



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

Zagreb, 2025. godine

SADRŽAJ

PODACI O MENTORIMA.....	III
SAŽETAK	VI
ABSTRACT	VII
POPIS SLIKA	VIII
POPIS TABLICA.....	XI
AKRONIMI.....	XIII
1. UVOD.....	1
1.1. Štetni utjecaj invazivnih stranih vrsta kukaca na šumske ekosustave	2
1.2. Hrastova mrežasta stjenica.....	4
1.3. Praćenje klorofila metodama terenskih i daljinskih istraživanja kao pokazatelja stresa	6
1.4. Procjena koncentracije klorofila krošnji pomoći strojnog učenja i spektralnih podataka prikupljenih metodama daljinskih istraživanja	12
1.4.1. Statističke (empirijske) metode regresije temeljene na strojnom učenju.....	12
1.4.2. Model prijenosa zračenja	14
1.5. Hibridni pristup modeliranja.....	16
2. CILJEVI I HIPOTEZE ISTRAŽIVANJA	18
3. MATERIJALI I METODE	19
3.1. Područje istraživanja.....	19
3.2. Prikupljanje terenskih podataka.....	21
3.2.1. Vremenski period provedbe istraživanja.....	21
3.2.2. Prikupljanje podataka bespilotnom letjelicom.....	25
3.2.3. Izmjera koncentracije klorofila u listovima	33
3.2.4. Izmjera broja jajnih legala HMS	36
3.2.5. Prikupljanje podataka o temperaturi	38
3.3. Metode obrade podataka i modeliranja.....	39
3.3.1. Procjena indeksa lisne površine korištenjem vegetacijskog indeksa i modela visine krošnje.....	39
3.3.1. Modeliranje povezanosti broja jajnih legala i akumuliranog stupnja dana.....	40
3.3.2. Uporaba samostalnih regresijskih modela (MLRA) i hibridnog pristupa PROSAIL +	

MLRA u ARTMO okruženju.....	41
4. REZULTATI	49
4.1 Terenska mjerena.....	49
4.1.1. Procjena indeksa lisne površine (LAI)	49
4.1.2. Rezultati izmjere koncentracije klorofila u listovima i krošnjama hrasta lužnjaka	51
4.1.3. Rezultati utjecaja temperature i broj jajnih legala na koncentraciju klorofila lista	53
4.2. Rezultati analize samostalnih regresijskih algoritama strojnog učenja	56
4.2.1. Predviđanja sadržaja klorofila krošnje za svibanj	57
4.2.2. Predviđanje sadržaja klorofila krošnje za srpanj	60
4.2.3. Predviđanje sadržaja klorofila krošnje za rujan	63
4.3. Hibridni modeli	66
4.3.1. Rezultati hibridnog pristupa za svibanj	67
4.3.2. Rezultati hibridnog pristupa za srpanj	69
4.3.3. Rezultati hibridnog pristupa za rujan	71
5. RASPRAVA	73
5.1. Procjena indeksa lisne površine (LAI)	74
5.2. Koncentracija klorofila u listovima i krošnjama hrasta lužnjaka	75
5.3. Utjecaj temperature i broja jajnih legala na koncentraciju klorofila u listu hrasta lužnjaka ..	76
5.4. Modeliranje vrijednosti klorofila krošnje (CCC)	78
5.4.1. Analiza MLRA pristupa	79
5.4.2. Analiza hibridnih modela (PROSAIL+GPR)	81
5.6. Ograničenja istraživanja i mogući izvori pogrešaka	84
5.7. Smjernice za buduća istraživanja i primjenu rezultata	85
6. ZAKLJUČAK	87
7. POPIS LITERATURE	89
8. PRILOZI	107
9. ŽIVOTOPIS	123

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 doktorskim radom naslova „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 i drvna 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 zarazu 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 je znanstvenica i profesorica iz područja geoznanosti, s posebnim fokusom na daljinsku detekciju, prostornu analitiku i primjenu naprednih geoinformacijskih tehnologija u istraživanjima okoliša. Kroz svoju akademsku i istraživačku karijeru, značajno je pridonijela razvoju metoda u području daljinskog istraživanja vegetacije, strojnog učenja i primjene multispektralnih i hiperspektralnih podataka u analizama promjena u okolišu. Doktorski studij iz geoznanosti završila je na Sveučilištu u Torontu, gdje je razvila inovativne metode kombiniranja više izvora daljinskih podataka za procjenu strukturalnih i biokemijskih karakteristika vegetacije. Magistrirala je u istom području na istom sveučilištu, dok je dodiplomski studij iz okolišnih studija završila pri Odjelu za geografiju. Tijekom svoje bogate akademske karijere, prof. Šimić Milas obnašala je različite nastavne i istraživačke uloge na prestižnim institucijama diljem svijeta. Trenutno je profesorica na Sveučilištu Bowling Green State u SAD-u, gdje predaje kolegije iz prostorne analitike, daljinskog istraživanja i geoinformatike. Osim rada u akademskoj zajednici, surađivala je s brojnim međunarodnim istraživačkim institutima i organizacijama, uključujući Kanadski centar za daljinsko istraživanje (Natural Resources Canada) i Institut Nacional de la Recherche Agronomique u Francuskoj. Također je bila gostujuća profesorica na Sveučilištu u Wuhanu, NR Kina i Sveučilištu Victoria, gdje je sudjelovala u projektima vezanim uz primjenu daljinskog istraživanja u ekološkom modeliranju. Kao stručnjakinja u području geoinformatike, radila je i kao konzultantica za različite vladine i privatne organizacije, pridonoseći projektima u domeni geokemije, kartiranja okoliša i upravljanja prirodnim resursima.

Glavna istraživačka područja Anite Šimić Milas uključuju: Primjenu daljinskog istraživanja u šumarstvu, preciznoj poljoprivredi i kartiranju priobalnih ekosustava; inverziju modela prijenosa zračenja za određivanje strukturnih i biokemijskih svojstava vegetacije; primjenu optičkih senzora i podataka dobivenih iz bespilotnih letjelica (UAV) za procjenu ekoloških parametara; Integraciju tehnika strojnog učenja i daljinskog istraživanja u modeliranju okolišnih procesa.

Posebno se ističe njezin doprinos razvoju metoda fuzije podataka, koja omogućava simultanu

procjenu strukturalnih i biokemijskih parametara vegetacije, smanjujući redundantnost u hiperspektralnim podacima. Ovaj koncept je rezultirao patentnom prijavom u SAD-u, čime je postavljen temelj za budući razvoj naprednih senzorskih tehnologija. Tijekom karijere sudjelovala je u brojnim međunarodnim istraživačkim projektima, uključujući financiranja od strane Američke nacionalne zaklade za znanost (NSF), NASA-e, US Geological Survey (USGS), Svjetske banke, Europske komisije i Hrvatske zaklade za znanost. Vodila je projekte vezane uz monitoring kvalitete vode, procjenu šumskih resursa, razvoj metoda za prepoznavanje invazivnih biljnih vrsta te unapređenje tehnika analize satelitskih i UAV podataka. Autorica je i koautorica preko 100 znanstvenih radova u prestižnim međunarodnim časopisima, uključujući Remote Sensing of Environment, International Journal of Remote Sensing, ISPRS Journal of Photogrammetry and Remote Sensing i Environmental Challenges. Njeni radovi često se fokusiraju na razvoj novih modela u analizi daljinskih podataka, s naglaskom na njihovoj primjeni u ekološkim znanostima. Uz publikacije, aktivno sudjeluje kao recenzentica za vodeće znanstvene časopise i članica je uredničkih odbora nekoliko međunarodnih časopisa. Kao predana edukatorica, bila je mentorica na doktorskim i magisterskim radovima iz područja geoznanosti, prostorne analitike i ekološkog modeliranja. Utemeljila je i vodi SPLIT Remote Sensing Professional School, program osmišljen za edukaciju budućih stručnjaka u području daljinskog istraživanja. Također je osmisnila i implementirala više programa edukacije u području geoinformatike, uključujući online tečajeve i interaktivne radionice u suradnji s akademskim i industrijskim partnerima. Članica je više međunarodnih profesionalnih organizacija, uključujući European Association of Remote Sensing Laboratories (EARSeL), International Society for Photogrammetry and Remote Sensing (ISPRS) i AmericaView. Aktivno sudjeluje u raznim odborima i istraživačkim mrežama koje promoviraju interdisciplinarni pristup u prostornoj analitici i daljinskom istraživanju.

SAŽETAK

Hrastova mrežasta stjenica (*Corythucha arcuata*) je štetnik šuma hrasta lužnjaka (*Quercus robur*) koji uzrokuje smanjenje fotosintetske aktivnosti, fiziološki stres te narušava stabilnost sastojina. Cilj ovog istraživanja bio je razviti i validirati metode za praćenje promjena u koncentraciji klorofila krošnje (CCC) izazvanih zarazom hrastovom mrežastom stjenicom, primjenom multispektralnih snimaka prikupljenih bespilotnom letjelicom i regresijskih modela strojnog učenja (MLRA), uključujući hibridne modele temeljene na modelu prijenosa zračenja (PROSAIL).

Istraživanje je provedeno na dvije pokusne plohe u Republici Hrvatskoj: zaraženoj plohi u šumariji Jastrebarsko (Ploha A) i kontrolnoj plohi u šumariji Buzet (Ploha B), tijekom triju vegetacijskih perioda (svibanj, srpanj i rujan) u razdoblju od 2021. do 2023. godine. Na svakoj plohi definirane su pod plohe na kojima su prikupljeni podaci. Prikupljeni su terenski podaci o koncentraciji klorofila, broju jajnih legala hrastove mrežaste stjenice i temperaturi, dok su multispektralne snimke korištene za modeliranje CCC-a. Uspoređeni su samostalni regresijski modeli strojnog učenja (MLRA) s hibridnim PROSAIL+MLRA pristupima.

Rezultati su djelomično potvrđili prvu hipotezu, odnosno da multispektralne snimke prikupljene bespilotnim letjelicama omogućuju detektiranje fizioloških promjena u krošnjama uzrokovanih zarazom. Gaussian Processes Regression (GPR) pokazao se kao optimalan model s obzirom na vrijednosti koeficijenta determinacije (R^2) i najmanje normalizirane pogreške (NRMSE), čime je nadmašio hibridni pristup modeliranju. Druga hipoteza, koja je prepostavljala da je moguće modelirati koncentraciju klorofila korištenjem kombinacije terenskih podataka, okolišnih varijabli i snimaka bespilotne letjelice uz pomoć regresijskih modela strojnog učenja, također je djelomično potvrđena. Samostalni pristup temeljen na GPR-u pokazao je zadovoljavajuću točnost, dok hibridni modeli, koji uključuju fiziološki simulirane podatke, nisu ostvarili očekivanu prediktivnu prednost. Ipak, njihova vrijednost leži u mogućnosti interpretacije fizioloških promjena na temelju poznatih biokemijskih procesa koji utječu na refleksiju vegetacije, kao i u potencijalnoj primjeni u situacijama s ograničenim terenskim uzorkovanjem ili na vegetacijski homogenijim površinama.

Ključne riječi: hrastova mrežasta stjenica, hrast lužnjak, bespilotne letjelice, daljinska istraživanja, multispektralne snimke, strojno učenje

ABSTRACT

The oak lace bug (*Corythucha arcuata*) poses a threat to pedunculate oak (*Quercus robur*) forests by reducing photosynthetic activity, inducing physiological stress, and causing destabilization of forest stands. The aim of this research was to develop and validate methods for monitoring changes in canopy chlorophyll content (CCC) caused by oak lace bug infestation, using multispectral imagery acquired by unmanned aerial vehicle (UAV) and machine learning regression algorithms (MLRA), including hybrid models based on radiative transfer modelling (PROSAIL).

The research was conducted on two experimental plots in the Republic of Croatia: one infested plot in the Jastrebarsko Forest Office (Plot A) and one control plot in the Buzet Forest Office (Plot B), during three vegetation periods (May, July, and September) between 2021 and 2023. Within each plot, subplots were defined for data collection. Field data were collected on leaf chlorophyll concentration, the number of oak lace bug egg clutches, and temperature, while multispectral UAV imagery was used to model CCC. Independent MLRA models were compared with hybrid PROSAIL+MLRA approaches.

The results partially confirmed the first hypothesis, namely that multispectral imagery acquired by UAVs can detect physiological changes in tree canopies caused by infestation. Gaussian Processes Regression (GPR) proved to be the most effective model, showing the highest coefficient of determination (R^2) and the lowest normalized root mean square error (NRMSE), outperforming the hybrid modeling approach. The second hypothesis, that chlorophyll concentration can be modeled using a combination of field data, environmental variables, and UAV imagery through regression-based machine learning, was also partially confirmed. The standalone GPR approach demonstrated satisfactory accuracy, while hybrid models incorporating physiologically simulated data did not achieve the expected predictive advantage. Nevertheless, their value lies in the ability to interpret physiological changes based on known biochemical processes affecting vegetation reflectance and their potential for application in environments with limited field sampling or over more homogeneous and extensive vegetated areas.

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

POPIS SLIKA

Slika 1 Karta širenja hrastove mrežaste stjenice (<i>Corythucha arcuata</i>) u Europi sa označenim područjima prirodnog areala hrasta lužnjaka (<i>Quercus robur</i>) i hrasta kitnjaka (<i>Quercus petraea</i>). Prikazan je vremenski slijed širenja od prvog nalaza 2000. godine do 2020 godine.....	5
Slika 2 Geografska lokacija pokusnih ploha u Republici Hrvatskoj odabranih za istraživanje: Ploha A (zaražena hrastovom mrežastom stjenicom) na području UŠP Karlovac (šumarija Jastrebarsko) i Ploha B (kontrolna ploha bez zaraze) na području UŠP Buzet (šumarija Buzet). 20	
Slika 3 Prikaz prostornog rasporeda podploha na plohi A (sa zarazom hrastovom mrežastom stjenicom) u šumariji Jastrebarsko sa brojčano označenim odsjecima i koordinatnom mrežom. Crveno su označena mjesta na kojima su postavljanji temperaturni senzori. Žutom bojom su označene pod plohe na kojima su uzorkovana dva stabla hrasta lužnjaka, dok je na zelenim pod plohamama uzorkovano jedno stablo hrasta lužnjaka.	24
Slika 4 Prostorni raspored podploha na kontrolnoj plohi B (bez zaraze hrastovom mrežastom stjenicom) u šumariji Buzet, Uprave šuma podružnice Buzet sa označenim odsjecima	25
Slika 5 a) Bespilotna letjelica eBee SQ korišten za prikupljanje multispektralnih snimaka tijekom istraživanja; b) Proces prikupljanja terenskih kontrolnih točaka pomoću GNSS uređaja za precizno georeferenciranje snimaka prikupljenih bespilotnom letjelicom	26
Slika 6 Prikaz sučelja programske podrške eMotion AG korištene za planiranje leta bespilotne letjelice s označenim položajima prikupljanja pojedinačnih snimaka na (a) plohi A i (b) plohi B	29
Slika 7 Dijagram toka obrade podataka unutar programske podrške Pix4D. Prikazan je detaljan slijed radnih koraka od ulaznih podataka do finalnih rezultata	30
Slika 8 Primjer mapa refleksije pojedinih kanala izrađenih obradom podataka pomoću Pix4D programa, korištenih za analizu koncentracije klorofila.....	31
Slika 9 Prikaz ručno delineirane krošnje stabla hrasta lužnjaka (<i>Quercus robur</i>) na ortomozaiku normalizirane razlike crvenog ruba (NDRE) vegetacijskog indeksa. Zeleno označava više vrijednosti (bliže 1) koje upućuju na viši sadržaj klorofila i zdraviju vegetaciju, dok crveno označava niže vrijednosti (bliže 0) koje ukazuju na fiziološki stres i potencijalno oštećeno lišće.	31
Slika 10 Prikaz digitalnog modela površine (DMP), digitalnog modela terena (DMT) i rezultirajućeg modela visine krošnje (CHM). DMP(u rasponu od 171.87-198.37 m) prikazuje ukupne visine površinskih objekata u ovom slučaju krošnje te tlo, dok DMT prikazuje konfiguraciju samog tla (u rasponu od 165.91-171.87 m).....	32
Slika 11 Specijalizirana arboristička praćka i dodatna oprema korištena za prikupljanje uzoraka listova hrasta lužnjaka iz gornjih dijelova krošnji za terenska mjerena koncentracije klorofila .	33

