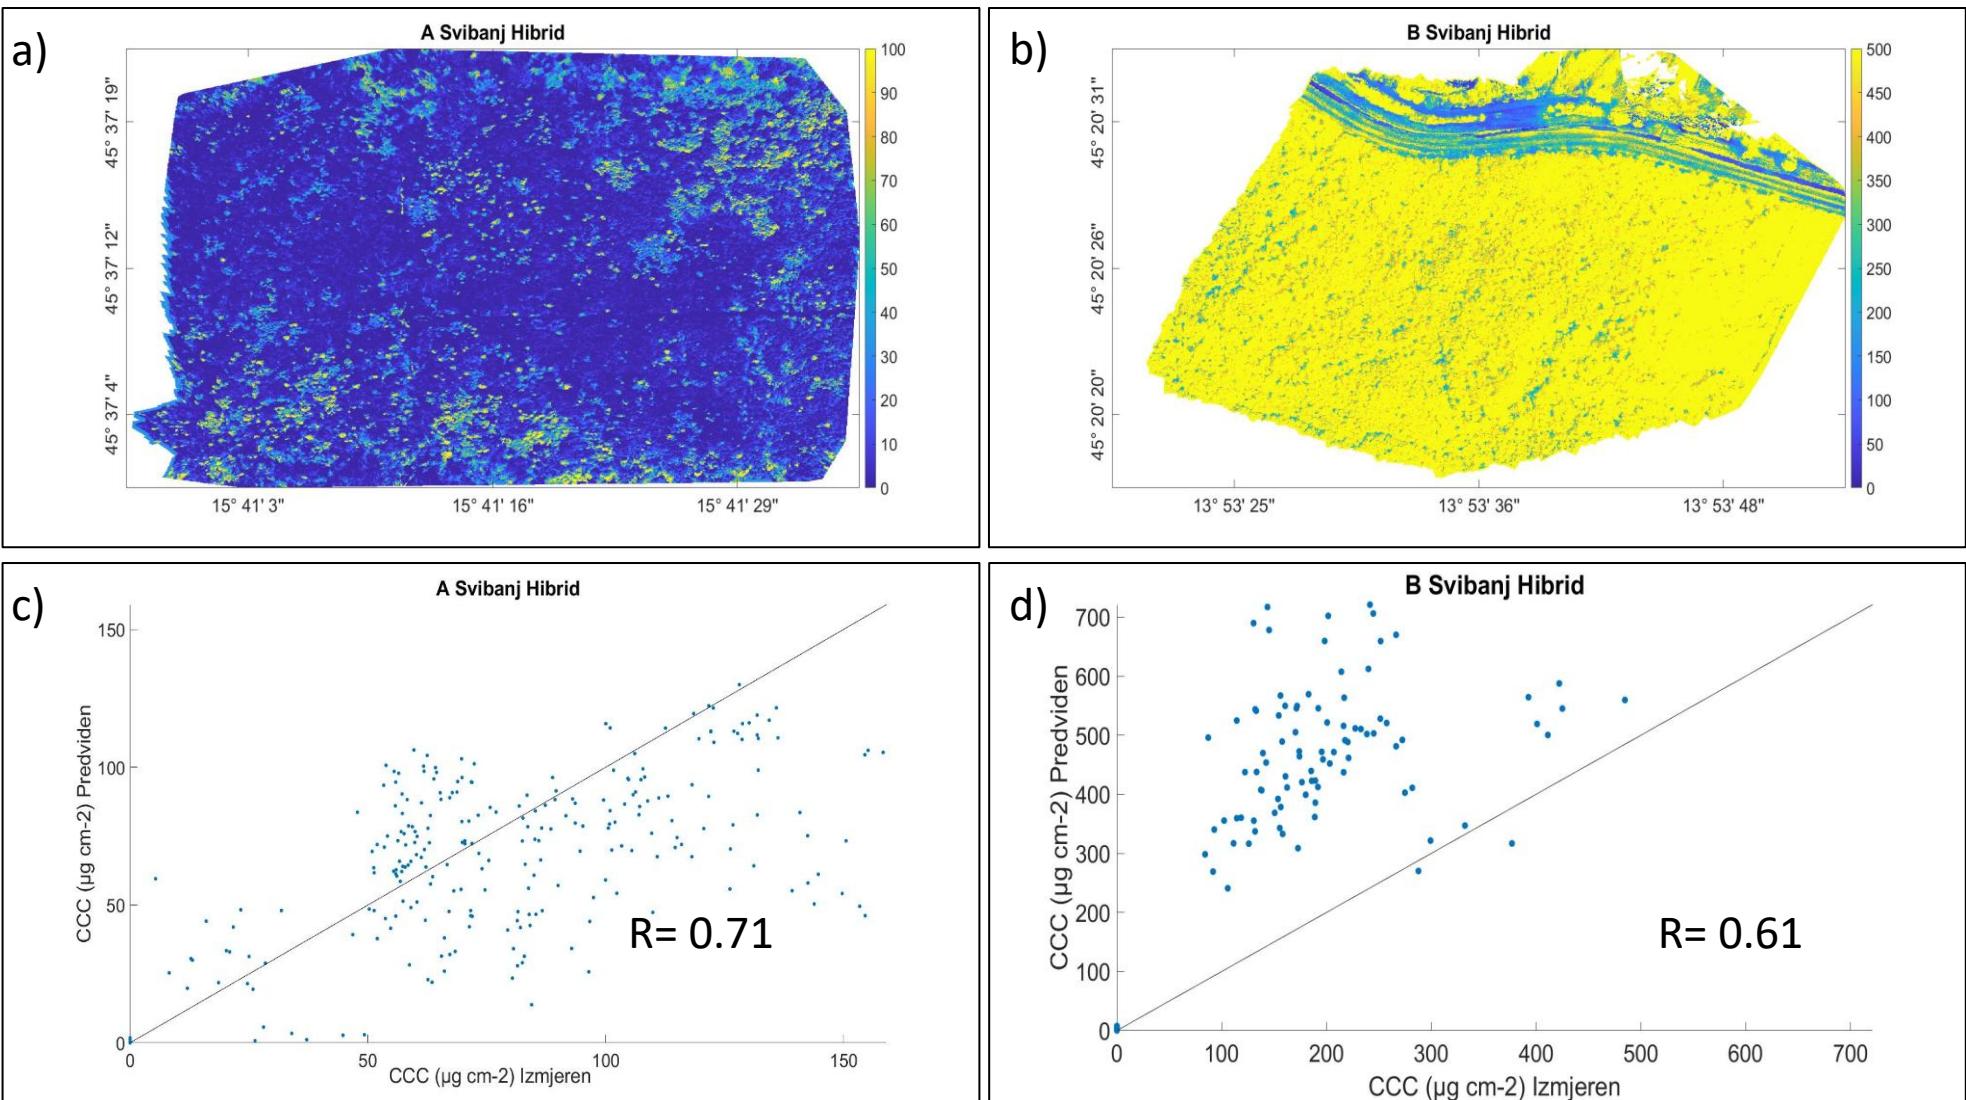
Visoke vrijednosti NRMSE (19.23% na plohi A i čak 57.93% na plohi B) dodatno potvrđuju nestabilnost modela, posebno na kontrolnoj plohi, gdje dolazi do značajnijih odstupanja između izmjerениh i predviđenih vrijednosti.

Prostorna analiza na Slikama 20 a i b pokazuje da hibridni model uspijeva detektirati osnovne gradijente klorofila, no oštećenja uzrokovana HMS-om još nisu jasno izražena. Na plohi A (Slika 20a) vidljive su tamnije nijanse, što upućuje na niže koncentracije klorofila u pojedinim dijelovima krošnje, no model ne uspijeva u potpunosti naglasiti ovu heterogenost. Nasuprot tome, prostorna karta plohe B (Slika 20 b) pokazuje ujednačeniju raspodjelu klorofila, međutim vrijednosti su precijenjene.

Koeficijenti korelacije također odražavaju ograničenja hibridnog modela – za plohu A, $R = 0.71$, dok za plohu B, $R = 0.61$, što upućuje na relativno bolju povezanost modeliranih i stvarnih vrijednosti na zaraženoj plohi, ali i dalje ukazuje na značajnu nesigurnost modela.

Na plohi A (20c), vrijednosti su značajno raspršene, što upućuje na veliku varijabilnost predikcija i nedostatnu preciznost modela u detekciji sadržaja klorofila. Ova visoka disperzija podataka ukazuje da model nema konzistentnost u predviđanju nižih ni viših vrijednosti, što otežava razlikovanje područja s izraženim stresom od zdravih segmenata krošnje.

Na plohi B (20d), situacija je nešto drugačija – vrijednosti su koncentrirane u gornjem lijevom kvadrantu, što znači da su izmjerene niže vrijednosti klorofila često značajno precijenjene. Ova pojava sugerira da model nema dovoljno preciznosti u predviđanju područja s manjim koncentracijama klorofila, što može dovesti do netočnog prikaza stvarnog stanja vegetacije na ovoj plohi.



Slika 20 Performanse hibridnog pristupa i primijenjeni model na plohe A (a i c) i B (b i d) za svibanj

Rezultati hibridnog GPR modela (PROSAIL + GPR) za srpanj pokazuju znatne varijacije u prediktivnoj sposobnosti modela između ploha A i B. Prema tabličnim pokazateljima, RMSE i NRMSE vrijednosti ukazuju na velike pogreške u predikciji, dok su R^2 koeficijenti niski, sugerirajući smanjenu pouzdanost modela u ovom periodu.