Slika 12 Prikaz lista hrasta lužnjaka sa označenim jajnim leglima (crveno), nimfama (žuto) i adultima (crno) hrastove mrežaste stjenice. Na listu su jasno vidljiva jajna legla hrastove mrežaste stjenice (HMS), smještena uz glavne lisne žile. Uz njih su prikazane i nimfe, kako bi se vizualno istaknula razlika između jajnih legala HMS i početnih razvojnih stadija HMS-a.....	37
Slika 13 Detaljni dijagram toka koji prikazuje metodologiju prikupljanja, obrade podataka te postupak modeliranja koncentracije klorofila korišten u istraživanju	45
Slika 14 Usporedba prosječnih vrijednosti indeksa lisne površine (LAI) između zaražene plohe A (Šumarija Jastrebarsko) i kontrolne plohe B (Šumarija Buzet) tijekom mjeseca svibnja, srpnja i rujna u razdoblju od 2021. do 2023. godine	50
Slika 15 Usporedba koncentracije klorofila krošnje (CCC) za svibanj, srpanj i rujan između zaražene plohe A (šumarija Jastrebarsko) i kontrolne plohe B (šumarija Buzet) tijekom istraživanog razdoblja (2021., 2022. i 2023. godina).....	52
Slika 16 Usporedba između koncentracije klorofila u listu (LCC) izmjerene na terenu i vrijednosti LCC-a procijenjene pomoću modela višestruke linearne regresije s tri ulazne varijable: koncentracija klorofila (LCC), stupanj-dana (SD) vrijednosti refleksije i broj jajnih legala za plohu A.....	55
Slika 17 Grafički prikaz rezultata nelinearnog modela strojnog učenja Random Forest korištenog za predviđanje koncentracije klorofila temeljem akumuliranih stupanj-dana (SD) i broja jajnih legala hrastove mrežaste stjenice za plohu A.....	55
Slika 18 Usporedba izmjerениh i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću MLRA GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca svibnja u razdoblju 2021., 2022. i 2023. godine. Slike 18 a i 18 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 18 c i 18 d prikazuju odnos između izmjerениh i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1).....	59
Slika 19 Usporedba izmjerenihs i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću MLRA GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca srpnja u razdoblju 2021., 2022. i 2023. godine. Slike 18 a i 18 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 18 c i 18 d prikazuju odnos između izmjerenihs i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1).....	62
Slika 20 Usporedba izmjerenihs i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću MLRA GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca rujna u razdoblju 2021., 2022. i 2023. godine. Slike 18 a i 18 b prikazuju prostornu raspodjelu modeliranihs vrijednosti CCC-a, dok Slike 18 c i 18 d prikazuju odnos između izmjerenihs i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1).....	65
Slika 21 Usporedba izmjerenihs i predviđenih vrijednosti koncentracije klorofila krošnje (CCC)	

pomoću hibridnog PROSAIL+GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca svibnja u razdoblju 2021., 2022. i 2023. godine. Slike 21 a i 21 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 21 c i 21 d prikazuju odnos između izmjerih i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1).... 68

Slika 22 Usporedba izmjerih i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću hibridnog PROSAIL+GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca srpnja u razdoblju 2021., 2022. i 2023. godine. Slike 22 a i 22 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 22 c i 22 d prikazuju odnos između izmjerih i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1).... 70

Slika 23 Usporedba izmjerih i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću hibridnog PROSAIL+GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca rujna u razdoblju 2021., 2022. i 2023. godine. Slike 23 a i 23 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 23 c i 23 d prikazuju odnos između izmjerih i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1).... 72

POPIS TABLICA

Tablica 1 Osnovni sastojinski elementi istraživanih sastojina hrasta lužnjaka: zaražena ploha (UŠP Karlovac, Šumarija Jastrebarsko) i kontrolna ploha bez zaraze hrastovom mrežastom stjenicom (UŠP Buzet, Šumarija Buzet).....	19
Tablica 2 Pregled prikupljenih podataka te vremenskog perioda sakupljanja na zaraženoj plohi A u šumariji Jastrebarsko, Uprava šuma podružnica Karlovac i kontrolnoj plohi B u šumariji Buzet, Uprava šuma podružnica Buzet	22
Tablica 3 Tehničke specifikacije bespilotne letjelice s fiksnim krilom eBee SQ korištene za prikupljanje multispektralnih podataka.....	27
Tablica 4 Spektralne karakteristike multispektralnog senzora Parrot Sequoia korištenog u istraživanju: nazivi kanala, centralne valne duljine i širine spektralnih kanala (nm)	27
Tablica 5 Ulazni biofizički i atmosferski parametri korišteni u simulacijama modela prijenosa radijacije lista (PROSPECT4) i modela prijenosa radijacije krošnje (4SAIL). Prikazani rasponi (minimalne i maksimalne vrijednosti) predstavljaju stvarno korištene ulazne parametre tijekom simulacija za plohe A i B u svibnju, srpnju i rujnu.....	43
Tablica 6 Pregled korištenih algoritama regresije strojnim učenjem u analizi podataka: opis glavnih karakteristika i referenca.....	47
Tablica 7 Vrijednosti indeksa lisne površine ($LAI \pm SD$) za Plohu A i Plohu B tijekom svibnja 2021., 2022. i 2023. godine.....	49
Tablica 8 Vrijednosti indeksa lisne površine ($LAI \pm SD$) za Plohu A i Plohu B tijekom srpnja 2021., 2022. i 2023. godine.....	49
Tablica 9 Vrijednosti indeksa lisne površine ($LAI \pm SD$) za Plohu A i Plohu B tijekom rujna 2021., 2022. i 2023. godine.....	50
Tablica 10 Deskriptivna statistika koncentracije klorofila lista (LCC) izmjerene na terenu i za zaraženu plohu A u šumariji Jastrebarsko i kontrolnu plohu B u šumariji Buzet tijekom svibnja, srpnja i rujna u razdoblju 2021.-2023.....	51
Tablica 11 Deskriptivna statistika okolišnih parametara na zaraženoj plohi A u šumariji Jastrebarsko: vrijednosti stupnjeva-dana i broja jajnih legala tijekom svibnja i srpnja, korištenih kao prediktori u regresijskim analizama.....	53
Tablica 12 Usporedba učinkovitosti različitih regresijskih modela strojnog učenja (MLRA) u procjeni koncentracije klorofila krošnje (CCC) za svibanj na plohamu A i B: prikaz pogreške kvadratne sredine (RMSE), relativne pogreške (NRMSE) i koeficijenta determinacije (R^2).....	57
Tablica 13 Usporedba učinkovitosti različitih modela regresije strojnim učenjem (MLRA) u procjeni koncentracije klorofila krošnje(CCC) za srpanj plohamu A i B: prikaz pogreške kvadratne sredine (RMSE), relativne pogreške (NRMSE) i koeficijenta determinacije (R^2)	60

Tablica 14 Usporedba učinkovitosti različitih modela regresije strojnim učenjem (MLRA) u procjeni koncentracije klorofila krošnje (CCC) za rujan na plohamama A i B: prikaz pogreške kvadratne sredine (RMSE), relativne pogreške (NRMSE) i koeficijenta determinacije (R^2).....	63
Tablica 15 Usporedba performansi hibridnog PROSAIL+GPR modela za predikciju koncentracije klorofila krošnje (CCC) zasebno za zaraženu (A) i kontrolnu plohu (B) tijekom istraživanog perioda 2021.-2023.....	66
Tablica 16 Sažetak rezultata modeliranja koncentracije klorofila krošnje (CCC) za sve promatrane mjesecce (svibanj, srpanj i rujan) tokom perioda istraživanja (2021.-2023.) i sve primijenjene metode (MLRA i hibridni PROSAIL+GPR pristup). Tablica prikazuje koeficijent determinacije (R^2) i pogrešku kvadratne sredine (RMSE) za svaku kombinaciju mjeseca, metode i plohe (A - zaražena; B - kontrolna).....	78

AKRONIMI

AL - Aktivno učenje, engl. *Active learning*

ARTMO - *Automated radiative transfer models operator*

CCC - Koncentracija klorofila krošnje, engl. *Canopy chlorophyll content*

CHM - Model visine krošanja, engl. *Canopy height model*

DD - Stupanj dani, engl. *Degree days*

GPR - *Gaussian processes regression*

HMS - Hrastova mrežasta stjenica

KRR - *Kernel ridge regression*

LAI - Indeks lisne površine, engl. *Leaf area index*

LCC - Koncentracija klorofila u listu, engl. *Leaf chlorophyll content*

LR - Linearna regresija

LSLR - *Least squares linear regression*

LUT - Pregledne tablice, engl. *Look up table*

MLRA - Regresijski algoritmi strojnog učenja, engl. *Machine learning regression algorithms*

NDRE - Vegetacijski indeks normalizirane razlike crvenog ruba, engl. *Normalized difference red edge index*

NDVI – Vegetacijski indeks normalizirane razlike, engl. *Normalized difference vegetation index*

NIR - Blisko infracrveno, engl. *Near infrared*

NN - *Neural network*

PCA - *Principal component analysis*

PLSR - *Partial least squares regression*

RF - *Random forest*

RT - *Regression tree*

RTM - Model prijenosa zračenja, engl. *Radiative transfer model*

SPAD - *Soil Plant Analysis Development*

1. UVOD

Šume osiguravaju važne ekosustavne usluge poput skladištenja ugljika, regulacije vodnih tokova, zaštite tla od erozije i očuvanja biološke raznolikosti, pri čemu su mješovite šumske zajednice učinkovitije u pružanju tih usluga od monokultura (Lu, 2025). Stabilnost i otpornost šuma podložne su utjecajima biotičkih i abiotičkih uzročnika stresa no u suvremenom kontekstu globalnih promjena klime te intenziviranja trgovine, jedan od sve izraženijih izazova postaje pojava i širenje invazivnih stranih vrsta kukaca (Liu i dr., 2021).

Strane invazivne vrste, unesene slučajno ili namjerno izvan svojih prirodnih areala, mogu značajno narušiti ravnotežu lokalnih šumskih zajednica. Njihova kompetitivna prednost, proizašla iz odsustva prirodnih neprijatelja i prilagodbe na nove klimatske uvjete, omogućava im brzu populacijsku ekspanziju i intenzivne štete na domaćim biljnim vrstama (Jarošík i dr., 2015, Brockerhoff i Liebhold, 2017). Primjeri poput borove nematode (*Bursaphelenchus xylophilus* Steiner & Buhrer) u Portugalu, jasenovog krasnika (*Agrilus planipennis* Fairmaire Coleoptera: Buprestidae) u Sjevernoj Americi te kestenove ose šiškarice (*Dryocosmus kuriphilus* Yasumatsu Hymenoptera; Cynipidae) u južnoj Europi pokazuju razmjere ekoloških i ekonomskih šteta koje invazivne vrste mogu izazvati (EFSA, 2010; Mota i dr., 2012; McCullough i dr., 2015).

Hrastova mrežasta stjenica (HMS) (*Corythucha arcuata* Say Hemiptera, Tingidae) strana je invazivna vrsta koja je prvi put u Europi zabilježena 2000. godine u sjevernoj Italiji (Bernardinelli i Zandigiacomo, 2000). Od tada se brzo proširila kroz više europskih zemalja, uključujući i Hrvatsku, gdje uzrokuje ozbiljne fiziološke poremećaje na stablima hrasta lužnjaka (*Quercus robur* L.), koji je u Hrvatskoj važna gospodarska vrsta (Franjević i dr., 2018, Csóka i dr., 2020). Svojim usnim ustrojem za bodenje i sisanje, HMS isisava biljne sokove iz lišća, što dovodi do smanjenja fotosintetske aktivnosti, klorotičnosti i opadanja listova, čime se narušava vitalnost cijelog stabla (Connell i dr., 1947; Bäläcenou i dr., 2021).

Monitoring šumskih štetnika radi se metodama vizualnih terenskih pregleda koji su vremenski i logistički zahtjevni, podložni subjektivnim pogreškama te često ne omogućuju pravovremeno otkrivanje ranih faza zaraze (Preti i dr., 2021). U posljednjem desetljeću značajan zamah bilježi primjena blizu-predmetnih metoda daljinskih istraživanja, posebice korištenje multispektralnih podataka prikupljenih bespilotnim letjelicama koje omogućuju preciznu, brzu i ponovljivu

procjenu fizioloških promjena u krošnjama stabala (Zarco-Tejada i dr., 2018; Savinelli i dr., 2024).

Uvođenjem spektralnih podataka u kombinaciji s modelima strojnog učenja i fizičkim modelima prijenosa zračenja, poput PROSAIL, otvaraju se nove mogućnosti za kvantitativnu procjenu sadržaja klorofila kao pokazatelja stresa. Ovakvi hibridni pristupi omogućuju integraciju terenskih mjerena, spektralnih indeksa i simulacija interakcije svjetlosti s listovima, što vodi razvoju operativnih alata za detekciju šteta uzrokovanih biotičkim čimbenicima u šumskim sastojinama (Verrelst i dr., 2016; Ali i dr., 2021)

1.1.Štetni utjecaj invazivnih stranih vrsta kukaca na šumske ekosustave

Povećane populacije šumskih štetnika, posebice fitofagnih kukaca, mogu uzrokovati značajne štete u šumskim ekosustavima. Ove su pojave neizbjegni dio prirodnog ciklusa u šumama, no u određenim situacijama, osobito kada je riječ o invazivnim vrstama, mogu imati značajan štetni utjecaj (Choi i Park, 2019). Kukci poput potkornjaka (*Scolytinae*), strizibuba (*Cerambycidae*), gusjenica (*Lepidoptera*), stjenica (*Hemiptera*) i drugih vrsta hrane se tkivima biljaka, oštećuju koru i ometaju transport vode i hranjivih tvari. Posljedice takvih napada kreću se od smanjenja vitalnosti biljaka do njihova potpunog odumiranja, što može dovesti do promjene strukture šumskih zajednica, gubitka biološke raznolikosti te poremećaja u kruženju hranjivih tvari i ugljika (Jarošik i dr., 2015).

Strane invazivne vrste kukaca, koje potječu izvan svog prirodnog areala, predstavljaju rastuću prijetnju šumskim ekosustavima jer često izostaju njihovi prirodni neprijatelji i domaćini nisu evolucijski prilagođeni na napade, što omogućuje brzu ekspanziju njihove populacije (Brockhoff i Liebhold, 2017). Globalizacija, posebno intenzivna međunarodna trgovina biljnim materijalom, i promet roba i putnika pogoduju njihovom širenju s kontinenta na kontinent, u nova područja (Mack i dr., 2000; Hulme, 2009). Dolaskom u novo područje, invazivne strane vrste mogu uspostaviti populacije i brzo se proširiti ako najdu na klimatski povoljne uvjete i dostupne biljne domaćine, pri čemu često dolazi do štetnog utjecaja na lokalnu bioraznolikost (Liebhold i Tobin, 2008). Štete koje čine invazivne strane vrste mogu biti ekološke i ekonomske, a u konačnici mogu narušiti ravnotežu ekosustava (Wittenberg i Cock, 2001).