Na plohi A, model ostvaruje visoku RMSE pogrešku ($80.14 \mu\text{g}/\text{cm}^2$) i relativno visok NRMSE (29.32%), što potvrđuje veliku varijabilnost u predikcijama. Koeficijent determinacije $R^2 = 0.1833$ dodatno pokazuje da model nije u stanju objasniti značajan dio varijacije u podacima, što sugerira da hibridni model ne uspijeva precizno detektirati promjene u sadržaju klorofila na ovoj plohi. Velika pogreška može biti rezultat povećane heterogenosti krošnje u srpnju, gdje HMS izaziva lokalne promjene u fotosintetskoj aktivnosti koje model ne prepozna dosljedno.

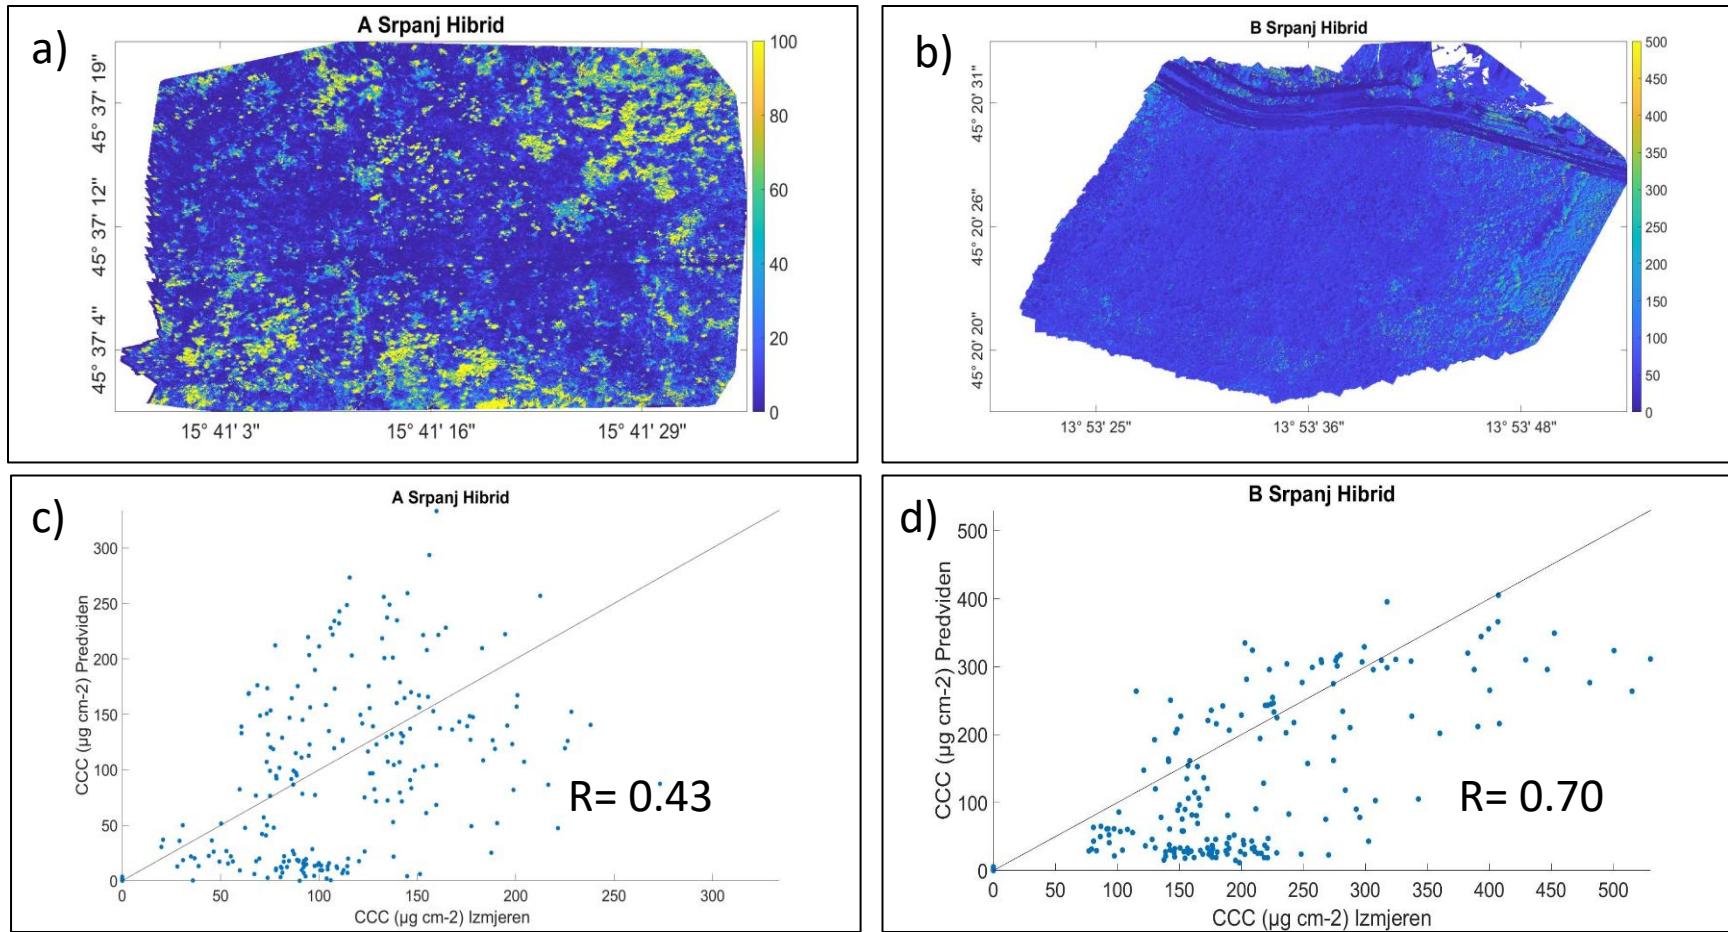
Na plohi B, iako su predikcije stabilnije, RMSE iznosi $110.81 \mu\text{g}/\text{cm}^2$, a NRMSE 20.91%, što je i dalje visoka pogreška. Međutim, $R^2 = 0.4922$ ukazuje na znatno bolju povezanost modelskih predikcija s izmjerenim vrijednostima u odnosu na plohu A, iako model i dalje pokazuje određena odstupanja. Manja heterogenost vegetacije na plohi B omogućila je bolju preciznost modela, no visoke pogreške ukazuju da model nije u potpunosti pouzdan u kvantifikaciji sadržaja klorofila.

Na plohi A (21 c), vrijednosti su znatno raspršene oko dijagonalne linije (1:1), pri čemu je Pearsonova korelacija $R = 0.43$, što upućuje na nisku povezanost između izmjerениh i predviđenih vrijednosti. Model ne uspijeva precizno identificirati prostorne gradijente klorofila, a visoka disperzija točaka ukazuje na veliku nesigurnost u predikcijama. Ova pojava može biti posljedica pojačane heterogenosti vegetacije na zaraženoj plohi, gdje model ne prepozna pravilne obrasce raspodjele klorofila.

Na plohi B (21 d), podaci su koncentriraniji, ali su veće vrijednosti klorofila značajno podcijenjene, što rezultira Pearsonovom korelacijom $R = 0.70$. Ova vrijednost ukazuje na umjerenou jaku povezanost između izmjerenihs i predviđenih vrijednosti, ali prisutna sistematska pogreška sugerira da model sustavno podcjenjuje više koncentracije klorofila, dok su niže vrijednosti precijenjene. Ovakav obrazac može ukazivati na ograničenja modela u predikciji ekstrema, što može biti posljedica spektralne nesigurnosti ili nedovoljno precizne kalibracije ulaznih podataka.

Prostorna analiza na snimkama ukazuje na daljnje smanjenje sadržaja klorofila na obje plohe, ali uz izraženiju prostornu heterogenost na plohi A (21 a). Na ovoj plohi vidljive su zone s izraženim padom klorofila, što može biti rezultat napredovanja HMS zaraze. Međutim, zbog visoke varijabilnosti modelskih predikcija, teško je sa sigurnošću potvrditi preciznost detekcije oštećenja samo na temelju modela.

Na plohi B (21 b), model prikazuje stabilniju raspodjelu klorofila, ali s vidljivim podcenjivanjem viših vrijednosti. Ova sistemska pogreška može otežati točnu interpretaciju promjena u vegetaciji, što ukazuje na potrebu za poboljšanjem modelskih parametara ili dodatnim prilagođavanjem spektralnih značajki.



Slika 21 Performanse hibridnog pristupa i primijenjeni model na plohe A (a i c) i B (b i d) za srpanj

Rezultati hibridnog GPR modela (PROSAIL + GPR) za rujan pokazuju daljnje smanjenje preciznosti modela, pri čemu su RMSE i NRMSE vrijednosti visoke, a R^2 koeficijenti vrlo niski, što ukazuje na smanjenu pouzdanost modela u kvantifikaciji sadržaja klorofila.