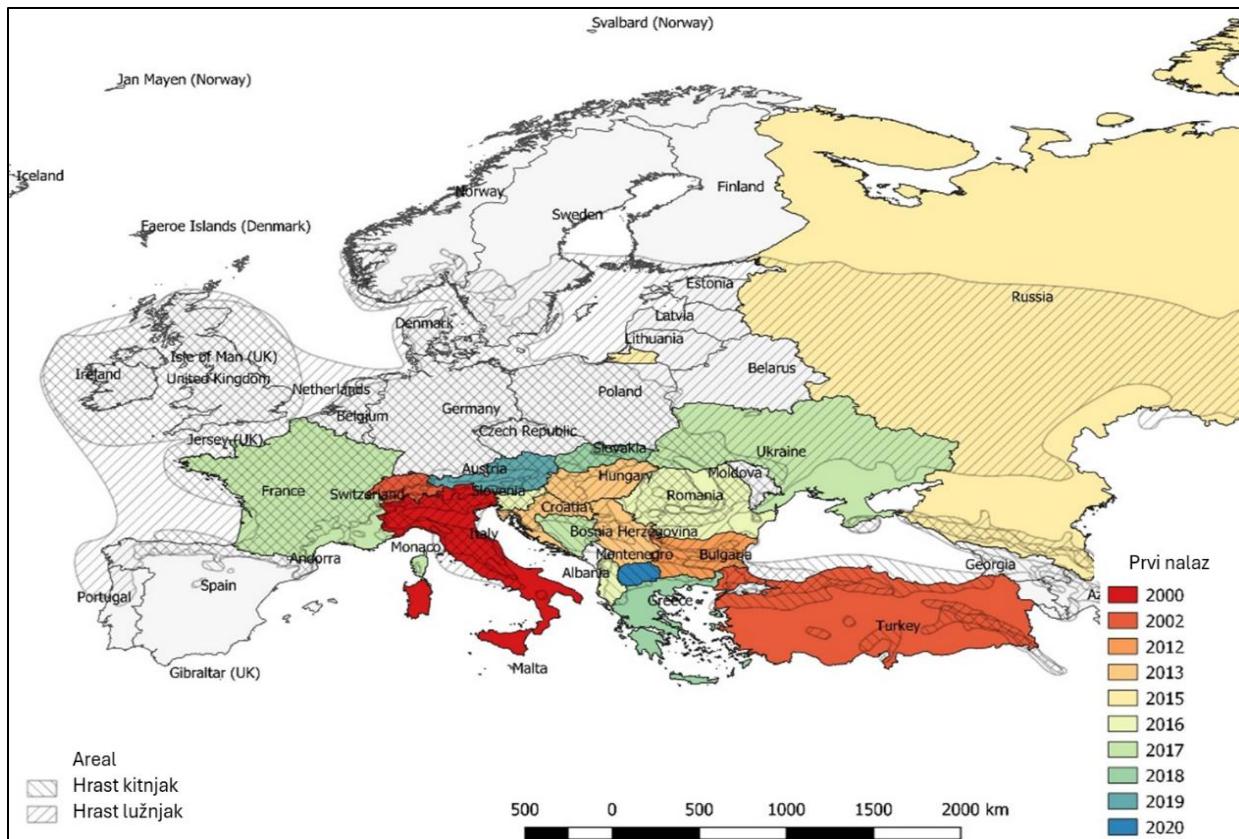
U Europi postoje neki nedavni primjeri, koji pokazuju koliko široke i trajne posljedice invazivne strane vrste kukaca mogu imati na lokalne šume i gospodarstvo. Kestenova osa šiškarica (*Dryocosmus kuriphilus*), porijeklom iz Azije, imala je negativan utjecaj na populacije pitomog

kestena u Italiji, Francuskoj i drugim europskim zemljama (EFSA, 2010). Osim što je nanijela ozbiljne ekonomske gubitke za lokalne proizvođače kestena, došlo je i do šteta na stablima zbog manje fotosintetske aktivnosti listova (Ugolini i dr., 2014). Strana invazivna vrsta borova nematoda (*Bursaphelenchus xylophilus*), koja je proširena u Portugalu i Španjolskoj uzrokuje brzo sušenje borovih šuma uz zamjetne troškove kontrole i suzbijanja te značajne gospodarske gubitke (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* Hopkins Coleoptera: Curculionidae) 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 velike površine šuma bez jasena (McCullough, 2020). 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 šumama i izbjegći katastrofalne posljedice za gospodarstvo i ekosustave (Brockhoff i dr., 2023).

1.2. Hrastova mrežasta stjenica

Hrastova mrežasta stjenica (HMS) (*Corythucha arcuata*) prirodno je rasprostranjena u sjevernoj Americi, u južnim dijelovima Kanade i istočnim saveznim državama Sjedinjenih Američkih Država (Horn i dr., 1979). U Europi je prvi put zabilježena 2000. godine u Italiji (Bernardinelli i Zandigiacomo, 2000), a od tada se brzo proširila diljem kontinenta (Paulin i dr., 2020; Csóka i dr., 2020) (Slika 1) te se smatra invazivnom stranom vrstom. U Hrvatskoj je prvi put primijećena u istočnom dijelu zemlje na području Uprave šuma podružnica Vinkovci, u šumama Spačvanskog bazena (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 hrastovim šumama (Csepelényi i dr., 2017; Csóka i dr., 2020). U svom prirodnom arealu primarno se razvija na bijelim hrastovima (*Quercus alba* L., *Q. macrocarpa* Michx., *Q. muehlenbergii* Engelm., *Q. prinoides* Willd.) (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). HMS u Europi napada mezofilne vrste hrastova, koje uspijevaju u umjereno vlažnim staništima s dobrom opskrbom vodom i stabilnim mikroklimatskim uvjetima, poput hrasta lužnjaka (*Quercus robur* L.), pri čemu njena uspješna invazija i brzo širenje u Europi su vjerojatno pod utjecajem povoljnih klimatskih uvjeta za njezin razvoj, visoke reproduktivne sposobnosti, široke ekološke prilagodljivosti te odsutnosti prirodnih neprijatelja u novom okolišu (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 njenog širenja. Svojim usnim ustrojem prilagođenim za bodenje i sisanje, odrasli oblici 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 (Connell i Beacher, 1947; Bălăcenoiu i dr., 2021).



Slika 1 Karta širenja hrastove mrežaste stjenice (*Corythucha arcuata*) u Europi sa označenim područjima prirodnog areala hrasta lužnjaka (*Quercus robur*) i hrasta kitnjaka (*Quercus petraea*). Prikazan je vremenski slijed širenja od prvog nalaza 2000. godine do 2020. godine.

Širenje HMS u Europi vjerojatno je potpomognuto klimatskim promjenama, koje proširuju temperaturne i sezonske uvjete pogodne za preživljavanje i razmnožavanje ove vrste u sve većem broju europskih regija (Stancă-Moise i dr., 2023). HMS uspješno prezimljava u Europi (Paulin i dr., 2020), a njenom širenju pogoduju viša temperatura i niža relativna vlažnost zraka, pod uvjetom da temperature ne prelaze prag termalnog stresa. Za brzinu širenje, osim meteoroloških uvjeta, važni čimbenici su i niže nadmorske visine te blizina prometnica jer se HRM širi kao slučajni "autostoper" zbog svoje male veličine (Maciej Serda i dr., 2024).

Istraživanja na bijelom hrastu pokazuju da se najviše odraslih jedinki HMS nalazi na stablima s otvorenijim krošnjama, jer listovi u takvim uvjetima sadržavaju više vode i mekše su strukture, što im olakšava ishranu (Barber, 2010). Mikroklimatski uvjeti značajno utječu na razvoj štetnika, pa

se u rjeđim sastojinama ili na rubnim stablima, koja primaju više svjetla, HMS brže razmnožava i postiže veću brojnost (Bălăcenoiu i dr., 2021). Najveće štete zbog napada HMS registrirane su u čistim hrastovim sastojinama, dok mješovite šume pokazuju blaže oblike zaraze (Marjanović i Kern, 2021; Hoch i dr., 2024). HMS se nakon prvog nalaza vrlo brzo proširila u hrastovim sastojima u Republici Hrvatskoj i počela je uzrokovati štete te pokazivati tipične karakteristike invazivne strane vrste (Franjević i dr., 2018; Kern i dr., 2021; Zorić i dr., 2023). Hrastove šume imaju veliki ekonomski i ekološki značaj u šumarstvu Republike Hrvatske i bitno je zaštiti taj vrijedni prirodni resurs.

1.3. Praćenje klorofila metodama terenskih i daljinskih istraživanja kao pokazatelja stresa

Štete koje HMS čini sisanjem sokova iz lista uzrokuje smanjenje sadržaja klorofila i karotenoida u lišću, što smanjuje fotosintetsku aktivnost i posljedično vitalnost biljaka. Osim toga, lišće postaje tanje zbog smanjenja veličine parenhimskih stanica, što dodatno narušava njegovu funkcionalnost (Bibin i dr., 2023). Klorofil u listovima, osnovna komponenta fotosintetskog aparata, jedan je od biljnih pigmenata koji najosjetljivije reagira na promjene vanjskih uvjeta. Djeluje kao glavni pokazatelj zdravlja i produktivnosti biljaka, unosa hranjivih tvari i reakcije na stres (Chakhvashvili i dr., 2022; Moustaka i Moustakas, 2023). Visoka razina oksidativnog stresa negativno djeluje na sintezu i akumulaciju klorofila, uzrokujući smanjenje njegove koncentracije, a niska razina stresa može potaknuti njegovu proizvodnju i akumulaciju. Taj stimulativni odgovor klorofila na blaži stres može značajno povećati sposobnost biljaka za obranu u razdobljima intenzivnijeg stresa, omogućujući im bolju prilagodbu na izazove poput invazivnih štetnika ili drugih štetnih biotičkih i abiotičkih čimbenika (Agathokleous i dr., 2020). Zato je praćenje biokemijskih sastojaka, od kojih je jedan i klorofil u lišću, jedan od mogućih parametara za procjenu stresa na stablima na kojima su registrirane štete od kukaca (Moley i dr., 2022). Rano otkrivanje stresa moguće je snimanjem klorofilne fluorescencije, koja predstavlja svjetlost koju klorofil emitira nakon apsorpcije sunčeve energije, a promjene u toj emisiji javljaju se prije nego što se stres očituje vidljivim simptomima na listovima. Uz to, promjene u spektralnoj refleksiji lišća, što označava količinu svjetlosti koju list reflektira na određenim valnim duljinama, osobito u području oko 700 nm, povezane su s promjenama sadržaja klorofila izazvanim stresom (Lichtenthaler i dr., 1998; Zarco-Tejada i dr., 2002).

Mjerenje sadržaja klorofila lista moguće je pomoću prijenosnih uređaja kao što su klorofilmetri. Ovi alati procjenjuju razine klorofila mjeranjem svojstava apsorpcije i refleksije svjetlosti na listovima biljaka. Pružaju brza, izravna mjerenja i posebno su korisni za znanstvenike koji trebaju podatke u stvarnom vremenu, bez potrebe za složenim laboratorijskim analizama (Bauerle i dr., 2004; Hutomo i dr., 2016). Jedan od alata za nedestruktivno utvrđivanje klorofila je SPAD (engl. *Soil Plant Analysis Development*) klorofilmetar (Shibaeva i dr., 2020). Odnos između SPAD vrijednosti, koja predstavlja indeks zelene boje lista dobiven prijenosnim uređajem na temelju apsorpcije svjetlosti pri specifičnim valnim duljinama, i stvarnog sadržaja klorofila specifičan je za svaku biljnu vrstu, varira tijekom vegetacijske sezone i obično se opisuje nelinearnim modelima (Xiong i dr., 2015; Wakiyama, 2016). U istraživanju provedenom na osam listopadnih vrsta drveća, korišteni su različiti klorofilmetri za mjerenje, a SPAD rezultati su nakon kalibracije prema destruktivno određenim vrijednostima koncentracije klorofila pokazali usporedivu točnost. Na temelju tih podataka razvijene su kalibracijske funkcije za precizno određivanje koncentracije klorofila u listu, što omogućuje pouzdanu primjenu SPAD klorofilmetra u terenskim uvjetima bez potrebe za destruktivnim analizama (Brown i dr., 2022).

Podaci o sadržaju klorofila prikupljeni pomoću prijenosnih uređaja poput SPAD klorofilmetara važni su za izravnu procjenu fiziološkog stanja stabala te služe kao referenca za kalibraciju i validaciju podataka iz daljinskih istraživanja, uključujući snimke dronova i satelita. Satelitski podaci omogućuju praćenje zdravstvenog stanja šuma na regionalnoj i kontinentalnoj razini jer bilježe spektralne refleksije vegetacije koje ukazuju na promjene u njezinoj fiziološkoj aktivnosti, no njihova interpretacija zahtijeva terenska mjerenja kako bi se spektralne vrijednosti precizno povezale s stvarnim biološkim parametrima poput sadržaja klorofila. Povezivanjem SPAD vrijednosti s refleksijskim karakteristikama satelitskih snimaka razvijaju se regresijski modeli za pouzdano kartiranje promjena u sadržaju klorofila na razini šumskega sastojina. (Gitelson i dr., 1996; Daughtry i dr., 2000) Integracijom satelitskih podataka visoke rezolucije i terenskih mjerenja koncentracije klorofila značajno se povećava točnost i pouzdanost procjene zdravstvenog stanja i vitalnosti šumskega ekosustava (Richardson i dr., 2001; Zarco-Tejada i dr., 2018).

Analizom refleksije svjetlosti u određenim dijelovima elektromagnetskog spektra moguće je odrediti sadržaj klorofila u biljkama i prepoznati promjene koje ukazuju na stres ili oštećenja vegetacije (Gitelson i Merzlyak, 1996; Daughtry i dr., 2000; Zarco-Tejada i dr., 2002).

Metode daljinskih istraživanja postale su nezamjenjiv alat u upravljanju šumskim resursima, omogućujući detaljno praćenje stanja i promjena u šumskim ekosustavima (Le i dr., 2023; Jiao, 2024). Satelitske snimke, kao i podaci prikupljeni zrakoplovima ili bespilotnim letjelicama opremljenim sa multispektralnim, hiperspektralnim ili laserskim (LiDAR, engl. *Light Detection and Ranging*) senzorima, omogućuju praćenje promjena u šumama uz visoku prostornu, vremensku i spektralnu rezoluciju (Benko i Balenovic, 2011; Jovanović i dr., 2021).

Multispektralni podaci obuhvaćaju nekoliko širokih spektralnih kanala, najčešće u crvenom, zelenom, plavom i optičkom infracrvenom dijelu spektra, te se često koriste parametarskim pristupom kroz izračun vegetacijskih indeksa koji omogućuju kvantificiranje biomase, stanja vegetacije i reakcije na čimbenike stresa (Belov i dr., 2022). Nasuprot parametarskom pristupu, neparametarski pristup koristi sirove refleksijske vrijednosti svih kanala bez transformacije u indekse, što omogućuje sofisticiriju analizu na temelju spektralnih obilježja, posebice uz primjenu metoda kao što je strojno učenje algoritmima regresije (Skidmore, 1989). Hiperspektralni podaci, s druge strane, sastoje se od stotina uzastopnih i uskih spektralnih kanala koji omogućuju detaljnu analizu spektralnih potpisa vegetacije, čime se značajno povećava preciznost u razlikovanju vrsta drveća, identifikaciji stresnih stanja i detekciji bolesti u šumskim ekosustavima (Ančić i dr., 2019).

Satelitske optičke platforme, poput MODIS (od engl. od eng. *Moderate Resolution Imaging Spectroradiometer*), Landsata 8/9 i Sentinel-2, mogu se koristiti za detaljno i vremenski kontinuirano praćenje vegetacije prikupljanjem podataka na velikim prostornim razmjerima, što ih čini posebno korisnima u kontekstu detekcije šumskih šteta izazvanih biotskim i/ili abioitskim čimbenicima (Dalponte i dr., 2022; Bozzini i dr., 2023). Tako se za procjenu zdravstvenog stanja i vitalnosti šuma koriste indeksi vegetacije, među kojima je najrašireniji vegetacijski indeks normalizirane razlike (NDVI, od engl. *Normalized Difference Vegetation Index*). NDVI kvantificira fotosintetsku aktivnost vegetacije na temelju spektralnih svojstava listova, konkretno omjera reflektirane svjetlosti u bliskom infracrvenom (NIR, prema engl. *near infrared*) i crvenom (R) području. Visoke vrijednosti NDVI-a upućuju na aktivnu, zdravu vegetaciju, dok snižene vrijednosti mogu ukazivati na fiziološki stres (Rouse i dr., 1974). Upravo zbog toga, NDVI se široko primjenjuje u analizi satelitskih podataka za detekciju šumskih oštećenja. Na primjer, korištenjem MODIS podataka razvijena je metoda za razdvajanje meteoroloških utjecaja od učinaka HMS na NDVI, pri čemu je pokazano da su najveći padovi NDVI vrijednosti zabilježeni

u sastojinama s dominacijom hrasta, primarnog domaćina ove invazivne vrste (Kern i dr., 2021).

Sateliti iz Landsat programa, sustava satelita Sjedinjenih Američkih Država za daljinsko istraživanje Zemlje koji kontinuirano prikupljaju optičke multispektralne podatke još od 1970-ih godina, predstavljaju dragocjen izvor podataka za retrospektivnu analizu zaraza štetnicima u šumama. Gubar (*Lymantria dispar* L., Lepidoptera; Lymantriidae), kao značajan defolijator šuma praćen je kombinirajući Landsat podatke i terenska mjerena. Potvrđena je velika korisnost Landsat podataka za praćenje višegodišnje dinamike zaraze štetnika. Analizom Landsat snimaka moguće je pravovremeno otkriti značajne promjene u strukturi krošnje te identificirati biljni stres uzrokovan zarazama štetnika ili drugim okolišnim čimbenicima. (Townsend i dr. 2012; Foster i dr. 2013).