Na plohi A, model ostvaruje izrazito visoku RMSE pogrešku ($165.33 \mu\text{g}/\text{cm}^2$) i NRMSE (49.64%), dok je $R^2 = 0.0611$, što ukazuje na gotovo nikakvu objašnjenu varijabilnost podataka od strane modela. Ovi rezultati potvrđuju da model nije sposoban prepoznati prostorne obrasce raspodjele klorofila u rujnu, kada su promjene u krošnji značajne, a heterogenost vegetacije visoka. Velika pogreška može biti rezultat progresije HMS zaraze i sezonskih promjena, zbog čega model ne uspijeva identificirati precizne obrasce gubitka klorofila.

Na plohi B, iako su predikcije stabilnije, RMSE iznosi $105.38 \mu\text{g}/\text{cm}^2$, a NRMSE 19.12%, što je i dalje relativno visoka pogreška, no manja u odnosu na plohu A. $R^2 = 0.2101$ pokazuje da model objašnjava samo 21% varijabilnosti podataka, što upućuje na ograničenu preciznost. Iako su varijacije klorofila na ovoj plohi manje izražene, model pokazuje sustavno podcjenjivanje vrijednosti, što otežava točnu procjenu fotosintetske aktivnosti.

Grafički prikaz dodatno potvrđuje razlike u performansama modela između ploha.

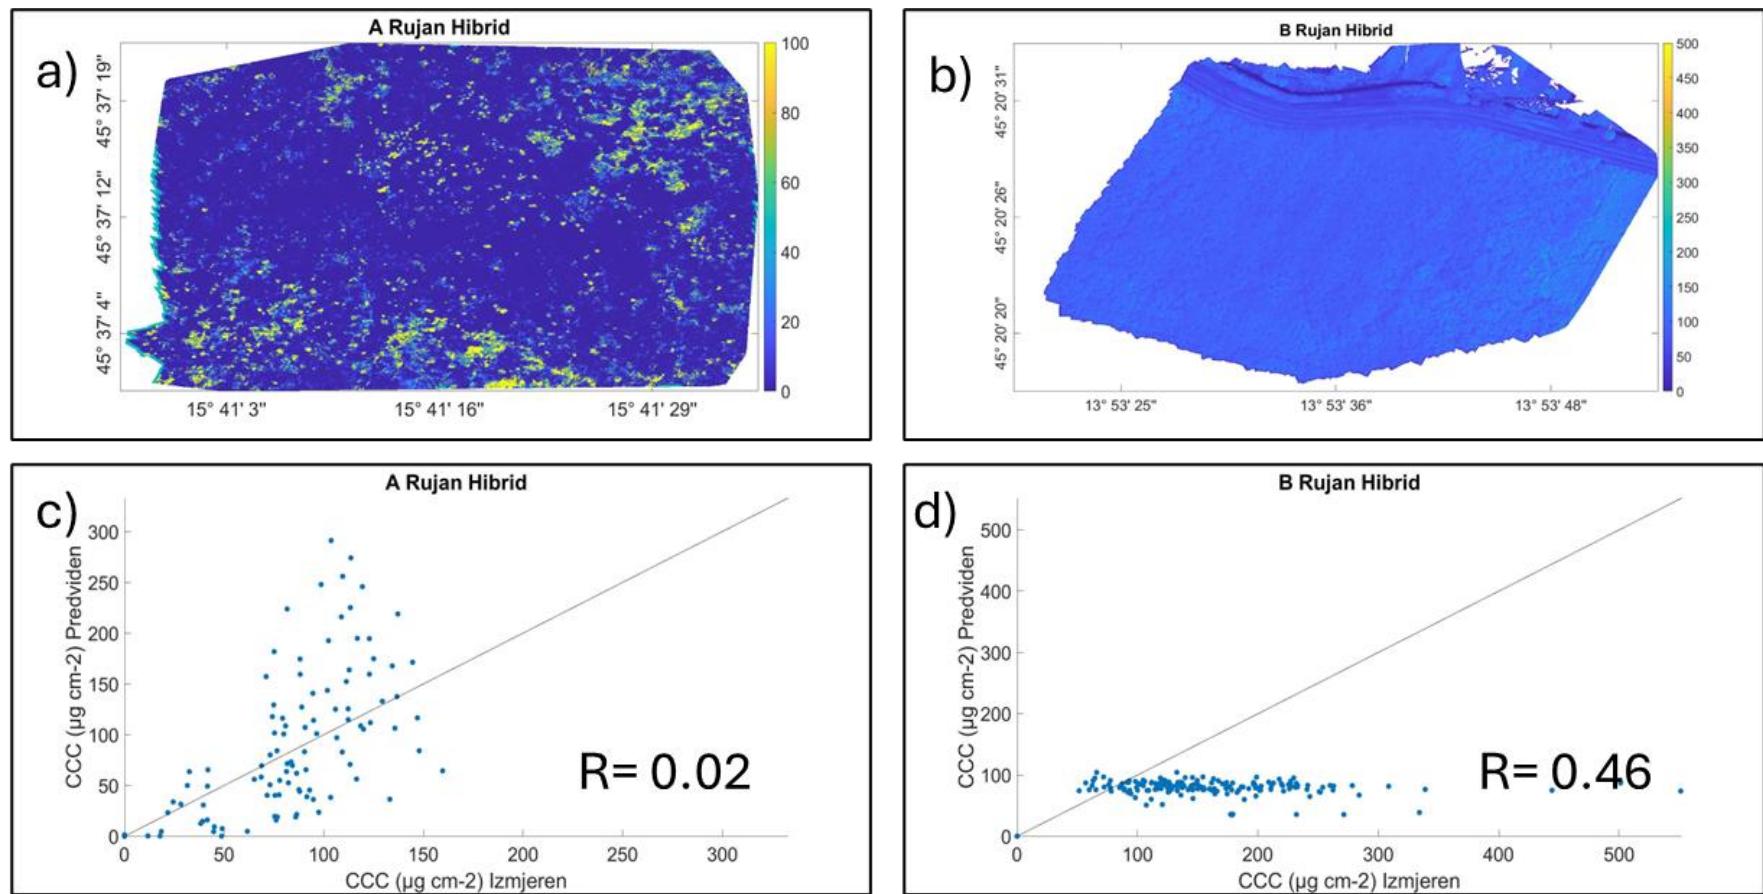
Na plohi A (22 c), vrijednosti su izrazito raspršene oko dijagonalne linije (1:1), što pokazuje izuzetno nisku korelaciju između izmjerениh i predviđenih vrijednosti ($R = 0.02$). Ova izrazita disperzija potvrđuje da model potpuno gubi sposobnost predviđanja klorofila, što ukazuje na njegovu nedosljednost u složenim uvjetima kasne vegetacijske sezone. Velika nesigurnost modelskih predikcija onemogućava prepoznavanje područja s većim oštećenjima i onih koja još uvijek zadržavaju višu fotosintetsku aktivnost.

Na plohi B (22 d), vrijednosti su znatno grupirane, no izrazito podcijenjene, što rezultira Pearsonovom korelacijom $R = 0.46$. Iako je povezanost bolja nego na plohi A, ovaj rezultat pokazuje da model sustavno podcjenjuje više vrijednosti klorofila, što može ukazivati na ograničenja modela u predikciji ekstrema. Ova sistemska pogreška može biti posljedica nedostatka spektralne osjetljivosti modela ili potrebe za dodatnom kalibracijom ulaznih podataka.

Prostorna analiza na snimkama ukazuje na daljnji pad koncentracije klorofila na obje plohe, ali uz ekstremne razlike u modelskim predikcijama.

Na plohi A (22 a), model ne uspijeva identificirati konzistentne obrasce raspodjele klorofila, pri čemu dolazi do velikih varijacija u predikcijama između različitih segmenata krošnje. Ova nepravilnost može biti posljedica pojačane degradacije lisne mase uslijed HMS zaraze, ali i ograničenja modela u prepoznavanju složenih spektralnih promjena u kasnoj fazi vegetacije.

Na plohi B (22 b), model prikazuje ujednačeniji raspored klorofila, ali s vidljivim podcenjivanjem viših vrijednosti, što znači da predikcije ne reflektiraju stvarnu distribuciju fotosintetske aktivnosti. Iako bi se očekivala stabilnija predikcija u odnosu na plohu A, sustavna pogreška u procjeni viših vrijednosti klorofila ukazuje da model nije sposoban precizno kvantificirati varijacije u zdravoj vegetaciji.



Slika 22 Performanse hibridnog pristupa i primijenjeni model na plohe A (a i c) i B (b i d) za rujan

5. RASPRAVA

Rezultati ovog istraživanja pokazuju da multispektralne snimke prikupljene bespilotnim letjelicama mogu biti izuzetno korisne za procjenu utjecaja infestacije hrastove mrežaste stjenice (HMS) na koncentraciju klorofila u hrastovim krošnjama. Ovi nalazi podržavaju postojeće dokaze o upotrebi daljinskih istraživanja za detekciju stresnih uvjeta u šumama, što je ranije opisano u radu Jovanović i dr. (2021), gdje se naglašava potencijal satelitskih i UAV podataka za praćenje štetnika u šumskim ekosustavima. Naše istraživanje dodatno potvrđuje da UAV tehnologija nudi višu prostornu i vremensku rezoluciju u usporedbi s tradicionalnim metodama te je time pogodna za brzu detekciju infestacija i stresnih uvjeta na razini pojedinačnih stabala, kako su također opisali Benko i Balenović (2011).

ao što je prikazano u analizi regresijskih algoritama, *Gaussian process regression* (GPR) model se pokazao kao najučinkovitiji za modeliranje složenih nelinearnih odnosa između ulaznih spektralnih podataka i koncentracije klorofila. Ovi rezultati su konzistentni s nalazima Verrelst i dr. (2012), koji su također pokazali da nelinearni modeli daju bolje rezultate za predviđanje biofizičkih parametara iz spektralnih podataka. Specifično, GPR se istaknuo kao metoda koja može procijeniti koncentraciju klorofila s visokom točnošću, što sugerira da ovaj algoritam nudi rješenje za izazove koji su povezani s heterogenim i kompleksnim vegetacijskim strukturama, kao što su spomenuli Caicedo Rivera i dr. (2014). Ovi rezultati imaju značajne praktične implikacije za šumarstvo i održivo upravljanje ekosustavima. Upotreba UAV, zajedno s naprednim modelima strojnog učenja, omogućava visoko precizno mapiranje ključnih biokemijskih parametara u šumskim ekosustavima. Precizne procjene CCC, posebno u uvjetima biotičkog stresa, mogu pomoći u ranom otkrivanju promjena i planiranju intervencija za očuvanje zdravlja šuma. GPR modeli, zbog svoje točnosti i robusnosti, mogu se koristiti za generiranje mapa rizika i planiranje aktivnosti kontrole štetnika. Iako specifična referenca za ovu primjenu nije dostupna, GPR modeli su poznati po svojoj sposobnosti kvantificiranja nesigurnosti u predikcijama i prilagodbi složenim ekološkim podacima, što ih čini korisnim za ovakve svrhe.

Biokemijska i strukturalna svojstva listova, poput sadržaja klorofila, sadržaja dušika, sadržaja vode u listu i LAI, mogu se učinkovito procijeniti korištenjem GPR na spektralnim podacima punog

raspona (400–2500 nm) iz raznolikog, terenski prikupljenog viševrsnog skupa podataka, uključujući listove s vrlo visokim koncentracijama klorofila. GPR ne samo da je pružio točne procjene s niskim normaliziranim srednjim kvadratnim pogreškama, već je i identificirao važne valne duljine kroz spektar, pokazujući svoju sposobnost rukovanja složenim skupovima podataka sa značajnim strukturnim razlikama među listovima (Van Wittenberghe i dr. 2014).

Primjena Random forest algoritma, koji je isto tako pokazao relativno visoku točnost predviđanja koncentracije klorofila s vrlo niskim RMSE, naglašava potencijal ovog strojnog učenja za obradu podataka oštećenih Šuma. Ovaj rezultat sugerira da bi daljnji razvoj i implementacija tehnika strojnog učenja mogli unaprijediti preciznost i brzinu procjene oštećenja prouzročenih invazivnim vrstama, što je konzistentno s nalazima Ye i dr. (2022), koji su pokazali da primjena Random forest metode poboljšava točnost detekcije invazivnih štetnika kroz integraciju terenskih podataka i daljinskog istraživanja.

Analizom utjecaja okolišnih faktora, poput temperature izražene kroz stupanj-dana (SD) i broja jajnih legala po listu, utvrđeno je da ovi parametri imaju umjerenu do visoku korelaciju s koncentracijom klorofila u krošnjama hrastova. Ovi nalazi su u skladu s istraživanjima (Jarošik i dr. 2015), koji su istaknuli da okolišni faktori kao što su temperatura i vlaga mogu značajno utjecati na uspjeh invazivnih vrsta i njihovu sposobnost kolonizacije novih staništa. Koeficijent determinacije od 0,296 za linearni regresijski model ukazuje na ograničenu sposobnost ovog modela da objasni varijabilnost u podacima, dok je random forest postigao značajno višu točnost s $R^2 = 0.947$, što upućuje na prednosti nelinearnih modela u analizi ovakvih kompleksnih ekoloških podataka, što su također primijetili Paulin i dr. (2020) u njihovom radu o predikciji širenja HMS-a. Sposobnost ovih modela da obuhvate kompleksne nelinearne odnose ključna je za razumijevanje dinamike invazije u šumskim ekosustavima.

Rezultati istraživanja također pokazuju da su zaražene plohe (Ploha A) bile znatno složenije za modeliranje nego plohe bez infestacije (Ploha B), zbog veće varijabilnosti podataka uzrokovane infestacijom HMS-a. Ovo je u skladu s nalazima Stancă-Moise i dr. (2023), koji su istaknuli da infestacija invazivnim vrstama može povećati varijabilnost ekoloških parametara te otežati modeliranje biofizičkih karakteristika zaraženih staništa. Najbolji rezultati su postignuti u proljetnom razdoblju, kada je vegetacija bila manje pod stresom što sugerira da se promjene

uzrokovane infestacijom lakše mogu uočiti u ranijim fazama sezone. Ovo je konzistentno s tvrdnjama Simberloff i dr. (2013) o značaju rane detekcije invazivnih vrsta za uspješno upravljanje i kontrolu štete.

S obzirom na značajnu korelaciju između SPAD vrijednosti i koncentracije klorofila, potvrđeno je da je SPAD mjera klorofila pouzdan alat za procjenu zdravstvenog stanja biljaka u uvjetima stresa, što je ranije dokazano u istraživanju Shibaeva i dr. (2020). Najpreciznija procjena postignuta je za sadržaj klorofila krošnje, dok je točnost procjena općenito porasla za uzorke s manje biljnih vrsta, što ukazuje na ograničenja modela u vrlo heterogenim uvjetima (Darvishzadeh i dr. 2008). U kombinaciji s multispektralnim snimkama, SPAD vrijednosti omogućavaju precizniju kvantifikaciju utjecaja infestacije na pojedinačnoj razini stabala, što je ključno za razvijanje strategija upravljanja, kako je navedeno u istraživanju Uddling i dr. (2007). Ovo također podržava tvrdnje Zhang i dr. (2022), koji su pokazali da kombinacija SPAD mjerjenja i daljinskog istraživanja može pružiti visoku razinu točnosti u procjeni klorofila.

Hibridni pristup korišten u ovom istraživanju, koji uključuje kombinaciju metode aktivnog učenja GPR i modela prijenosa radijacije (PROSAIL), pokazao je potencijal za poboljšanje procjene biofizičkih parametara vegetacije. Implementacija aktivnog učenja omogućila je selekciju najinformativnijih uzoraka, čime je povećana točnost predviđanja i smanjena potreba za velikim količinama podataka prikupljenih na terenu. Međutim, hibridni pristup nije pokazao značajno bolje rezultate u usporedbi s jednostavnijim regresijskim metodama, što je u skladu s nalazima Berger i dr. (2021) i Alam i dr. (2024), koji su istaknuli da kompleksni hibridni modeli ne garantiraju uvijek poboljšanje predviđanja u odnosu na klasične regresijske pristupe. Ovo može biti zbog visoke složenosti modela i mogućnosti prekomjerne prilagodbe (overfitting), što se posebno manifestira u slučaju heterogenih podataka posebno za manja područja kao sto je nase područje studija (Alam i dr. 2024).

U srpnju i rujnu, model je pokazao visoke RMSE pogreške i niske R^2 vrijednosti, osobito na plohi A, što sugerira da hibridni pristup nije uspio uhvatiti složene promjene u fotosintetskoj aktivnosti. Ovi rezultati ukazuju na to da je hibridni model manje osjetljiv na heterogenost vegetacije te da bi poboljšanja u spektralnoj kalibraciji mogla povećati njegovu preciznost.

Analiza dijagrama izmjerениh i predviđenih vrijednosti klorofila pokazuje da su niže vrijednosti često precijenjene, dok su više vrijednosti klorofila podcijenjene. Ova sistemska pogreška osobito je izražena na plohi B u rujnu, gdje je $R = 0.46$, što ukazuje na lošiju prediktivnu sposobnost modela u procjeni viših koncentracija klorofila. Na plohi A u rujnu model je pokazao izuzetno nisku korelaciju ($R = 0.02$), s izrazito raspršenim vrijednostima, što ukazuje na potpunu nesigurnost modelskih predikcija.

Rezultati ukazuju na ograničenja hibridnog pristupa u kvantificiranju koncentracije klorofila i u složenim uvjetima kasne vegetacijske sezone. Performanse hibridnog pristupa u rujnu su slabije od performansi najboljih MLRA modela, poput GPR-a i KRR-a, koji su u stanju bolje generalizirati i prilagoditi se nepredvidivim promjenama u podacima. Kompleksnost hibridnog modela, zajedno s potencijalom za prekomjernu prilagodbu, dodatno ograničava njegovu učinkovitost, osobito u uvjetima povećane prostorne i vremenske varijabilnosti.

Buduća istraživanja trebala bi se fokusirati na daljnju integraciju različitih senzorskih podataka, uključujući hiperspektralna i termalna snimanja, koja bi mogla omogućiti detaljniju procjenu stresa u šumskim ekosustavima. Daljnji razvoj hibridnih pristupa također je potreban kako bi se smanjila neodređenost LUT-a i poboljšala prilagodljivost modela na složene uvjete na terenu (Santos i dr. 2021). Osim toga, važnost fenoloških promjena u interpretaciji rezultata naglašava potrebu za dinamičnim modeliranjem koje može obuhvatiti sezonske promjene u vegetaciji. Prikupljanje podataka u različitim fazama vegetacije i njihova integracija u modele može dodatno poboljšati predviđanja i pomoći u boljem razumijevanju interakcija između biotičkih i abiotičkih stresova.