U posljednjem desetljeću, Sentinel-2 postaje sve popularniji zbog visoke 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 crvenog-zelenog-plavog kanala (RGB, prema engl. *red-green-blue*) te NIR i SWIR (prema engl. *shortwave near infrared*) 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. Dosadašnja istraživanja su pokazala da red-edge indeksi mogu pouzdanije od tradicionalnih indeksa poput NDVI razlikovati zdrava i oštećena stabla (Senf i dr., 2017). Zahvaljujući visokoj prostornoj i vremenskoj rezoluciji moguće je otkriti rane promjene u vegetacijskim indeksima povezanima s defolijacijom ili stresom, čak i prije nego što su simptomi jasno vidljivi na terenu (Huo i dr., 2021).

Analizom sezonskih promjena spektralnih karakteristika krošnji moguće je razlikovati zdrava stabla od onih u početnim fazama zaraze, što omogućuje pravovremeno planiranje ciljanih terenskih pregleda i mjera suzbijanja (Molnár i Király, 2023). Takav pristup značajno doprinosi učinkovitijem gospodarenju šumskim resursima (Huo i dr., 2021; Molnár i Király, 2023).

Spomenuti optički sateliti, koji mogu biti korisni za praćenje zaraza većih šumskih područja, imaju nekoliko nedostataka koji ograničavaju njihovu učinkovitost. Jedan od glavnih problema je njihova prostorna rezolucija snimaka (veća od 10 m za satelite sa besplatnim pristupom podacima), koja može biti nedovoljna za precizno otkrivanje manjih prostornih žarišta zaraze. Trenutno postoji nekoliko komercijalnih optičkih satelita (npr. PlanetScope, WorldView 2/3/4 ili GeoEye) koji

imaju znatno veću prostornu rezoluciju (<1 m) te snimaju u većem broju spektralnih kanala u usporedbi s javno dostupnim satelitskim podacima (Longbotham i dr., 2015, Roy i dr., 2021). Međutim, ti podaci nisu slobodno dostupni, već zahtijevaju plaćeni pristup, što ograničava njihovu široku primjenu. Dodatni nedostatak svih optičkih satelita je oslanjanje na vidljivu (RGB) i NIR/SWIR svjetlost pa je prikupljanje podataka osjetljivo na vremenske uvjete (npr. pokrivenost oblacima), što može značajno utjecati na kvalitetu snimaka. Stoga je primjena bespilotnih letjelica praktična jer omogućuju prikupljanje podataka i u uvjetima oblačnog vremena zahvaljujući mogućnosti letenja ispod oblaka te mogu biti opremljeni različitim senzorima poput optičkih RGB, termalnih i multispektralnih koji omogućuju detaljno snimanje vegetacije, tla i površinske temperature. Ovi sustavi omogućuju brzo prikupljanje podataka s kratkim vremenom obrade, te snimanje većih područja odjednom (Ecke i dr., 2022).

Primjenom bespilotnih letjelica moguće je prikupiti podatke vrlo visoke prostorne rezolucije najčešće centimetarske razine, što omogućuje precizno praćenje stanja šuma i pravovremeno otkrivanje znakova zaraza (Savinelli i dr., 2024). Bespilotne letjelice mogu letjeti na nižim visinama i u stvarnom vremenu prenositi podatke, što omogućuje bržu dostupnost podataka.

S obzirom na to da bespilotne letjelice lete ispod oblaka, mogu zaobići problem naoblake koja ometa prikupljanje podataka satelitima. Bespilotne letjelice su prilagodljivije od satelita pri snimanju manjih i specifičnih područja zahvaćenih zarazama, jer omogućuju usmjeravanje snimanja na točno određene lokacije unutar šume, pri čemu se dobivaju snimke s vrlo visokom prostornom rezolucijom (često nekoliko centimetara po pikselu) (Dash i dr., 2018).

Bespilotne letjelice mogu biti opremljeni različitim senzorima, uključujući multispektralne i hiperspektralne kamere, što omogućuje prikupljanje vrlo detaljnih podataka s visokim spektralnim rasponom. Sve navedene karakteristike čine bespilotne letjelice korisnim alatom za precizno i brzo praćenje pojave poput napada štetnika, širenja invazivnih vrsta i drugih biotskih stresora koji utječu na zdravlje šuma (Guimarães i dr., 2020; Duarte i dr., 2022).

Multispektralne snimke prikupljene bespilotnom letjelicom opremljenom senzorom Parrot Sequoia uspješno su upotrijebljene za automatsku procjenu defolijacije stabala uzrokovane borovim četnjakom (*Thaumetopea pityocampa* Denis & Schiffermüller Lepidoptera; Notodontidae), u mješovitim sastojinama bijelog bora (*Pinus sylvestris* L.) i hrasta crnike (*Quercus ilex* L.) (Cardil i dr., 2019). Model temeljen na vegetacijskim indeksima dobivenim iz

multispektralnih podataka postigao je točnost klasifikacije razina defolijacije od 81,8%, čime je potvrđena učinkovitost bespilotnih sustava u praćenju biotskog stresa na razini pojedinačnih stabala. U istraživanju provedenom u sastojinama obične smreke (*Picea abies* L.), stres uzrokovani potkornjakom (*Ips typographus* L., Coleoptera: Curculionidae) uspješno je detektiran pomoću multispektralnih snimaka prikupljenih bespilotnom letjelicom, a dodatno su identificirani ključni spektralni kanali i vegetacijski indeksi korisni za razlikovanje razina oštećenja (Minařík i Langhammer 2016). U sastojinama eukaliptusa (*Eucalyptus globulus* Labill.) u Portugalu, oštećenja izazvana kukcem *Phoracantha semipunctata* Fabricius (Coleoptera: Cerambycidae) detektirana su s visokom preciznošću (98,5%) korištenjem bespilotnog sustava eBee SenseFly opremljenog Parrot Sequoia senzorom (Duarte i ostali 2020). U istraživanju provedenom tijekom progradacije južnog borovog potkornjaka (*Dendroctonus frontalis* Zimm. Coleoptera: Curculionidae) u Sjedinjenim Američkim Državama (SAD) multispektralni podaci prikupljeni bespilotnom letjelicom korišteni su za detekciju ranih znakova napada na borove (*Pinus rigida* Mill.) (Kanaskie i dr., 2024)

Za usporedbu, multispektralne snimke prikupljene bespilotnom letjelicom se na sličan način nastoje primijeniti i u poljoprivredi. Fiziološke promjene u biljkama izazvane biotičkim stresorima mogu se detektirati putem promjena u spektralnoj refleksiji, osobito u NIR području. U istraživanju na sojinim poljima, povećanje populacije sojine lisne uši bilo je povezano sa smanjenjem refleksije u NIR spektru što je ukazivalo na oštećenje listova i smanjenje njihova vodnog sadržaja (Marston i dr., 2020). S druge strane, u radu na kukuruzu naglašena je važnost indeksa lisne površine za procjenu klorofila krošnje, kao pokazatelja fiziološkog stanja usjeva (Simic Milas i dr., 2018). Navedeni primjeri potvrđuju da spektralne analize i mjerena koncentracije klorofila omogućuju ranu detekciju stresa u biljkama, čime doprinose pravovremenim odgovorima u poljoprivrednoj i šumarskoj praksi.

1.4. Procjena koncentracije klorofila krošnji pomoću strojnog učenja i spektralnih podataka prikupljenih metodama daljinskih istraživanja

Dva ključna pristupa omogućuju procjenu koncentracije klorofila u krošnjama temeljenom na podacima prikupljenim daljinskim istraživanjem: (1) statističke regresijske metode koji uključuju regresijske algoritme strojnog učenja (MLRA, prema engl. *Machine learning regression algorithms*) (2) primjena modela prijenosa zračenja (RTM, prema engl. *Radiative transfer models*) (Baret i Buis, 2008). Spajanje modela prijenosa zračenja sa statističkim regresijskim metodama strojnog učenja u hibridne modele (RTM+MLRA) pokazalo se kao obećavajuće rješenje za procjenu koncentracije klorofila u krošnjama (Guo i dr., 2023, Alam i dr., 2024, Xu i dr., 2024). Hibridni pristupi kombiniraju prednosti fizičkog modeliranja putem RTM-a i fleksibilnosti MLRA metoda. Navedeni modeli omogućuju integraciju fizičkih principa s lokalno prikupljenim podacima, uz zadržavanje visoke računalne učinkovitosti i prilagodljivosti modela (Verrelst i dr., 2016; Verrelst i dr., 2019).

1.4.1. 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 spektralnih podataka prikupljenih pomoću senzora (npr. multispektralnih ili hiperspektralnih), uočavaju statističku povezanost i predviđaju ciljane varijable na temelju odnosa između spektralnih karakteristika i biofizičkih parametara, poput sadržaja klorofila ili indeksa lisne površine (Camps-Valls i Bruzzone, 2009). Prednost ovih algoritama je u sposobnosti da se prilagode i poboljšaju svoje performanse s novim podacima, često bez potrebe za dodatnim programiranjem od strane krajnjeg korisnika za svaku specifičnu primjenu (Lary i dr., 2016). To znači da nakon što je algoritam strojnog učenja obučen na odgovarajućem skupu podataka, on može samostalno analizirati nove ulazne podatke koji nisu bili uključeni u fazi treniranja i generirati pouzdana predviđanja.

U primjeni kod daljinskih istraživanja, algoritmi strojnog učenja koriste kombinaciju podataka prikupljenih pomoću različitih senzora (npr. multispektralni i hiperspektralni senzori na satelitima, bespilotnim letjelicama ili zrakoplovima) i terenskih mjerena (npr. koristeći klorofilmetar ili laboratorijska mjerena sadržaja klorofila u listovima) (Verrelst i dr., 2012; Ye i dr., 2022).

Spektralni podaci prikupljeni senzorima daju informaciju o refleksiji ili emitiranju

elektromagnetskog zračenja s površine Zemlje u različitim valnim duljinama, a terenski podaci služe kao referentna vrijednost za validaciju i treniranje modela (Xie i dr. 2018). Ova kombinacija podataka omogućuje algoritmima strojnog učenja da analiziraju spektralne značajke snimaka i provedu precizne regresijske analize, procjenjujući kvantitativne vrijednosti okolišnih parametara, poput koncentracije klorofila na razini krošnje i indeksa lisne površine (LAI) (Ahmad i dr. 2020). Regresijska analiza omogućuje uspostavljanje kvantitativne veze između spektralnih podataka dobivenih daljinskim istraživanjima i referentnih vrijednosti iz terenskih mjerena. Algoritmi strojnog učenja se također koriste u klasifikacijama, gdje razvrstavaju piksele snimke u različite kategorije (klase), kao što su različite vrste vegetacije, tipovi tla, vodene površine, izgrađena područja i druge (Camps-Valls i dr. 2009).

Jedan od doprinosa strojnog učenja daljinskim istraživanjima jest sposobnost učinkovite analize velikih količina podataka (često se govori o "velikim podacima" (eng. *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. Takav pristup omogućuje ne samo dublje i detaljnije razumijevanje složenih odnosa između izmjerениh spektralnih refleksija i stanja okoliša, već i razvoj poboljšanih, preciznijih alata za kartiranje i praćenje stanja okoliša, promjena u okolišu i različitim procesima u ekosustavima (Xie i dr. 2018; Berger i dr. 2020).

Statističke metode za procjenu koncentracije klorofila u listu mogu koristiti linearnu regresiju, ali i sofisticirane pristupe temeljene na algoritmima regresije strojnog učenja, koji su osobito učinkoviti u prepoznavanju složenih, nelinearnih odnosa u podacima daljinskih istraživanja. Metode strojnog učenja, treniraju se na izdvojenim podacima iz podataka daljinskog istraživanja i odgovarajućim terenskim mjerjenjima klorofila (Bozzini i dr. 2023; Ye i dr. 2022). Složeniji MLRA, poput dubokih neuronskih mreža, koriste se za prepoznavanje složenih nelinearnih obrazaca koji nisu očiti u jednostavnijim modelima (Du i Luo, 2024).

Spektralne vrijednosti snimaka u različitim spektralnim područjima kao i različiti spektralni indeksi (poput NDVI) se mogu koristiti u MLRA kao ulazni podaci. Spektralni indeksi, odnosno omjeri vrijednosti izmjereni u različitim dijelovima elektromagnetskog spektra, matematički smanjuju utjecaj pogrešaka nastalih tijekom prikupljanja spektralnih podataka objekata. Takve pogreške najčešće proizlaze iz atmosferskih utjecaja ili efekta dvosmrterne razdiobe refleksije

(engl. *Bi-directional Reflectance Distribution Function*), koji nastaje uslijed specifične geometrije odnosa objekta, položaja Sunca i senzora (Simic i dr., 2011). Treniranje modela uključuje ulazne varijable, poput refleksije ili spektralnih indeksa, i ciljne varijable, kao što su koncentracije klorofila izmјerenog na terenu ili iz satellita/bespilotne letjelice-a. 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 pristrandost modela. Pomaže u sprječavanju prekomjernog prilagođavanja (engl. *overfitting*) evaluirajući kako model funkcioniра na neviđenim podacima. Proces obuhvaća dijeljenje skupa podataka na podskupove, trenirati model na nekim od njih i testirati/validirati ga na preostalim podacima (Singhal i dr., 2019).

Modeli često prethodno zahtijevaju redukciju dimenzionalnosti, primjenom Principal Component Analysis (PCA) ili Partial Least Squares Regression (PLSR), kako bi se ublažila kolinearnost spektralnih refleksija u jednom skupu podataka daljinskih mјerenja (npr. kod hiperspektralnih podataka) i omogućilo učinkovito modeliranje (Ye i dr., 2007; Arenas-Garcia i dr., 2013). Obje metode transformiraju visoko dimenzionalne ulazne podatke u prostor niže dimenzionalnosti, pritom zadržavajući najveći mogući dio varijabilnosti relevantne za analizu. Time se smanjuje šum, poboljšava interpretabilnost i omogućuje učinkovitija primjena u strojnem učenju (Nofrizal i dr., 2022).

1.4.2. Model prijenosa zračenja

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

RTM uključuju različite razine kompleksnosti vegetacije i najčešće se kreiraju na razini lista ili krošnje. Potom se RTM lista i krošnje povezuju u jedan sveobuhvatni RTM, što rezultira većom preciznosti predviđanja (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 povezanost između elektromagnetskog zračenja i krošnji, uzimajući u obzir faktore arhitekture krošnje poput

položaja kuta listova, indeksa površine lista (LAI, eng. *Leaf area indeks*) i pozadinskog tla (Verhoef, 1984). Integracija oba nivoa kompleksnosti omogućuje cjelovitiji prikaz refleksije vegetacije, budući da obuhvaća biokemijska svojstva listova te strukturne karakteristike krošnje. PROSAIL model (Jacquemoud i dr., 2009) je jedan od najšire korištenih integriranih RTM-ova. Kombinira optička svojstva lista, koja simulira PROSPECT model (Jacquemoud i Baret, 1990) s modelom SAIL (Verhoef, 1984), koji opisuje prijenos zračenja i interakcije između listova na razini krošnje. PROSPECT model simulira optička svojstva listova biljaka koristeći parametre kao što su struktura mezofila lista, koncentracija pigmenata i sadržaj vode, učinkovito rekonstrui rajući 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 nagib listova, pružajući realistične kutne profile refleksije na temelju kuta gledanja i solarnog zenitnog kuta (Verhoef, 1984). Iako se model PROSAIL uspješno primjenjuje u analizi multispektralnih podataka, njegova puna učinkovitost dolazi do izražaja pri radu s hiperspektralnim podacima, zahvaljujući mogućnosti detaljne simulacije refleksije u velikom broju uskih valnih duljina. Time model pruža čvrstu osnovu za kvantitativnu procjenu vegetacijskih parametara u istraživanjima stanja i dinamike vegetacije (Berger i dr., 2018). Rezultati validacije pokazali su da PROSAIL uspješno simulira spektralnu krivulju refleksije vegetacije za različite kutove gledanja uključujući i specifične geometrijske položaje poput "hotspot" (pri čemu su Sunce i senzor u istoj liniji) i "dark spot" (gdje je reflektirana svjetlost minimalna zbog geometrije osvjetljenja) (Barman i dr., 2010).

Obzirom da PROSAIL simulira optičke reflektivne vrijednosti nekog vegetacijskog područja koristeći ulazne parametre, njegova matematička inverzija omogućuje procjenu ključnih parametara, poput sadržaja klorofila, 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, engl. *Look up table*) (Weiss i dr., 2000; Darvishzadeh i dr., 2008; Vicent i dr., 2020) i metode strojnog učenja, poput umjetnih neuronskih mreža (Ai i dr., 2019; He i dr., 2021).

Model PROSAIL postao je široko prihvaćen u istraživačkoj zajednici zahvaljujući svojoj jednostavnosti, točnosti i dostupnosti, no unatoč brojnim prednostima, ograničen je u simulaciji složenijih, heterogenih krošnji. Zbog toga su potrebna dodatna unaprjeđenja modela i uvođenje novih varijabli kako bi se postigla realističnija i točnija simulacija stvarnih šumskih ekosustava (Wu i dr., 2022; Xu i dr., 2024).

1.5. Hibridni pristup modeliranja

Hibridni modeli koji kombiniraju RTM i metode strojnog učenja predstavljaju napredak u daljinskom istraživanju vegetacije. Ovi modeli objedinjuju prednosti fizičkog modeliranja temeljenog na zakonima prijenosa zračenja i fleksibilnosti metoda strojnog učenja koje koriste podatke specifične za područje istraživanja, omogućujući precizniju procjenu biofizičkih i biokemijskih parametara vegetacije (Verrelst i dr., 2016). Ključna prednost hibridnih modela leži u njihovoj sposobnosti integracije simuliranih optičkih refleksijskih podataka s podacima dobivenim stvarnim daljinskim snimanjem (npr. satelitskim ili platformama bespilotnih letjelica) i terenskim mjeranjima. Usporednom s konvencionalnim statističkim ili fizičkim pristupima, hibridni modeli pokazuju robusnost u predviđanju vegetacijskih parametara, osobito u uvjetima stanišne heterogenosti i ograničenih količina terenskih podataka (Verrelst i dr., 2019).

Aktivno učenje, kao sastavni dio ovog pristupa, omogućuje selektivno biranje najinformativnijih uzoraka za treniranje modela, čime se smanjuje potreba za velikim količinama podataka, dok se istovremeno povećava učinkovitost i točnost modela (Tuia i dr., 2011). Umjesto nasumičnog uzorkovanja, aktivno učenje koristi strategije poput "uncertainty sampling" i "diversity sampling" kako bi se optimizirala reprezentativnost skupa podataka. Time se znatno smanjuje potreba za velikim količinama podataka, ubrzava treniranje modela i istovremeno povećava njegova točnost. Pokazalo se da modeli trenirani pomoću aktivnog učenja postižu bolju preciznost od onih treniranih na slučajno odabranim uzorcima, dok istovremeno smanjuju složenost modela i vrijeme obrade (Berger i dr., 2021).

Integracija modela prijenosa zračenja (RTM) i metoda strojnog učenja implementirana je u softverskoj platformi ARTMO (Automated Radiative Transfer Models Operator), razvijenoj u MATLAB okruženju (verzija korištena u ovom istraživanju: 9.8.0.1323502 (R2020a)). MATLAB (Matrix Laboratory) je komercijalno programsko rješenje za numeričku analizu i znanstveno programiranje koji razvija i distribuira tvrtka MathWorks. ARTMO, razvijen od strane Instituta za geomatiku Sveučilišta u Valenciji (Caicedo Rivera i dr., 2014), omogućuje izvođenje različitih RTM simulacija, primjenu strojnog učenja te integraciju hibridnih modela poput PROSAIL+MLRA. Unutar ove platforme, PROSAIL hibridni model objedinjuje PROSPECT model, koji simulira optička svojstva listova na temelju sadržaja klorofila, vode i drugih biokemijskih komponenti, s SAIL modelom koji opisuje interakciju zračenja s arhitekturom krošnje i pozadinskim tlom. Ovaj pristup detaljno je opisan u poglavljju Materijali i metode.

S obzirom na gospodarsku i ekološku važnost sastojina hrasta lužnjaka u Republici Hrvatskoj te prijetnju koju predstavlja hrastova mrežasta stjenica (HMS), ključno je razviti pouzdane i učinkovite metode za praćenje dinamike zaraze ovim štetnikom. Zbog toga je ovo je istraživanje usmjereni na primjenu metoda daljinske detekcije temeljenih na podacima prikupljenih bespilotnim letjelicama i kombinacijom fizičkih i empirijskih modela (PROSAIL+MLRA), kako bi se procijenila koncentracija klorofila koji može služiti kao indikatora stresa uzrokovanih napadnom HMS-om. Ovakav integrirani pristup omogućuje razvoj operativnih alata za rano prepoznavanje stresa na stablima i može se opisati kao jedan od koraka za brže i učinkovitije rano otkrivanje negativnih učinaka štetnika u šumskim ekosustavima.

2. CILJEVI I HIPOTEZE ISTRAŽIVANJA

Ciljevi ovoga istraživanja su:

- Razvoj i validacija hibridnih optičko-empirijskih modela (PROSAIL+MLRA) strojnog učenja za modeliranje koncentracije klorofila u listovima i krošnjama hrasta lužnjaka napadnutih od hrastove mrežaste stjenice.
- Utvrditi pouzdanost multispektralnih snimaka u određivanju smanjenja koncentracije klorofila u odnosu na terestrička mjerena.
- Analizirati i kvantificirati prostorni raspored i stupanj smanjenja koncentracije klorofila uslijed infestacije 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

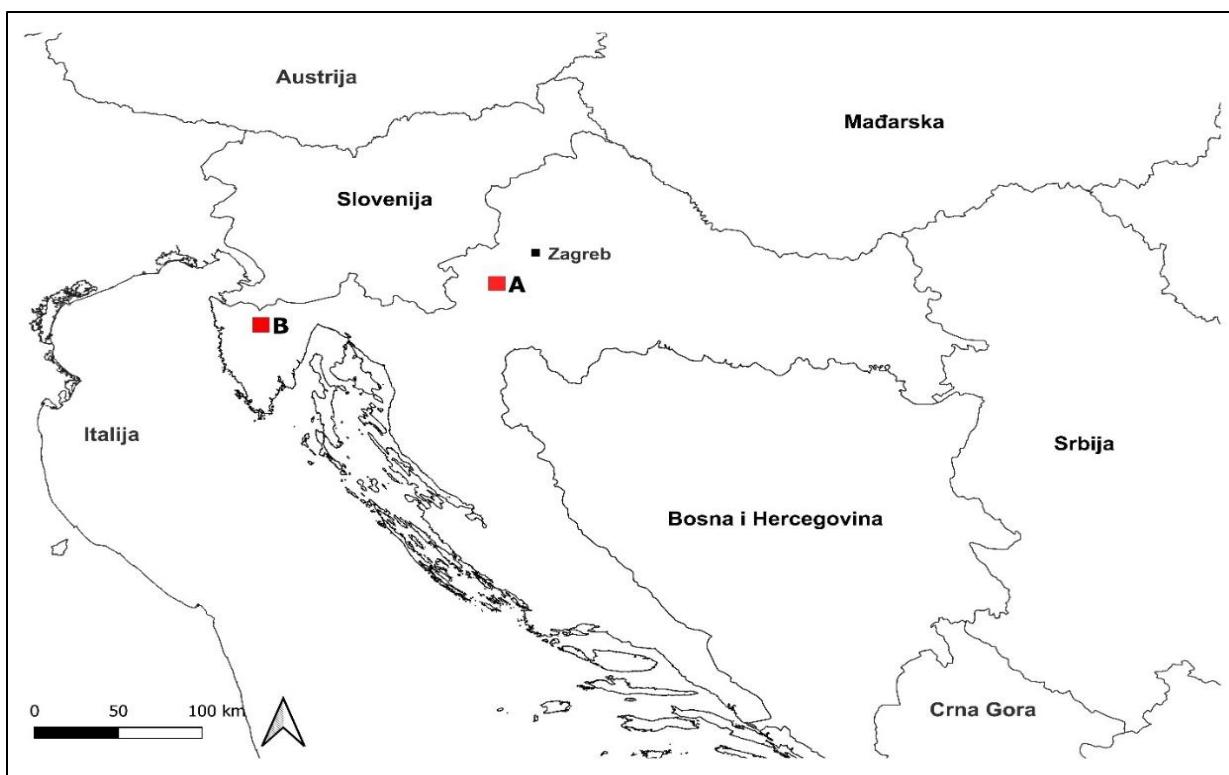
3.1. Područje istraživanja

Istraživanje je provedeno na dvije pokusne plohe smještene u sastojinama hrasta lužnjaka sa sličnim strukturnim karakteristikama (Tablica 1). Unutar svake pokusne plohe definirane su dodatne pod plohe na kojima su prikupljeni terenski podaci. Odabir sastojina proveden je korištenjem baze podataka Hrvatskih šuma, pri čemu su filtrirane one sastojine koje su zadovoljavale kriterije strukturalnih elemenata potrebnih za ovo istraživanje: starost, udio hrasta lužnjaka u smjesi i broja stabala po hektaru (N/ha). Prva ploha nalazi se na području Uprave šuma Karlovac (šumarija Jastrebarsko), gdje je prisutna HMS (dalje se u tekstu opisuje kao zaražena ploha), dok se druga ploha nalazi na području Uprave šuma Buzet (šumarija Buzet), gdje HMS nije zabilježena tijekom ovog istraživanja (u dalnjem tekstu se opisuje kao kontrolna ploha) (Slika 2).

Tablica 1 Osnovni sastojinski elementi istraživanih sastojina hrasta lužnjaka: zaražena ploha A (UŠP Karlovac, Šumarija Jastrebarsko) i kontrolna ploha B bez zaraze hrastovom mrežastom stjenicom (UŠP Buzet, Šumarija Buzet)

Ploha	Starost	Omjer hrasta lužnjaka	smjese (%)	Broj stabala	Vrsta tla	Ostale vrste stabala prisutne na plohi
				N/ha		
A	50 god.	53		270	Euglej amfiglej	Poljski jasen, Obični grab, OTB
B	65 god.	56		271	Aluvijalno	Poljski jasen, OTB

OTB: ostala tvrda bjelogorica



Slika 2 Geografska lokacija pokusnih ploha u Republici Hrvatskoj odabranih za istraživanje: Ploha A (zaražena hrastovom mrežastom stjenicom) na području UŠP Karlovac (šumarija Jastrebarsko) i Ploha B (kontrolna ploha bez zaraze) na području UŠP Buzet (šumarija Buzet)

Ploha u Jastrebarskom (Ploha A) (HTRS96 436668.44 E, 5053604.67 N) dio je dugotrajne plohe uspostavljene od strane znanstvenika sa Zavoda za uređivanje šuma Hrvatskog šumarskog instituta. Na ovoj plohi kontinuirano se prate izmjene ugljikova dioksida (CO_2) između šumskog ekosustava i atmosfere. Ploha se nalazi u gospodarskoj jedinici Jastrebarski lugovi. Ploha je prema Köppenovoj klasifikaciji, okarakterizirana kao umjereno toplo vlažna 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. Odsjeci pripadaju gospodarskom uredajnom 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 (*Genisto elatae-Quercetum roboris caricetosum remotae*). 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 (*Fraxinus angustifolia* Vahl) sa zastupljeniču do 30% i drvnom zalihom do 35,65 m³/ha, te obični grab (*Carpinus betulus* L.), koji zauzima 10-25% s drvnom zalihom do 37,26 m³/ha. Uz njih su prisutne i crna joha (*Alnus glutinosa* L.), nizinski briješ (*Ulmus minor* Mill.) te euroamerička topola (*Populus × canadensis* Moench).

Ploha u Motovunskoj šumi (ploha B)(HTRS96 295835.58 E, 5025651.99 N) nalazi se na području Uprave šuma Buzet, šumarija Buzet u gospodarskoj jedinici Mirna. Ploha je odabrana kao kontrolna u drugoj godini istraživanja jer na tom lokalitetu tijekom prve godine nije utvrđena prisutnost HMS. Ploha se nalazi u unutrašnjosti Istre i opisana je prema Koppenovoj klasifikaciji kao umjereno toplo vlažna s vrućim ljetima (Cfa). Odsjek 8a gospodareke jedinice Mirna u kojem je provedeno istraživanje 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 eksponicijom i minimalnim nagibom (0-1°). Tlo je aluvijalno, mineralno-močvarno, karbonatno, s mikrodepresijama. Fitocenozu čini šuma poljskog jasena i hrasta lužnjaka s visecim šašem (*Carici pendulae-Fraxinetum angustifoliae*), što pripada stanišnom tipu E.3.1. mješovite hrastovo-grabove i čiste grabove šume. U sloju drveća prevladavaju hrast lužnjak sa drvnom zalihom od 149,38 m³/ha i poljski jasen koji u omjeru smjese dolazi sa 27% i 71,56 m³/ha drvne zalihe, uz prisutnost klena (*Acer campestre* L.), briješta i običnog graba. Grmlje je slabo razvijeno, a čine ga glog (*Crataegus monogyna* L.), crni trn (*Prunus spinosa* L.), svib (*Cornus sanguinea* L.), drijen (*Cornus mas* L.) i kupina (*Rubus caesius* L.). U prizemnom sloju dominiraju mezofilne biljne vrste. Južni rub odsjeka prati staro korito rijeke Butonige.

3.2. Prikupljanje terenskih podataka

3.2.1. Vremenski period provedbe istraživanja

Terenska istraživanja provedena su tijekom tri uzastopne kalendarske godine (2021., 2022. i 2023.), u mjesecima svibnju, srpnju i rujnu, kako bi se obuhvatile faze razvoja HMS (Tablica 2). Nakon početne analize podataka prikupljenih u 2021. godini, identificirana je potreba za uključivanjem kontrolne plohe bez prisutnosti HMS-a, što je rezultiralo uspostavom Plohe B tijekom zimskog razdoblja 2021. godine.

Mjerenja su uključivala brojnost jajnih legala, koncentraciju klorofila na pojedinačnim listovima te multispektralne podatke prikupljene pomoću bespilotnih letjelica. Odabir vremenskih točaka omogućio je uvid u sezonske promjene fiziološkog odgovora stabala na zarazu i osigurao reprezentativnost podataka unutar svake godine u kojoj su provedena mjerenja.

Tablica 2 Pregled prikupljenih podataka te vremenskog perioda sakupljanja na zaraženoj plohi A u šumariji Jastrebarsko, Uprava šuma podružnica Karlovac i kontrolnoj plohi B u šumariji Buzet, Uprava šuma podružnica Buzet. U 2021. godini nisu prikupljani podaci na kontrolnoj plohi B.

Godina	2021		2022		2023	
Lokacija	Ploha A	Ploha B	Ploha A	Ploha B	Ploha A	Ploha B
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.

Pokusna ploha A, zahvaćena zarazom HMS, definirana je za potrebe ovog istraživanja tijekom zimskog razdoblja 2020. godine. Terenska mjerenja u prvoj godini provedena su isključivo na toj plohi. Nakon analize početnih rezultata, ukazala se potreba za uvođenjem kontrolne plohe bez prisutnosti zaraze (Ploha B), koja je definirana i uspostavljena tijekom zimskog razdoblja 2021. godine.