Pokazano je u vise studija da aktivno učenje može značajno doprinijeti preciznijem i efikasnijem dohvaćanju biokemijskih varijabli u operativnom praćenju vegetacije koristeći na primjer hiperspektralne satelitske podatke (Berger i dr. 2021). Slično tome, samo na hiperspektralnim snimkama prikupljenim UAV, provedeno je rano otkrivanje infestacije štetnika *Dendroctonus valens* na individualnoj razini stabala. Uspoređene su spektralne karakteristike *Pinus tabuliformis* u tri stanja (zdravo, infestirano i mrtvo), te uspostavljeni klasifikacijski modeli koristeći tri skupine značajki (refleksija, derivati i spektralni indeksi vegetacije) i dva algoritma (random forest i neural network). Spektralne značajke mrtvih stabala bile su jasno različite od ostalih dviju klasa, a svih

modeli ih su točno identificirali. (Gao i dr. 2023)

Jedan od glavnih ograničavajućih faktora ovog istraživanja bio je nedostatak terenskih podataka za validaciju modela. LAI (Leaf Area Index) je procijenjen indirektno, a ne izravno izmјeren na terenu, što je moglo utjecati na ulazne parametre PROSAIL modela i smanjiti njegovu preciznost. Nadalje, multispektralna kamera imaju ograničen broj spektralnih kanala u odnosu na hiperspektralne senzore, što može smanjiti sposobnost modela da precizno prepozna razlike između zdravih i zaraženih stabala. Osim toga, mikroklimatske varijacije unutar ploha, poput vlažnosti tla i dostupnosti vode, nisu uključene u modeliranje, iako mogu značajno utjecati na koncentraciju klorofila

Rezultati istraživanja o utjecaju primjene algoritama strojnog učenja i napretka u tehnologiji bespilotnih letjelica (UAV) na daljinsko istraživanje, posebno u procjeni biokemijskih svojstava vegetacije kroz fuziju podataka UAV-a i satelita, pokazuju da sinergija ovih podataka značajno poboljšava performanse algoritama u mapiranju klorofila u krošnjama usjeva. (Alam i dr. 2024). Buduće studije bi trebale iskoristiti ovu fuziju podataka gdje bi se analizirale veće šumske površine sa hibridnim modelom te bi se trebale fokusirati na korištenje hiperspektralnih podataka kako bi se poboljšala sposobnost modela za detekciju naprednih faza biotičkog stresa. Također, daljnja optimizacija modela, uključujući dinamične fenološke parametre i poboljšanje atmosferske korekcije UAV snimaka, može značajno unaprijediti predikcije. Kombinacija višestrukih senzorskih izvora podataka i strojnog učenja mogla bi pružiti preciznije i pouzdanije metode za rano otkrivanje ekoloških promjena u šumskim ekosustavima.

Konačno, ukupno gledajući, ovo istraživanje doprinosi razumijevanju uloge naprednih tehnika strojnog učenja i daljinskog istraživanja u kvantifikaciji utjecaja invazivnih vrsta na šumske ekosustave. Nalazi ovog rada podržavaju tvrdnje Lockwood i dr. (2013) o važnosti razvoja multidisciplinarnih pristupa za upravljanje invazivnim vrstama, koji uključuju i tehnologije daljinskog istraživanja. Daljnja istraživanja trebala bi se fokusirati na optimizaciju modela, uključivanje više okolišnih parametara te testiranje primjene ovih tehnika na različitim invazivnim vrstama i staništima, što je ključno za postizanje preciznijeg i sveobuhvatnijeg razumijevanja dinamike invazija i njihovog utjecaja na ekosustave.

6. ZAKLJUČAK

Hrastova mrežasta stjenica (*Corythucha arcuata*) predstavlja ozbiljnu prijetnju šumskim ekosustavima, uzrokujući smanjenje koncentracije klorofila, degradaciju fotosintetske aktivnosti i progresivna oštećenja krošnji hrasta lužnjaka (*Quercus robur*). Ovo istraživanje imalo je za cilj razviti i validirati metode za kvantifikaciju i prostornu analizu oštećenja krošnji korištenjem multispektralnih snimaka prikupljenih bespilotnim letjelicama, u kombinaciji s modelima strojnog učenja i fizičkim modelima prijenosa radijacije. Istraživanje je provedeno u šumama hrasta lužnjaka u blizini Jastrebarskog i Buzeta, uz prikupljanje podataka tijekom tri vegetacijske sezone, kako bi se analizirala dinamika promjena kroz vrijeme. Kombinacijom daljinskog istraživanja koristeći UAV, terenskih mjerena i naprednih modela strojnog učenja, istraženi su ključni faktori koji utječu na fotosintetsku učinkovitost šuma i potencijal UAV snimaka za modeliranje sadržaja klorofila.

Rezultati su pokazali da multispektralne snimke bespilotnih letjelica mogu pouzdano detektirati smanjenje koncentracije klorofila uzrokovano napadom štetnika, pri čemu je prostorna distribucija oštećenja bila u visokoj korelaciji s terenskim mjerenjima. Analiza regresijskih modela i modela strojnog učenja potvrdila je da je Gaussian Process Regression (GPR) bio najprecizniji model za predikciju sadržaja klorofila, dok je hibridni pristup (PROSAIL + GPR), pokazao slabije performanse u odnosu na samostalne regresijske metode. Iako su hibridni modeli dali dodatne uvide u prostornu dinamiku promjena u krošnjama, nisu značajno poboljšali ukupnu točnost predikcija, posebno u kasnijim fazama vegetacije. S obzirom na navedeno, rezultati su potvrdili prvu hipotezu – UAV snimke uspješno detektiraju smanjenje klorofila uslijed infestacije – dok druga hipoteza nije u potpunosti potvrđena, jer hibridni model nije statistički značajno precizniji od klasičnih modela strojnog učenja.

Prednosti korištenja multispektralnih snimaka očituju se u pravovremenom otkrivanju biotičkog stresa i preciznom prostornom praćenju promjena u šumskim ekosustavima. Međutim, analiza podataka kroz vegetacijsku sezonu pokazala je da učinkovitost modela varira ovisno o stadiju infestacije i kompleksnosti vegetacije. U ranim fazama sezone (svibanj), modeli su ostvarili visoku preciznost, dok je u kasnijim mjesecima (rujan) sposobnost predikcije značajno opala, osobito na

heterogenim plohamama. Ovo sugerira da su metode daljinskog istraživanja najpogodnije za rano otkrivanje infestacija, dok kasnije faze zahtijevaju dodatnu prilagodbu modelskih parametara.

Fizički modeli, poput PROSAIL-a, pružili su temeljne uvide u strukturu vegetacije, ali su pokazali ograničenja u prilagodbi stvarnim uvjetima, što je nadoknađeno primjenom strojnog učenja. Unatoč njihovom potencijalu, hibridni modeli nisu značajno poboljšali predikcije, što može biti posljedica složenosti ekoloških podataka, spektralnih ograničenja multispektralnih kamera i varijabilnosti okolišnih faktora koji nisu u potpunosti obuhvaćeni modeliranjem. Dodatno, hibridni modeli obično daju bolje rezultate na većim površinama, dok je ovo istraživanje provedeno na manjim plohamama, gdje se povećana varijabilnost podataka može negativno odraziti na njihovu točnost.

Sveukupno, istraživanje je pokazalo da multispektralne snimke UAV-a, u kombinaciji s regresijskim modelima strojnog učenja, predstavljaju pouzdan alat za monitoring šumskih ekosustava i rano otkrivanje štetnika poput hrastove mrežaste stjenice. Ove metode omogućuju bržu i precizniju identifikaciju stresnih stanja u vegetaciji, što može doprinijeti boljem upravljanju i očuvanju šumskih ekosustava. Iako su hibridni modeli pružili dodatne informacije o povezanosti okolišnih čimbenika i zdravlja krošnji, njihova primjena nije rezultirala značajnim poboljšanjem točnosti predviđanja, što ukazuje na potrebu za dalnjim optimizacijama modelskih parametara i integracijom višesenzorskih podataka za poboljšanje detekcije kasnijih stadija infestacije.