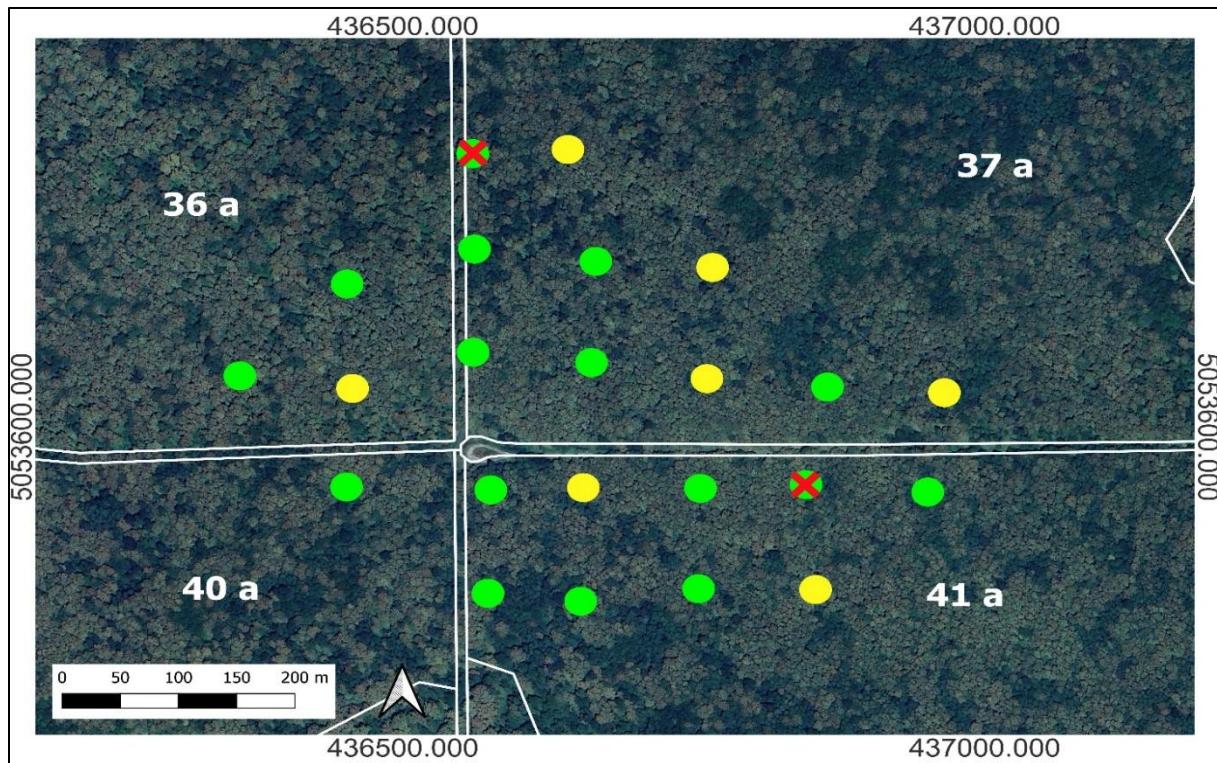
Unutar svake pokusne plohe A i B odabrane su pod plohe. Ukupno je odabранo 53 pod ploha, i to 23 pod plohe na Plohi A i 30 pod ploha na Plohi B. Na plohi A na sedam pod ploha uzorkovana su dva stabla hrasta lužnjaka. Veličina uzorka od 30 stabala odabrana je kako bi se postigla odgovarajuća statistička reprezentativnost, budući da se taj broj u literaturi često navodi kao minimalan prag pri kojem se prema centralnom graničnom teoremu rezultati mogu smatrati pouzdanim za većinu statističkih analiza (Kwak i Kim, 2017).

Precizne koordinate svakog stabla zabilježene su pomoću GNSS (prema engl. Global Navigation Satellite System) RTK (prema engl. Real Time Kinematic) uređaja STONEX S900 povezanim na CROPOSS (prema engl. CROatian POSitioning System) pozicijski sustav, odnosno VPPS

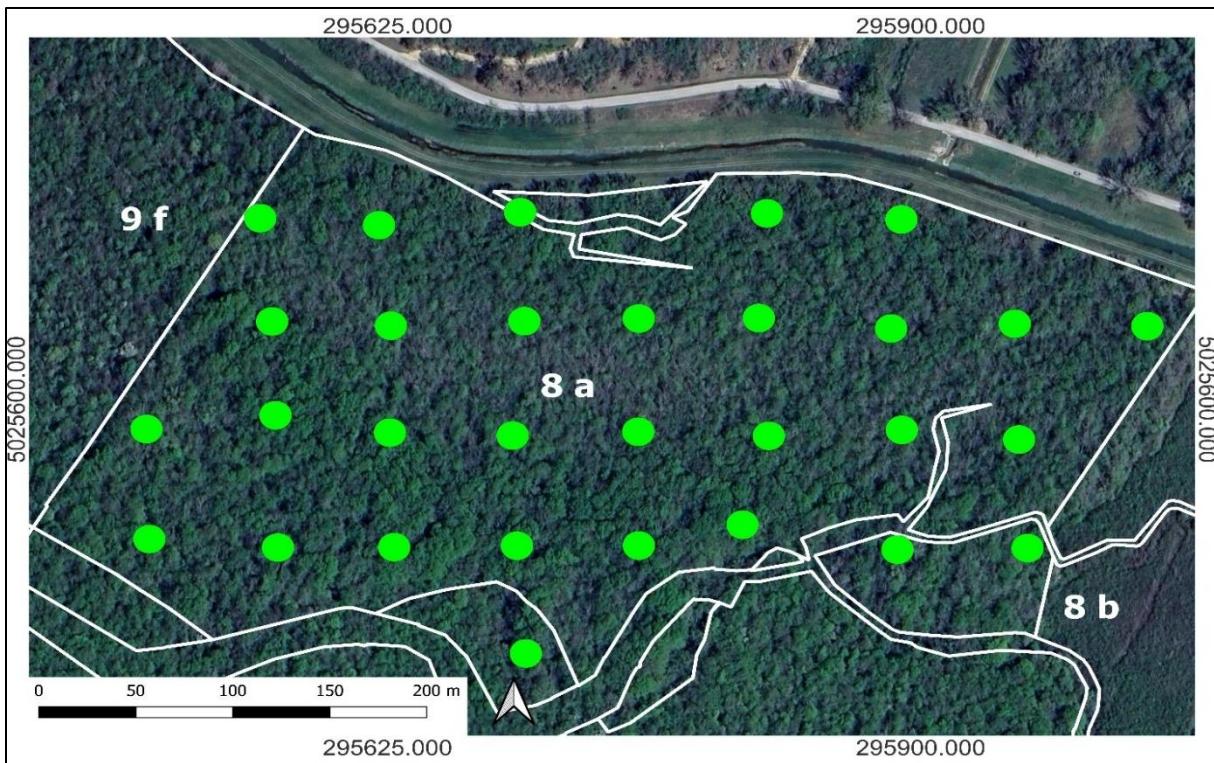
(visokoprecizni servis pozicioniranja u realnom vremenu) deklarirane točnosti 2 cm u horizontalnom i 4 cm u vertikalnom smjeru (vidi Slike 3 i 4). U ovom istraživanju korišten je službeni koordinatni sustav Republike Hrvatske - HTRS96/TM (EPSG:3765), koji se temelji na europskom koordinatnom sustavu ETRS89 (EPSG:4258).

Budući da razmještaj pod ploha na plohi B prethodno nije bio definiran kao što je na plohi A, njihov ravnomjeran prostorni raspored osiguran je korištenjem softvera QGIS 3.40 (QGIS Geographic Information System Developers Manual, 2025), kojim je izrađena mreža pod ploha koja pokriva cijelo istraživačko područje. Dobivene točke, predstavljene GPS koordinatama, poslužile su kao polazišta za uspostavu podplohi na terenu, čime je omogućena precizna i standardizirana terenska provedba uzorkovanja.

Na zaraženoj plohi (ploha A) postavljeni su temperaturni senzori marke Onset, model Hobo Pendant, kojima su tijekom cijelog razdoblja istraživanja kontinuirano bilježene vrijednosti temperature zraka u satnim intervalima. Ovi podaci korišteni su za analizu mikroklimatskih uvjeta i njihov potencijalni utjecaj na dinamiku zaraze hrastove mrežaste stjenice.



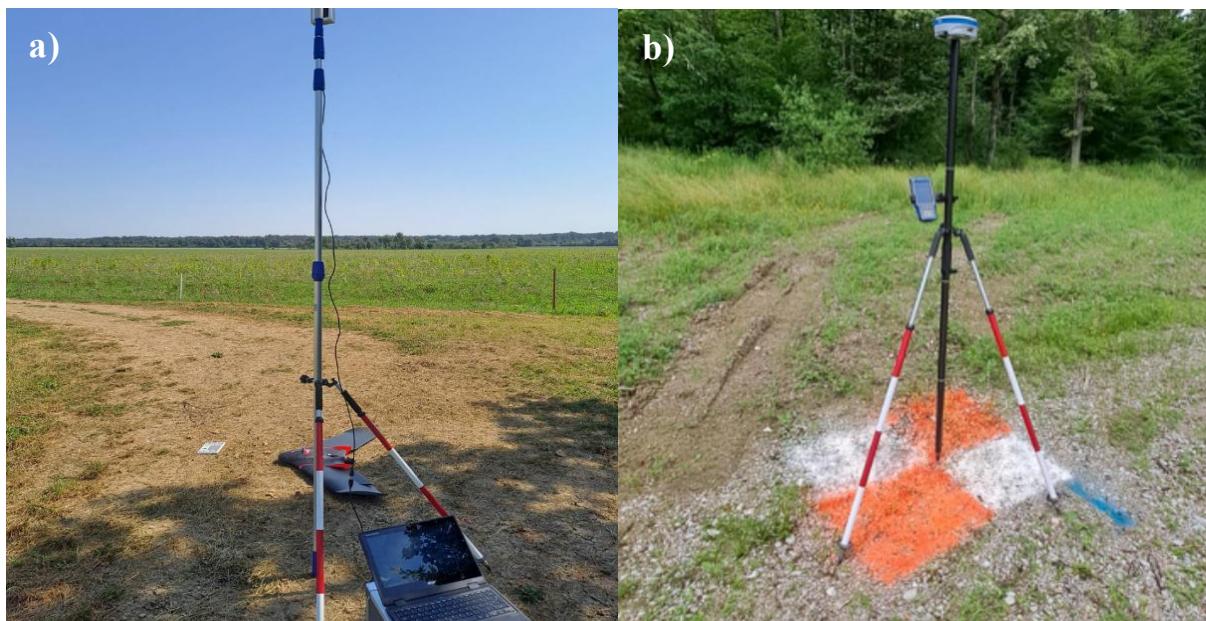
Slika 3 Prikaz prostornog rasporeda pod ploha na plohi A (sa zarazom hrastovom mrežastom stjenicom) u šumariji Jastrebarsko sa brojčano označenim odsjecima i koordinatnom mrežom. Crveno su označena mjesta na kojima su postavljeni temperaturni senzori. Žutom bojom su označene pod plohe na kojima su uzorkovana dva stabla hrasta lužnjaka, dok je na zelenim pod plohamama uzorkovano jedno stablo hrasta lužnjaka.



Slika 4 Prostorni raspored podploha na kontrolnoj plohi B (bez zaraze hrastovom mrežastom stjenicom) u šumariji Buzet, Uprave šuma podružnice Buzet sa označenim odsjecima

3.2.2. Prikupljanje podataka bespilotnom letjelicom

Prikupljanje podataka bespilotnom letjelicom provedeno je neposredno prije uzorkovanja lišća, tijekom istog tjedna kada su prikupljeni terenski podaci (Tablica 2). Time je osigurana vremenska usklađenost između spektralnih i terenskih mjerena. 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.



Slika 5 a) Bespilotna letjelica eBee SQ korišten za prikupljanje multispektralnih snimaka tijekom istraživanja; b) Proces prikupljanja terenskih kontrolnih točaka pomoću GNSS uređaja za precizno georeferenciranje snimaka prikupljenih bespilotnom letjelicom

Masa letjelice od 1,1 kg i brzina krstarenja od 11 do 30 m/s omogućuju učinkovito pokrivanje relativno velikih područja u kratkom vremenu. Maksimalno vrijeme leta od 55 minuta i nominalni domet radijske veze do 3 km (do 8 km u optimalnim uvjetima) omogućavaju provođenje detaljnih snimanja na udaljenim i teško pristupačnim šumskim površinama (Tablica 3).

Za potrebe prikupljanja snimki korišten je multispektralni senzor *Parrot Sequoia* (Parrot SA, Francuska), čije su tehničke karakteristike prikazane u Tablici 4. Senzor ima četiri spektralna kanala: zeleni (550 nm), crveni (668 nm), crveni rub (735 nm) i bliski infracrveni (790 nm). Odabran je jer pokriva ključna područja elektromagnetskog spektra bitna za procjenu koncentracije klorofila u listovima stabala.

U ovom istraživanju nisu korišteni vegetacijski indeksi, nego direktnе mape refleksije, zbog čega je izbor spektralnih kanala još važniji. Kanal crvenog ruba (*Red Edge*, 735 nm), zbog svoje uže širine kanala (10 nm), posebno je pogodan za određivanje finih promjena koncentracije klorofila, dok zeleni, crveni i bliski infracrveni kanal pružaju dodatne informacije potrebne za razvoj preciznih optičko-empirijskih modela.

Tablica 3 Tehničke specifikacije bespilotne letjelice s fiksnim krilom eBee SQ korištene za prikupljanje multispektralnih podataka

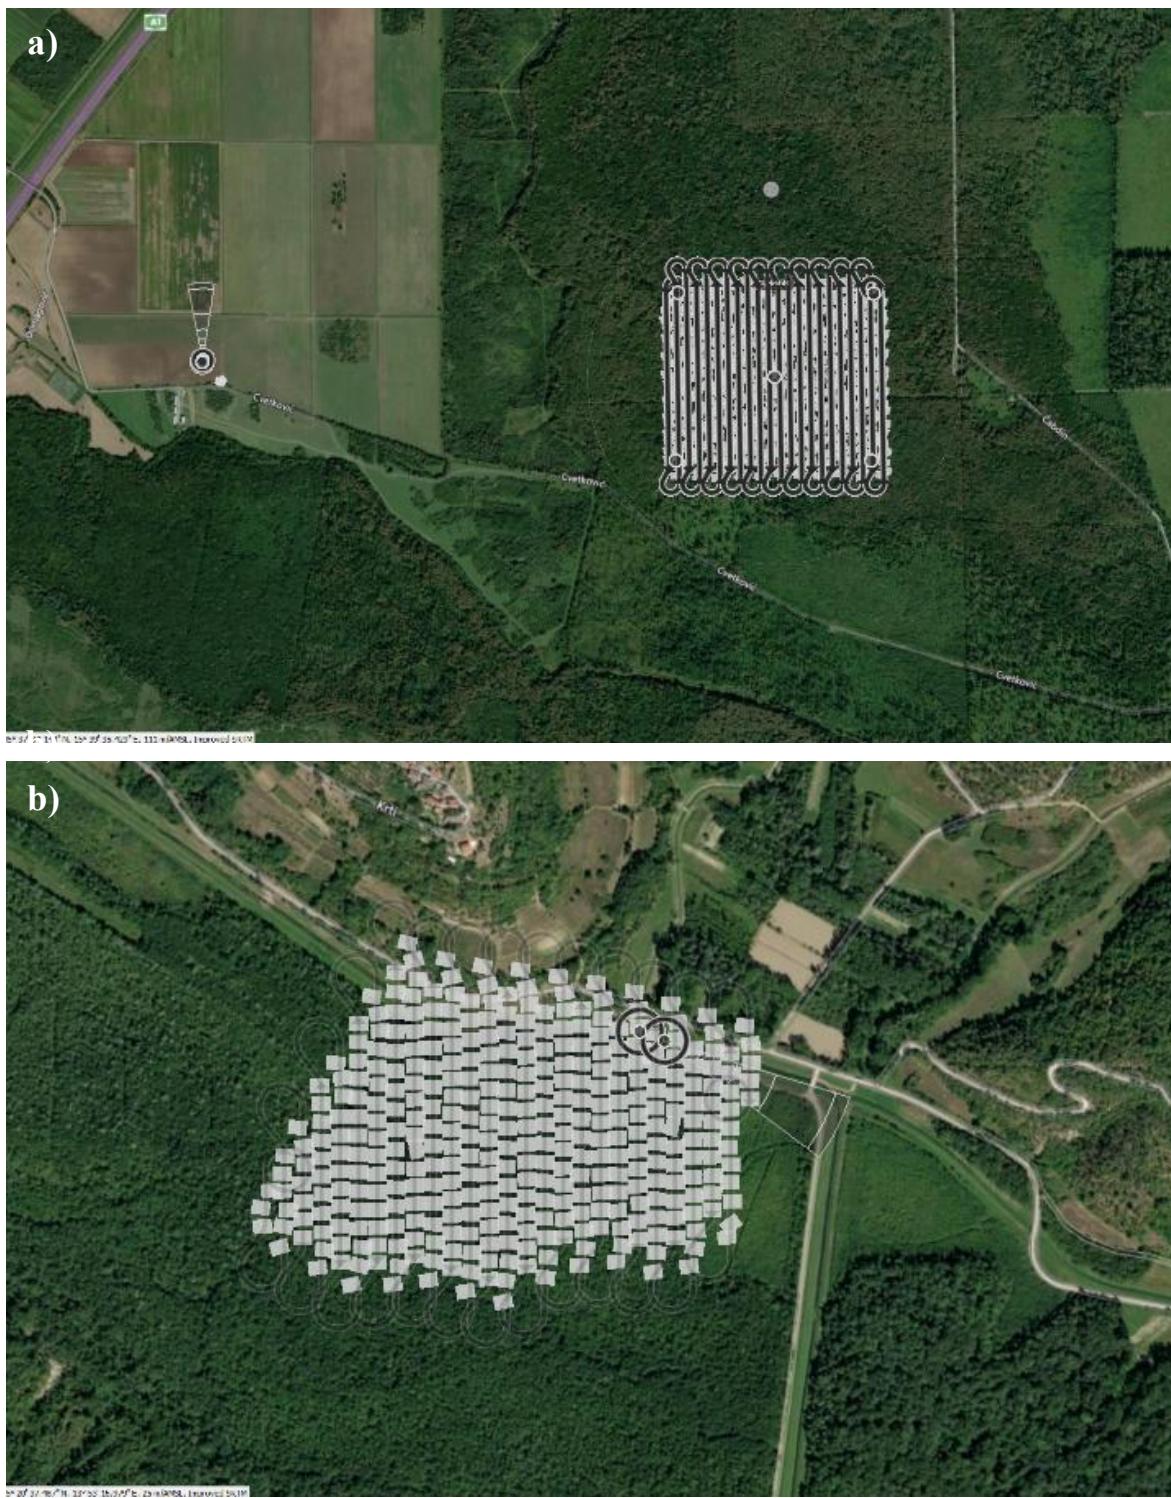
Specifikacija	Detalji
Težina	1,1 kg
Raspon radio veze	Nominalno 3 km (do 8 km u optimalnim uvjetima)
Maksimalno vrijeme leta	Do 55 minuta
Brzina krstarenja	11-30 m/s
Otpornost na vjetar	Do 12 m/s
Pokrovnost u jednom letu na 120 m visine	Do 200 ha
GSD multispektralno na 100 m	10 cm/piksel
GSD RGB na 100 m	3,1 cm/piksel