7. POPIS LITERATURE

- Ai B, Wen Z, Jiang Y, Gao S, Lv G, 2019. Sea surface temperature inversion model for infrared remote sensing images based on deep neural network. *Infrared Phys. Technol.* 99: 231–239. <https://doi.org/10.1016/J.INFRARED.2019.04.022>.
- Alam TM, Milas AS, Gašparovic M, 2024. Retrieval of Crop Canopy Chlorophyll: Machine Learning vs. Radiative Transfer Model. *Remote Sens.* 16: 2058. <https://doi.org/10.3390/RS16122058>.
- Arenas-Garcia J, Petersen KB, Camps-Valls G, Hansen LK, 2013. Kernel multivariate analysis framework for supervised subspace learning: A tutorial on linear and kernel multivariate methods. *IEEE Signal Process. Mag.* 30: 16–29. <https://doi.org/10.1109/MSP.2013.2250591>.
- Bălăcenoiu F, Toma D, Nețoiu C, 2023. From Field Data to Practical Knowledge: Investigating the Bioecology of the Oak Lace Bug—An Invasive Insect Species in Europe. *Insects* 14: 882. <https://doi.org/10.3390/insects14110882>.
- Baret F, Buis S, 2008. Estimating Canopy Characteristics from Remote Sensing Observations: Review of Methods and Associated Problems. *Adv. L. Remote Sens. Syst. Model. Invers. Appl.*: 173–201. https://doi.org/10.1007/978-1-4020-6450-0_7.
- Barman D, Sehgal VK, Sahoo RN, Nagarajan S, 2010. Relationship of bidirectional reflectance of wheat with biophysical parameters and its radiative transfer modeling using Prosail. *J. Indian Soc. Remote Sens.* 38: 35–44. <https://doi.org/10.1007/S12524-010-0010-1/METRICS>.
- Benko M, Balenovic I, 2011. Prošlost, sadašnjost i budućnost primjene metoda daljinskih istraživanja pri inventuri šuma u Hrvatskoj. *Sumar. List*.
- Berger K, Rivera Caicedo JP, Martino L, Woher M, Hank T, Verrelst J, 2021. A Survey of Active Learning for Quantifying Vegetation Traits from Terrestrial Earth Observation Data. *Remote Sens.* 2021, Vol. 13, Page 287 13: 287. <https://doi.org/10.3390/RS13020287>.
- Berger K, Atzberger C, Danner M, D'Urso G, Mauser W, Vuolo F, Hank T, 2018. Evaluation of the PROSAIL Model Capabilities for Future Hyperspectral Model Environments: A Review

- Study. *Remote Sens.* 2018, Vol. 10, Page 85 10: 85. <https://doi.org/10.3390/RS10010085>.
- Berger K, Verrelst J, Féret JB, Hank T, Woher M, Mauser W, Camps-Valls G, 2020. Retrieval of aboveground crop nitrogen content with a hybrid machine learning method. *Int. J. Appl. Earth Obs. Geoinf.* 92: 102174. <https://doi.org/10.1016/j.jag.2020.102174>.
- Bernardinelli I, Zandigiacomo P, 2000. Prima segnalazione di Corythucha arcuata (Say) Heteroptera, Tingidae) in Europa. *Inf. Fitopatol.* 50: 47–49.
- Bozzini A, Francini S, Chirici G, Battisti A, Faccoli M, 2023. Spruce Bark Beetle Outbreak Prediction through Automatic Classification of Sentinel-2 Imagery. *For. 2023, Vol. 14, Page 1116* 14: 1116. <https://doi.org/10.3390/F14061116>.
- Bozzini A, Francini S, Chirici G, Battisti A, Faccoli M, . Spruce Bark Beetle Outbreak Prediction through Automatic Classification of Sentinel-2 Imagery. *Forests* 14: 1116. <https://doi.org/10.3390/f14061116>.
- Breiman L, 2001. Random forests. *Mach. Learn.* 45: 5–32. <https://doi.org/10.1023/A:1010933404324/METRICS>.
- Brown LA, Williams O, Dash J, 2022. Calibration and characterisation of four chlorophyll meters and transmittance spectroscopy for non-destructive estimation of forest leaf chlorophyll concentration. *Agric. For. Meteorol.* 323: 109059. <https://doi.org/10.1016/j.agrformet.2022.109059>.
- Caicedo JPR, Verrelst J, Munoz-Mari J, Moreno J, Camps-Valls G, 2014. Toward a semiautomatic machine learning retrieval of biophysical parameters. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 7: 1249–1259. <https://doi.org/10.1109/JSTARS.2014.2298752>.
- Caicedo Rivera JP, Verrelst J, Munoz-Mari J, Moreno J, Camps-Valls G, 2014. Toward a semiautomatic machine learning retrieval of biophysical parameters. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 7: 1249–1259. <https://doi.org/10.1109/JSTARS.2014.2298752>.
- Ciceu A, Bălăcenoiu F, de Groot M, Chakraborty D, Avtzis D, Barta M, Blaser S, Bracalini M, Castagneyrol B, Chernova UA, Çota E, Csóka G, Dautbasic M, Glavendekic M, Gninenko YI, Hoch G, Hradil K, Husemann M, Meshkova V, Mujezinovic O, Mutun S, Panzavolta T, Paulin M, Riba-Flinch JM, Simov N, Sotirovski K, Vasilciuc S, Zúbrik M, Schueler S, 2024. The ongoing range expansion of the invasive oak lace bug across Europe: current occurrence

and potential distribution under climate change. *Sci. Total Environ.* 949: 174950. <https://doi.org/10.1016/J.SCITOTENV.2024.174950>.

Connell W, Beacher J, 1947. Life history and control of the oak lace bug. *Bull. Univ. Delaware Agric. Exp. Stn.* 265: 1–28.

Csepelényi M, Hirka A, Szénási Á, Mikó Á, Szőcs L, Csóka G, 2017. Az inváziós tölgy csipkéspoloska [Corythucha arcuata (Say, 1832)] gyors terjeszkedése és tömeges fellépése Magyarországon. *Erdészettudományi Közlemények* 7: 127–134. <https://doi.org/10.17164/ek.2017.009>.

Csóka G, Hirka A, Mutun S, Glavendekić M, Mikó Á, Szőcs L, Paulin M, Eötvös CB, Gáspár C, Csepelényi M, Szénási Á, Franjević M, Gninenco Y, Dautbašić M, Muzejinović O, Zúbrik M, Netoiu C, Buzatu A, Bălăcenoiu F, Jurc M, Jurc D, Bernardinelli I, Streito JC, Avtzis D, Hrašovec B, 2020. Spread and potential host range of the invasive oak lace bug [Corythucha arcuata (Say, 1832) – Heteroptera: Tingidae] in Eurasia. *Agric. For. Entomol.* 22: 61–74. <https://doi.org/10.1111/AFE.12362>.

Dalponte M, Solano-Correa YT, Frizzera L, Gianelle D, 2022. Mapping a European Spruce Bark Beetle Outbreak Using Sentinel-2 Remote Sensing Data. *Remote Sens.* 2022, Vol. 14, Page 3135 14: 3135. <https://doi.org/10.3390/RS14133135>.

Darvishzadeh R, Skidmore A, Schlerf M, Atzberger C, 2008. Inversion of a radiative transfer model for estimating vegetation LAI and chlorophyll in a heterogeneous grassland. *Remote Sens. Environ.* 112: 2592–2604. <https://doi.org/10.1016/J.RSE.2007.12.003>.

Dash JP, Pearse GD, Watt MS, 2018. UAV Multispectral Imagery Can Complement Satellite Data for Monitoring Forest Health. *Remote Sens.* 2018, Vol. 10, Page 1216 10: 1216. <https://doi.org/10.3390/RS10081216>.

Daughtry CST, Walthall CL, Kim MS, De Colstoun EB, McMurtrey JE, 2000. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sens. Environ.* 74: 229–239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9).

Drake CJ, Ruhoff FA, 1965. Lacebugs of the World: A Catalog (Hemiptera: Tingidae). *Bull. United States Natl. Museum*: 1–634. <https://doi.org/10.5479/si.03629236.243.1>.

Duarte A, Borralho N, Cabral P, Caetano M, 2022. Recent Advances in Forest Insect Pests and

Diseases Monitoring Using UAV-Based Data: A Systematic Review. *Forests* 13: 911. <https://doi.org/10.3390/f13060911>.

Duarte A, Acevedo-Muñoz L, Gonçalves CI, Mota L, Sarmento A, Silva M, Fabres S, Borralho N, Valente C, 2020. Detection of Longhorned Borer Attack and Assessment in Eucalyptus Plantations Using UAV Imagery. *Remote Sens.* 2020, Vol. 12, Page 3153 12: 3153. <https://doi.org/10.3390/RS12193153>.

Everitt JH, Escobar DE, Villarreal R, Noriega JR, Davis MR, 1991. Airborne video systems for agricultural assessment. *Remote Sens. Environ.* 35: 231–242. [https://doi.org/10.1016/0034-4257\(91\)90015-X](https://doi.org/10.1016/0034-4257(91)90015-X).

Gao B, Yu L, Ren L, Zhan Z, Luo Y, 2023. Early Detection of Dendroctonus valens Infestation at Tree Level with a Hyperspectral UAV Image. *Remote Sens.* 15: 407. <https://doi.org/10.3390/rs15020407>.

García-Soria JL, Morata M, Berger K, Pascual-Vento AB, Rivera-Caicedo JP, Verrelst J, 2024. Evaluating epistemic uncertainty estimation strategies in vegetation trait retrieval using hybrid models and imaging spectroscopy data. *Remote Sens. Environ.* 310: 114228. <https://doi.org/10.1016/j.rse.2024.114228>.

Gitelson AA, Kaufman YJ, Merzlyak MN, 1996. Use of a green channel in remote sensing of global vegetation from EOS- MODIS. *Remote Sens. Environ.* 58: 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7).

Gitelson AA, Viña A, Ciganda V, Rundquist DC, Arkebauer TJ, 2005. Remote estimation of canopy chlorophyll content in crops. *Geophys. Res. Lett.* 32: 1–4. <https://doi.org/10.1029/2005GL022688>.

Guimarães N, Pádua L, Marques P, Silva N, Peres E, Sousa JJ, 2020. Forestry Remote Sensing from Unmanned Aerial Vehicles: A Review Focusing on the Data, Processing and Potentialities. *Remote Sens.* 2020, Vol. 12, Page 1046 12: 1046. <https://doi.org/10.3390/RS12061046>.

Hall RJ, Castilla G, White JC, Cooke BJ, Skakun RS, 2016. Remote sensing of forest pest damage: A review and lessons learned from a Canadian perspective *. *Can. Entomol.* 148: S296–S356. <https://doi.org/10.4039/tce.2016.11>.

Haykin S, 1999. Neural Networks - A Comprehensive Foundation. 2. izd. Prentice Hall, Englewood Cliffs, NJ, USA, 842p.

He Y, Gong Z, Zheng Y, Zhang Y, 2021. Inland Reservoir Water Quality Inversion and Eutrophication Evaluation Using BP Neural Network and Remote Sensing Imagery: A Case Study of Dashahe Reservoir. *Water* 2021, Vol. 13, Page 2844 13: 2844. <https://doi.org/10.3390/W13202844>.

Horn KF, Wright CG, Farrier MH, 1979. The lace bugs (Hemiptera: Tingidae) of North Carolina and their hosts [Economic plants]. *Tech. Bull. - North Carolina Agric. Exp. Stn. (USA)*. no. 257.. <https://doi.org/10.3/JQUERY-UIJS>.

Impollonia G, Croci M, Blandinières H, Marcone A, Amaducci S, 2022. Comparison of PROSAIL Model Inversion Methods for Estimating Leaf Chlorophyll Content and LAI Using UAV Imagery for Hemp Phenotyping. *Remote Sens.* 2022, Vol. 14, Page 5801 14: 5801. <https://doi.org/10.3390/RS14225801>.

Jacquemoud S, Baret F, 1990. PROSPECT: A model of leaf optical properties spectra. *Remote Sens. Environ.* 34: 75–91. [https://doi.org/10.1016/0034-4257\(90\)90100-Z](https://doi.org/10.1016/0034-4257(90)90100-Z).

Jacquemoud S, Verhoef W, Baret F, Bacour C, Zarco-Tejada PJ, Asner GP, François C, Ustin SL, 2009. PROSPECT + SAIL models: A review of use for vegetation characterization. *Remote Sens. Environ.* 113: S56–S66. <https://doi.org/10.1016/j.rse.2008.01.026>.

Jarošík V, Kenis M, Honěk A, Skuhrovec J, Pyšek P, 2015. Invasive Insects Differ from Non-Invasive in Their Thermal Requirements. *PLoS One* 10: e0131072. <https://doi.org/10.1371/JOURNAL.PONE.0131072>.

Jovanović D, Gavrilović M, Borisov M, Govendarica M, 2021. Uporaba Sentinel 1 i Sentinel 2 snimaka u identifikaciji nestalih šumskih površina – studija slučaja Fruška gora (Srbija). *Šumarski List* 145: 127–134. <https://doi.org/10.31298/SL.145.3-4.2>.

Loh WY, 2011. Classification and regression trees. *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.* 1: 14–23. <https://doi.org/10.1002/WIDM.8>.

Marston ZPD, Cira TM, Hodgson EW, Knight JF, MacRae I V., Koch RL, Rondon S, 2020. Detection of Stress Induced by Soybean Aphid (Hemiptera: Aphididae) Using Multispectral Imagery from Unmanned Aerial Vehicles. *J. Econ. Entomol.* 113: 779–786.

<https://doi.org/10.1093/JEE/TOZ306>.

Minařík R, Langhammer J, 2016. USE OF A MULTISPECTRAL UAV PHOTOGAMMOMETRY FOR DETECTION AND TRACKING OF FOREST DISTURBANCE DYNAMICS. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* XLI-B8: 711–718. <https://doi.org/10.5194/ISPRS-ARCHIVES-XLI-B8-711-2016>.

MOON H-GT-YD-IJ-G, 2018. Study on the Estimation of leaf area index (LAI) of using UAV vegetation index and Tree Height data. *J. Korean Assoc. Geogr. Inf. Stud.* 21: 158–174. <https://doi.org/10.11108/KAGIS.2018.21.4.158>.

Paulin M, Hirka A, Eötvös CB, Gáspár C, Fürjes-Mikó Á, Csóka G, 2020. Known and predicted impacts of the invasive oak lace bug (*Corythucha arcuata*) in European oak ecosystems- A review. *Folia Oecologica* 47: 131–139. <https://doi.org/10.2478/foecol-2020-0015>.

Rasmussen CE, Williams CKI, 2006. Gaussian Processes for Machine Learning. the MIT Press, 266p.

Richardson AD, Berlyn GP, Gregoire TG, 2001. Spectral reflectance of *Picea rubens* (pinaceae) and *Abies balsamea* (Pinaceae) needles along an elevational gradient, Mt. Moosilauke, New Hampshire, USA. *Am. J. Bot.* 88: 667–676. <https://doi.org/10.2307/2657067>.

Sahoo RN, Gakhar S, Rejith RG, Verrelst J, Ranjan R, Kondraju T, Meena MC, Mukherjee J, Daas A, Kumar S, Kumar M, Dhandapani R, Chinnusamy V, 2023. Optimizing the Retrieval of Wheat Crop Traits from UAV-Borne Hyperspectral Image with Radiative Transfer Modelling Using Gaussian Process Regression. *Remote Sens.* 15: 5496. <https://doi.org/10.3390/rs15235496>.

Shibaeva TG, Mamaev A V., Sherudilo EG, 2020. Evaluation of a SPAD-502 Plus Chlorophyll Meter to Estimate Chlorophyll Content in Leaves with Intervenial Chlorosis. *Russ. J. Plant Physiol.* 67: 690–696. <https://doi.org/10.1134/S1021443720040160>.

Simic A, Chen JM, Noland TL, 2011. Retrieval of forest chlorophyll content using canopy structure parameters derived from multi-angle data: the measurement concept of combining nadir hyperspectral and off-nadir multispectral data. *Int. J. Remote Sens.* 32: 5621–5644. <https://doi.org/10.1080/01431161.2010.507257>.

Sinha SK, Padalia H, Dasgupta A, Verrelst J, Rivera JP, 2020. Estimation of leaf area index using

- PROSAIL based LUT inversion, MLRA-GPR and empirical models: Case study of tropical deciduous forest plantation, North India. *Int. J. Appl. Earth Obs. Geoinf.* 86: 102027. <https://doi.org/10.1016/J.JAG.2019.102027>.
- Stancă-Moise C, Moise G, Rotaru M, Vonica G, Sanislau D, 2023. Study on the Ecology, Biology and Ethology of the Invasive Species *Corythucha arcuata* Say, 1832 (Heteroptera: Tingidae), a Danger to *Quercus* spp. in the Climatic Conditions of the City of Sibiu, Romania. *For. 2023, Vol. 14, Page 1278* 14: 1278. <https://doi.org/10.3390/F14061278>.
- Sun J, Shi S, Wang L, Li H, Wang S, Gong W, Tagesson T, 2021. Optimizing LUT-based inversion of leaf chlorophyll from hyperspectral lidar data: Role of cost functions and regulation strategies. *Int. J. Appl. Earth Obs. Geoinf.* 105: 102602. <https://doi.org/10.1016/j.jag.2021.102602>.
- Suykens JAK, Vandewalle J, 1999. Least squares support vector machine classifiers. *Neural Process. Lett.* 9: 293–300. [https://doi.org/10.1023/A:1018628609742/METRICS](https://doi.org/10.1023/A:1018628609742).
- Tagliabue G, Boschetti M, Bramati G, Candiani G, Colombo R, Nutini F, Pompilio L, Rivera-Caicedo JP, Rossi M, Rossini M, Verrelst J, Panigada C, 2022. Hybrid retrieval of crop traits from multi-temporal PRISMA hyperspectral imagery. *ISPRS J. Photogramm. Remote Sens.* 187: 362–377. <https://doi.org/10.1016/j.isprsjprs.2022.03.014>.
- Tueller PT, 1987. Remote sensing science applications in arid environments. *Remote Sens. Environ.* 23: 143–154. [https://doi.org/10.1016/0034-4257\(87\)90034-4](https://doi.org/10.1016/0034-4257(87)90034-4).
- Tuia D, Volpi M, Copa L, Kanevski M, Muñoz-Marí J, 2011. A survey of active learning algorithms for supervised remote sensing image classification. *IEEE J. Sel. Top. Signal Process.* 5: 606–617. <https://doi.org/10.1109/JSTSP.2011.2139193>.
- Uddling J, Gelang-Alfredsson J, Piikki K, Pleijel H, 2007. Evaluating the relationship between leaf chlorophyll concentration and SPAD-502 chlorophyll meter readings. *Photosynth. Res.* 91: 37–46. <https://doi.org/10.1007/S11120-006-9077-5>.
- Verhoef W, 1984. Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model. *Remote Sens. Environ.* 16: 125–141. [https://doi.org/10.1016/0034-4257\(84\)90057-9](https://doi.org/10.1016/0034-4257(84)90057-9).
- Verhoef W, Jia L, Su Z, 2007. Optical-thermal canopy radiance directionality modelling by