GSD multispektralno - prostorna razlučivost (od engl. *Ground Sampling Distance*) multispektralnog senzora pri visini leta od 100 m iznad tla
 GSD RGB - odnosi se na prostornu razlučivost standardne kamere koja snima u crvenom, zelenom i plavom spektru

Tablica 4 Spektralne karakteristike multispektralnog senzora *Parrot Sequoia* korištenog u istraživanju: nazivi kanala, centralne valne duljine i širine spektralnih kanala (nm)

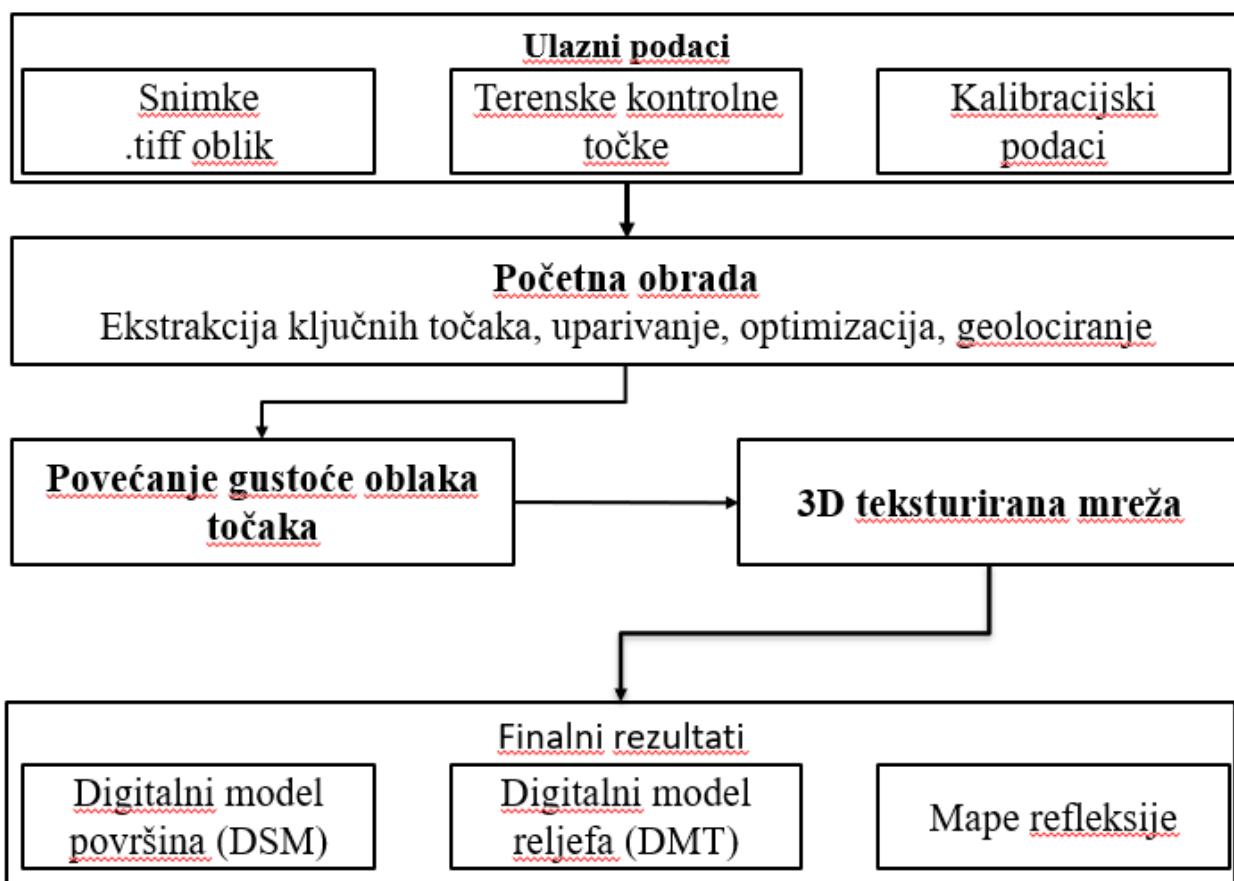
Kanal	Centralna valna duljina (nm)	Širina kanala (nm)
Zeleni (G)	550	40
Crveni (R)	668	40
Crveni rub (Red Edge)	735	10
Bliski infracrveni	790	40

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 snimljen kalibracijski panel, a dobiveni podaci su kasnije upotrijebljeni za radiometrijsku kalibraciju snimaka. Planiranje i provedba leta napravljeni su pomoću softvera eMotion AG, pri čemu su definirani ključni parametri leta kako bi se osigurala preciznost i usporedivost prikupljenih podataka. Tijekom svakog leta, bespilotna letjelica je održavala konstantnu visinu od 100 m iznad razine tla, uz zadani poprečni preklop od 75% i uzdužni preklop od 80% (Slika 6). Ovi parametri postavljeni su kako bi se osigurala visoka pokrivenost i ista prostorna rezolucija od 10 cm na obje plohe. Ploha A obuhvaćala je površinu od 39 ha, dok je ploha B imala površinu od 15,4 ha. Ploha B je imala manju površinu jer je cijelu plohu činio samo jedan odsjek, koji je bio odabran kako bi bio što sličnijih karakteristika s plohom A.

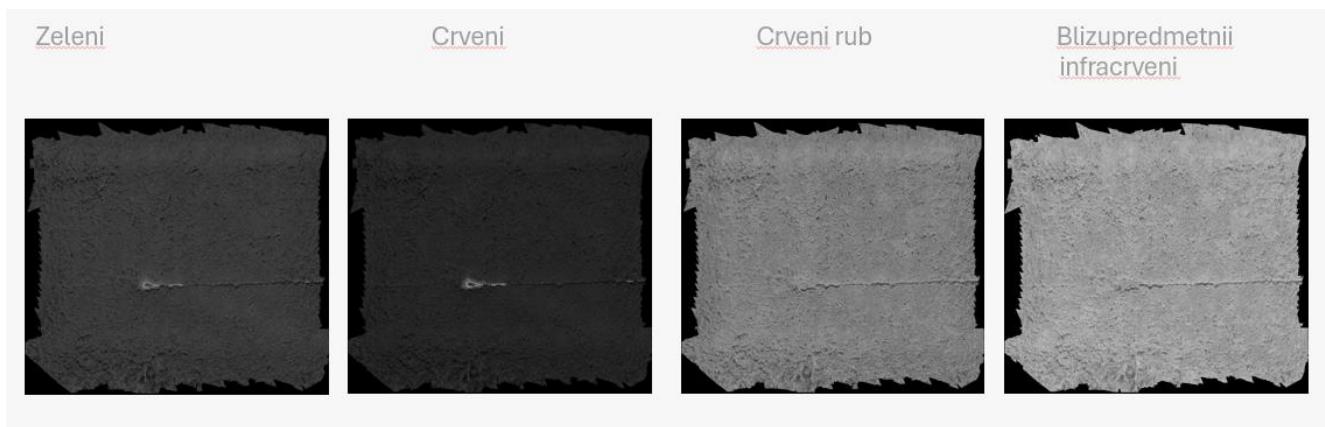


Slika 6 Prikaz sučelja programske podrške eMotion AG korištene za planiranje leta bespilotne letjelice eBee SQ opremljene multispektralnom kamerom s označenim položajima prikupljanja pojedinačnih snimaka na (a) plohi A i (b) plohi B

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. 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. Proces obrade podataka unutar Pix4D prikazan je na Slici 7, a u Prilogu 1 prikazano je sučelje programske podrške za svaki korak obrade snimaka.

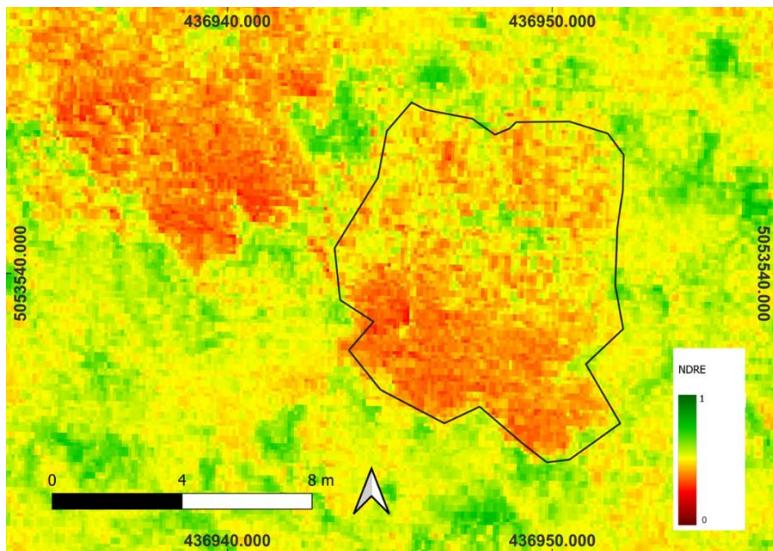


Slika 7 Dijagram toka obrade podataka unutar programske podrške Pix4D. Prikazan je detaljan slijed radnih koraka od ulaznih podataka do finalnih rezultata



Slika 8 Primjer mapa refleksije pojedinih kanala izrađenih obradom podataka pomoću Pix4D programa, korištenih za analizu koncentracije klorofila

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. Na Slici 9 prikazan je primjer jedne pod plohe s jasno vidljivom ručno definiranom krošnjom stabla hrasta lužnjaka i pripadajućim vegetacijskim indeksom normalizirane razlike crvenog ruba (NDRE, prema engl. *Normalized difference red edge*), koji je korišten kao jedan od ulaznih parametara za izračun indeksa površine lista.

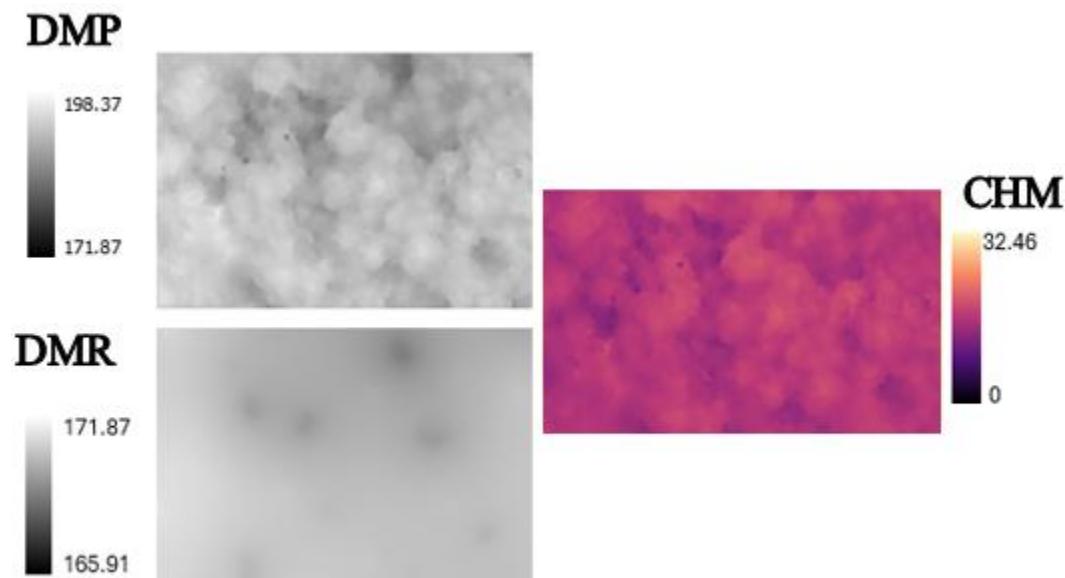


Slika 9 Prikaz ručno delineirane krošnje stabla hrasta lužnjaka (*Quercus robur*) na ortomozaiku normalizirane razlike crvenog ruba (NDRE) vegetacijskog indeksa. Zeleno označava više vrijednosti (bliže 1) koje upućuju na viši sadržaj klorofila i zdraviju vegetaciju, dok crveno označava niže vrijednosti (bliže 0) koje ukazuju na fiziološki stres i potencijalno oštećeno lišće.

Kako bi se uklonio utjecaj tla na refleksijske vrijednosti na multispektralnim snimkama, analiza je ograničena na područja iznad 10 m visine pomoću modela visine krošnje (CHM, prema engl. *Canopy height model*). CHM, kao što je prikazano na Slici 10, se računa kao razlika između digitalnog modela površine (DMP) i digitalnog modela terena (DMT), čime se dobiva stvarna visina vegetacije iznad tla, kako prikazuje Formula (1):.

$$CHM = DMP - DMT \quad (1)$$

Primjenom CHM-a omogućeno je fokusiranje isključivo na krošnje stabala, eliminirajući refleksijske smetnje uzrokovane tlom i nižim slojevima vegetacije. Takav pristup osigurava da analizirani spektralni podaci odražavaju isključivo fiziološke i strukturne karakteristike krošnji.



Slika 10 Prikaz digitalnog modela površine (DMP), digitalnog modela terena (DMT) i rezultirajućeg modela visine krošnje (CHM). DMP(u rasponu od 171.87-198.37 m) prikazuje ukupne visine površinskih objekata u ovom slučaju krošnje te tlo, dok DMT prikazuje konfiguraciju samog tla (u rasponu od 165.91-171.87 m).

3.2.3. Izmjera koncentracije klorofila u listovima

Uzorkovanje listova provedeno je pomoću prilagođene arborističke praćke i pripadajuće opreme (Slika 11), dizajnirane za jednostavno prikupljanje uzoraka s različitih visina krošnje. Listovi su uzorkovani s tri strane svijeta svakog stabla (sjever, jug, i istok) kako bi se obuhvatile varijacije u izloženosti svjetlosti. Sa svake orientacije prikupljeno je po 50 listova, na kojima su zatim provedena mjerena koncentracije klorofila klorofilmetrom. Ukupno je uzorkovano 150 listova po stablu, odnosno 4.500 listova po terenskoj kampanji na plohi (Tablica 2).



Slika 11 Specijalizirana arboristička praćka i dodatna oprema korištena za prikupljanje uzoraka listova hrasta lužnjaka iz gornjih dijelova krošnji za terenska mjerena koncentracije klorofila
Za određivanje relativne količine prisutnog klorofila korišten je klorofilmetar Konica Minolta SPAD 502, koji mjeri apsorpciju svjetlosti u listu 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 povezano s boljim fiziološkim stanjem biljke (Uddling i dr. 2007).

SPAD mjerena su izvršena na tri različita mjesta radi povećanja točnosti, pri čemu su izbjegnute glavne žile i jajna legla HMS. Referentna SPAD vrijednost je bila aritmetička sredina tri mjerena na pojedinom listu te je ona upisivana u terenski obrazac. 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 kojim nema zaraženosti, te za validaciju modela korištenih u ovom istraživanju.