- unified 4SAIL model. .
- Verrelst J, Romijn E, Kooistra L, 2012. Mapping Vegetation Density in a Heterogeneous River Floodplain Ecosystem Using Pointable CHRIS/PROBA Data. *Remote Sens. 2012, Vol. 4, Pages 2866-2889* 4: 2866–2889. <https://doi.org/10.3390/RS4092866>.
- Verrelst J, Dethier S, Rivera JP, Munoz-Mari J, Camps-Valls G, Moreno J, 2016. Active Learning Methods for Efficient Hybrid Biophysical Variable Retrieval. *IEEE Geosci. Remote Sens. Lett.* 13: 1012–1016. <https://doi.org/10.1109/LGRS.2016.2560799>.
- Verrelst J, Rivera-Caicedo JP, Reyes-Muñoz P, Morata M, Amin E, Tagliabue G, Panigada C, Hank T, Berger K, 2021. Mapping landscape canopy nitrogen content from space using PRISMA data. *ISPRS J. Photogramm. Remote Sens.* 178: 382–395. <https://doi.org/10.1016/J.ISPRSJPRS.2021.06.017>.
- Vicent J, Verrelst J, Sabater N, Alonso L, Pablo Rivera-Caicedo J, Martino L, Muñoz-Marí J, Moreno J, 2020. Comparative analysis of atmospheric radiative transfer models using the Atmospheric Look-up table Generator (ALG) toolbox (version 2.0). *Geosci. Model Dev.* 13: 1945–1957. <https://doi.org/10.5194/GMD-13-1945-2020>.
- Watson DJ, 1947. Comparative physiological studies on the growth of field crops: I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years. *Ann. Bot.* 11: 41–76. <https://doi.org/10.1093/OXFORDJOURNALS.AOB.A083148/2/11-1-41.PDF.GIF>.
- Watson GS, 1967. Linear Least Squares Regression. <Https://doi.org/10.1214/aoms/1177698603> 38: 1679–1699. <https://doi.org/10.1214/AOMS/1177698603>.
- Weiss M, Baret F, Myneni RB, Pragnère A, Knyazikhin Y, 2000. Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data. *Agronomie* 20: 3–22. <https://doi.org/10.1051/AGRO:2000105>.
- Van Wittenberghe S, Verrelst J, Rivera JP, Alonso L, Moreno J, Samson R, 2014. Gaussian processes retrieval of leaf parameters from a multi-species reflectance, absorbance and fluorescence dataset. *J. Photochem. Photobiol. B Biol.* 134: 37–48. <https://doi.org/10.1016/j.jphotobiol.2014.03.010>.
- Xiong D, Chen J, Yu T, Gao W, Ling X, Li Y, Peng S, Huang J, 2015. SPAD-based leaf nitrogen

estimation is impacted by environmental factors and crop leaf characteristics. *Sci. Reports* 2015 5: 1–12. <https://doi.org/10.1038/srep13389>.

Ye W, Lao J, Liu Y, Chang C-C, Zhang Z, Li H, Zhou H, . Pine pest detection using remote sensing satellite images combined with a multi-scale attention-UNet model. *Ecol. Inform.* 72: 101906. <https://doi.org/10.1016/j.ecoinf.2022.101906>.

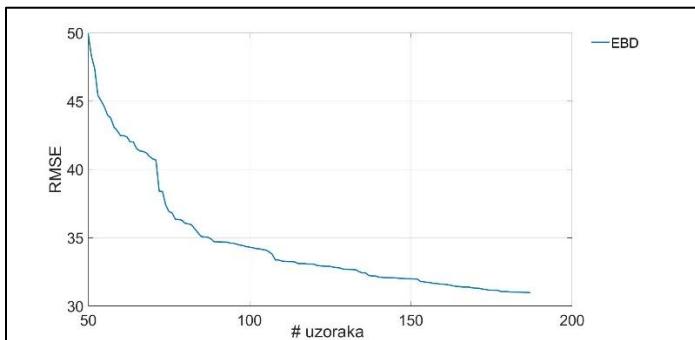
Ye X, Sakai K, Manago M, Asada SI, Sasao A, 2007. Prediction of citrus yield from airborne hyperspectral imagery. *Precis. Agric.* 8: 111–125. <https://doi.org/10.1007/S11119-007-9032-2>.

Zarco-Tejada PJ, Hornero A, Hernández-Clemente R, Beck PSA, 2018. Understanding the temporal dimension of the red-edge spectral region for forest decline detection using high-resolution hyperspectral and Sentinel-2a imagery. *ISPRS J. Photogramm. Remote Sens.* 137: 134–148. <https://doi.org/10.1016/J.ISPRSJPRS.2018.01.017>.

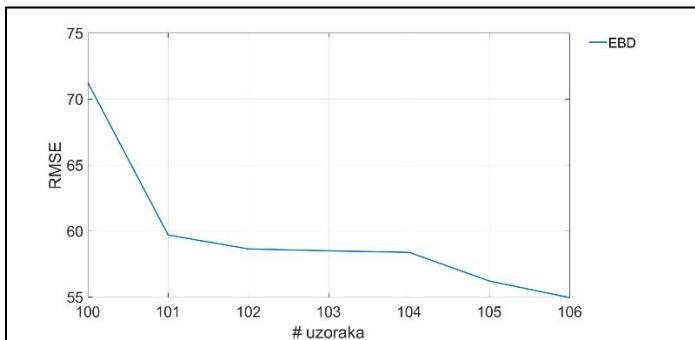
Zarco-Tejada PJ, Miller JR, Mohammed GH, Noland TL, Sampson PH, 2002. Vegetation Stress Detection through Chlorophyll a + b Estimation and Fluorescence Effects on Hyperspectral Imagery. *J. Environ. Qual.* 31: 1433–1441. <https://doi.org/10.2134/JEQ2002.1433>.

8.PRILOZI

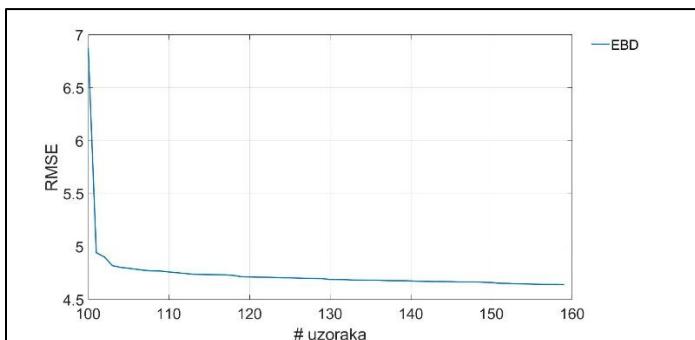
Prilog 1 a) Rezultati aktivnog učenja po broju uzoraka ploha A



Svibanj

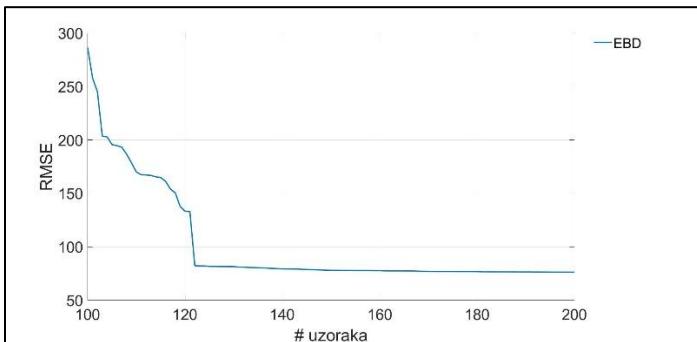


Srpanj

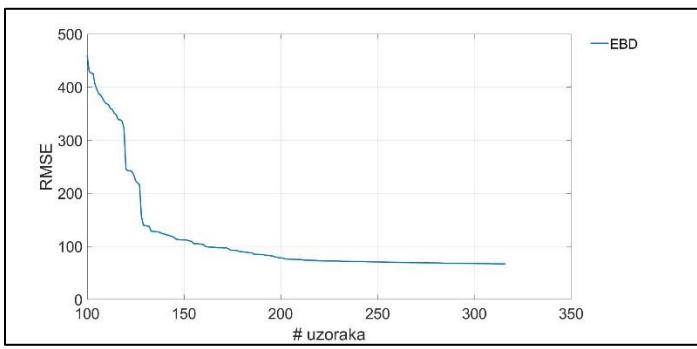


Rujan

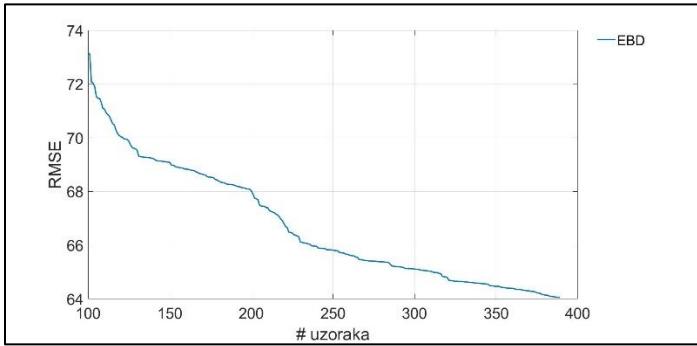
Prilog 1 b) Rezultati aktivnog učenja po broju uzoraka ploha B



Svibanj



Srpanj



Rujan

Prilog 2 MLRA odvojen za mjesec i plohe