Kako bi se iz SPAD vrijednosti dobila koncentracija klorofila u listu (LCC od eng. *Leaf chlorophyll content*), izražena u $\mu\text{g}/\text{cm}^2$, korištena je prilagođena eksponencijalna formula izvedena iz kalibracijskog skupa podataka specifičnog za hrast lužnjak. Formula za konverziju je:

$$LCC = 0.1719e^{0.0355SPAD} \quad (2)$$

Formula 2 za konverziju SPAD vrijednosti u LCC preuzeta je iz Brown i dr. (2022). Ova kalibracijska formula razvijena je regresijskom analizom na temelju destruktivno određenih laboratorijskih mjerena koncentracije klorofila (izvučenog iz listova različitih listopadnih vrsta drveća) uspoređenih sa SPAD vrijednostima (Brown i dr. 2022). Budući da u ovom istraživanju nisu provedena laboratorijska određivanja klorofila ekstrakcijom, formula je izravno preuzeta iz navedene literature i primijenjena za hrast lužnjak. Time je procijenjena koncentracija klorofila bez potrebe za laboratorijskim postupcima koji zahtijevaju dodatne resurse i vrijeme. Dobivene vrijednosti su u gramima po metru kvadratnom (g/m^2) te je izvršena konverzija u mikrograme po centimetru ($\mu\text{g}/\text{cm}^2$) kvadratnom radi lakše interpretacije u modelu.

Kako bi se dobio uvid u ukupnu količinu klorofila prisutnog u krošnji, pojedinačne vrijednosti LCC nadopunjene su informacijama o strukturnoj gustoći krošnje. U tu svrhu, izračunata je koncentracija klorofila u krošnji (CCC, prema engl. Canopy chlorophyll content) kao umnožak LCC i indeksa lisne površine (LAI), prema Formuli 3:

$$CCC = LCC \times LAI \quad (3)$$

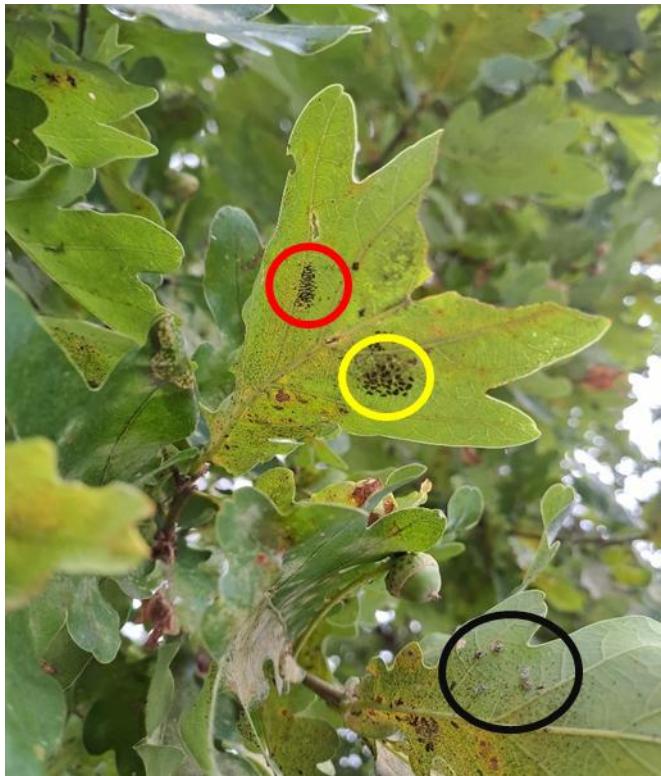
CCC predstavlja ukupnu količinu klorofilnih pigmenata (klorofil-a i klorofil-b) u krošnji po jedinici površine tla (npr. mg/m²). Njegova vrijednost ovisi o koncentraciji klorofila u listu i ukupnoj lisnoj površini krošnje, koja se izražava putem LAI. Klorofil omogućuje odvijanje fotosinteze pa njegova raspodjela unutar krošnje izravno određuje koliko će biljka biti produktivna i kako će funkcioništati ekološki procesi u šumskim ekosustavima (Gitelson i dr. 2005). Dobivene CCC vrijednosti (izražene u µg/cm²) omogućuju kvantifikaciju fiziološke aktivnosti vegetacije na razini krošnje, uzimajući u obzir i strukturalne karakteristike sklopa. Budući da optički senzori na bespilotnim letjelicama detektiraju isključivo refleksiju svjetlosti s gornjeg sloja vegetacijskog pokrova, CCC se koristi kao agregirani pokazatelj ukupnog klorofila u krošnji, čime se omogućuje dosljedna procjena stanja šumskog ekosustava kroz prostor i vrijeme.

3.2.4. Izmjera broja jajnih legala HMS

U ovom istraživanju brojanje jajnih legala HMS primijenjeno je kao indirektna metoda procjene razine zaraze. Iako su jajna legla brojane izravno na listovima, metoda je indirektna jer ne uključuje brojanje ličinki (nimfi) ili odraslih stadija štetnika, već se oslanja na njihov ovipozicijski trag kao pokazatelj prisutnosti i intenziteta zaraze (Pearson i dr., 2002). Takav pristup uobičajen je u biološkom monitoringu pokretnih ili kriptičnih (morphološki neodvojivih) vrsta kod kojih je terensko brojanje odraslih jedinki ili nimfi otežano (Beumier i dr., 2021, Oswalt i dr., 2021).

Brojanje je provedeno na ukupno 150 listova hrasta lužnjaka na kojima je prethodno mjerен SPAD indeks kao mjera relativnog sadržaja klorofila. Na istim listovima, s donje strane, vizualno su identificirane i prebrojane sve jasno razgraničene skupine jaja. Skupine su se nalazile pretežno uz glavne lisne žile, gdje ženke HMS najčešće polažu jaja. Za svaki list hrasta upisan je točan broj jajnih legala u terenski obrazac.

Vizualna razlika između jajnih legala i početnih razvojnih stadija HMS-a je prikazana na Slici 12, gdje su skupine jaja označene crveno, a nimfe žuto. Ovaj prikaz pokazuje da je moguće razlikovati jajna legla od početnih razvojnih stadija HMS tijekom terenskog uzorkovanja, čime se osigurava točnost brojanja.



Slika 12 Prikaz lista hrasta lužnjaka sa označenim jajnim leglima (crveno), nimfama (žuto) i adultima (crno) hrastove mrežaste stjenice. Na listu su jasno vidljiva jajna legla hrastove mrežaste stjenice (HMS), smještena uz glavne lisne žile. Uz njih su prikazane i nimfe, kako bi se vizualno istaknula razlika između jajnih legala HMS i početnih razvojnih stadija HMS-a

Brojanje jajnih legala u ovom istraživanju omogućio je kvantitativnu analizu zaraze HMS te su ti podaci dalje korišteni u modeliranju utjecaja HMS na koncentraciju klorofila.

3.2.5. Prikupljanje podataka o temperaturi

U svrhu praćenja mikroklimatskih uvjeta važnih za razvoj HMS temperaturni podaci su prikupljani pomoću automatskih senzora Hobo Pendant (Onset Computer Corporation), s točnošću mjerjenja $\pm 0,53^{\circ}\text{C}$. Senzori su postavljeni u vrhove krošnja stabala na plohi A, kako bi se dobili precizni podaci iz neposrednog okoliša gdje se odvijaju ključne životne aktivnosti stjenice, uključujući polaganje jajašaca i razvoj ličinki. Ova pretpostavka temelji se na vlastitim terenskim opažanjima u okviru ovog istraživanja. Dva senzora postavljena su na prostorno udaljene pod plohe, čime je omogućen prostor za prostornu interpolaciju podataka.

Za prostornu ekstrapolaciju podataka na cijelu plohu korištena je geostatistička metoda običnog kriginga (engl. *ordinary kriging*). Ova metoda omogućuje izračun procijenjenih vrijednosti temperature na lokacijama bez senzora, temeljem prostorne autokorelacije među izmjerenim točkama, uzimajući u obzir varijaciju i udaljenost između točaka. Za razliku od jednostavnijih metoda (npr. linearne interpolacije), "kriging" osigurava statistički optimalne, nepristrane procjene, što ga čini pogodnim za ekološke primjene s ograničenim brojem senzora (Vedurmudi i dr., 2023).

Unatoč ograničenom broju senzora, njihov strateški raspored i kvaliteta podataka omogućili su dovoljnu razinu prostorne rezolucije, osobito kada je cilj dobiti temperaturni profil ključnih mikrolokacija u krošnjama, koje su relevantne za modeliranje populacijske dinamike *C. arcuata*. Slične metode interpolacije već su se pokazale učinkovitima u analizi okolišnih podataka s ograničenim brojem mjernih točaka (Li i dr., 2022)

Na temelju mjerjenja temperature izračunati su stupnjevi-dani (DD, od engl. *Degree days*) koji predstavljaju akumuliranu toplinsku energiju dostupnu organizmima. Za izračun DD korištena je metodologija koja je ranije primijenjena na HMS (Bălăcenoiu i dr., 2021) (Formula 4)

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

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

3.3. Metode obrade podataka i modeliranja

3.3.1. Procjena indeksa lisne površine korištenjem vegetacijskog indeksa i modela visine krošnje

Indeks površine lista (LAI, od engl. *Leaf area index*) 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).

LAI za obje plohe izračunat je indirektnom metodom prema Moon i dr. (2018) (Formula 5). Procjena LAI-a je jedan od osnovnih ulaznih parametara PROSAIL modela, koji nije bio izravno izmjerен na terenu. LAI djeluje kao faktor skaliranja između razine lista i razine krošnje te je nužan za točnu kvantifikaciju ukupne koncentracije klorofila u krošnji.

$$LAI = 1.837 + 0.836 \times (NDRE \times CHM) \quad (5)$$

Gdje je LAI - indeks površine lista; NDRE – vegetacijski indeks i CHM - model visine krošnje.

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:

$$NDRE = \frac{NIR-RED\ EDGE}{NIR+REDEEDGE} \quad (6)$$

Kombinacijom NDRE i CHM u formuli za izračun LAI integriraju se spektralne informacije povezane s fiziološkim stanjem lisne mase (NDRE) te strukturni podaci o visini i gustoći krošnje (CHM). Koristeći snimke prikupljene bespilotnom letjelicom, prvo su kreirane NDRE i CHM snimke, te su potom LAI vrijednosti očitane na mjestima terenskih mjerjenja klorofila lista.

3.3.1. Modeliranje povezanosti broja jajnih legala i akumuliranog stupnja dana

Kako bi se analizirala povezanost između zaraze HMS, temperature i LCC provedena je regresijska analiza s ciljem utvrđivanja da li se na temelju broja jajnih legala HMS-a i akumuliranih DD može predvidjeti koncentracija klorofila. Analiza je temeljena na skupu od 360 mjeranja provedenih na Plohi A tijekom tri godine (2021., 2022. i 2023. godina). Vrijednosti akumuliranih stupnjeva dana (DD) i brojnost jajnih legala HMS-a izmjerene u svibnju korištene su za predviđanje LCC u srpnju, dok su podaci prikupljeni u srpnju korišteni za predviđanje koncentracije klorofila u rujnu iste godine.

Za izradu regresijskih modela korištene su biblioteke programskog jezika Python (Van Rossum, 2009), konkretno scikit-learn. Regresijska analiza obuhvatila je tri varijable: jednu zavisnu varijablu (izmjerene vrijednosti koncentracije klorofila - LCC na terenu) te dvije nezavisne varijable (izmjerene vrijednosti akumuliranih stupanj-dana - DD i broj jajnih legala HMS-a), pri čemu su sve tri varijable prikupljene s Plohe A (Tablica 2).

Korištена su dva pristupa regresijskom modeliranju za predviđanje koncentracije klorofila na temelju DD-a i broja jajnih legala: višestruka linearna regresija kao jednostavniji linearni pristup, te Random Forest (RF) kao složeniji, nelinearni pristup temeljen na metodama strojnog učenja. Višestruka linearna regresija generirana je korištenjem modula sklearn.linear_model, dok je Random Forest model generiran primjenom modula sklearn.ensemble. Odabir RF modela omogućio je analizu složenijih i nelinearnih odnosa između ulaznih varijabli (DD i broj jajnih legala) i LCC, osobito za razdoblja kada terenska mjerena nisu bila dostupna.

Performanse modela procijenjene su pomoću standardnih metrika: koeficijenta determinacije (R^2) i korijena srednje kvadratne pogreške (RMSE), implementiranih u modulu sklearn.metrics. Vrijednosti LCC dobivene RF regresijskim modelom služile su isključivo za procjenu potencijala predviđanja na temelju broja jajnih legala i akumuliranih temperaturnih sumi (DD), a u svim dalnjim fazama hibridnog modeliranja PROSAIL+GPR korišteni su isključivo stvarni, terenski izmjereni rasponi LCC. Detaljan opis korištenja PROSPECT i PROSAIL modela dan je u sljedećem pod poglavljju (3.3.2).

3.3.2. Uporaba samostalnih regresijskih modela (MLRA) i hibridnog pristupa PROSAIL + MLRA u ARTMO okruženju

Automated Radiative Transfer Models Operator (ARTMO), razvijen u MATLAB okruženju, predstavlja sveobuhvatnu platformu za modeliranje vegetacijskih parametara kombinacijom fizikalnih modela i metoda strojnog učenja. U ovom istraživanju ARTMO je korišten za tri pristupa:

- (1) samostalno regresijsko modeliranje (MLRA)
- (2) hibridni pristup koji kombinira PROSAIL s regresijskim algoritmima strojnog učenja (PROSAIL + MLRA) (Verrelst i dr. 2012; Caicedo i dr. 2014)

ARTMO je alatni okvir unutar MATLAB programskog rješenja 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) koristeći podatke iz 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 posljednjih 12-tak godina razvoj ARTMO-a se temelji na integraciji PROSAIL s naprednim MLRA u hibridne modele (PROSAIL + MLRA), uključujući metode za interpretaciju podataka daljinskog istraživanja i rezultata kao što su razina klorofila krošnje. Grafički prikaz koraka obrade podataka u ARTMO prikazan je u Prilogu 2.

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 (Tablica 5). U korisničkom sučelju ARTMO alatnog okvira za RTM raspon vrijednosti je definiran te su generirana dva uzorka za svaki ulazni parametar. 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 prostorno-

vremenskim uvjetima područja istraživanja, uzimajući u obzir geografsku širinu i dužinu lokacije, kao i konkretne datume i doba dana tijekom kojih su provedena terenska mjerjenja.

Korišteni su stvarno izmjereni podaci o LCC i procijenjenom LAI, koji su prikupljeni na terenu u svibnju, srpnju i rujnu za svaku plohu zasebno. Za svaki mjesec izrađena je odgovarajuća pregledna tablica (LUT) u PROSAIL modelu, u kojoj su uneseni stvarni izmjereni rasponi biofizičkih parametara specifičnih za određeno razdoblje i lokalitet. Preostali ulazni parametri, kao što su struktura lista, sadržaj vode i tvari te varijable povezane s geometrijom snimanja i svjetlinom tla, uzimani su iz literature i kalibrirani prema stvarnim uvjetima na terenu.

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 mjerjenja, kako bi se osigurala točnost generiranih podataka za analizu.

Tablica 5 Ulagani biofizički i atmosferski parametri korišteni u simulacijama modela prijenosa radijacije lista (PROSPECT4) i modela prijenosa radijacije krošnje (4SAIL). Prikazani rasponi (minimalne i maksimalne vrijednosti) predstavljaju stvarno korištene ulagane parametre tijekom simulacija za plohe A i B u svibnju, srpnju i rujnu sumarno tokom istraživanog razdoblja 2021., 2022. i 2023. godine

PROSPECT4	Mjerna jedinica	Parametri ploha A			Parametri ploha B		
		Svibanj	Srpanj	Rujan	Svibanj	Srpanj	Rujan
Struktura lista	N	1-1.5	1.5-2	1.2-1.7	1.5-2	2-2.5	1.5-2
Koncentracija klorofila	µg/cm ²	20-40	30-50	10-30	30-50	50-70	20-40
Voda u listu	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
Suha tvar	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
<hr/>							
4SAIL							
LAI		2-3	4-6	3-4	2-3	4-6	3-4
Efekt žarišne točke		0.0015- 0.0035	0.006	0.0051	0.0015- 0.0035	0.006	0.0051
Prosječan kut lista	°	30-40	20-30	25-35	30-40	20-30	25-35
Kut zenita sunca	°	36-37	33-34	50-51	36-37	34-35	54-55
Difuzna direktna radijacija		30-50	25-40	35-55	30-50	25-40	35-55
Zenitni kut promatrača	°	0-10	0-10	0-10	0-10	0-10	0-10
Koeficijent svjetline tla		0.10- 0.15	0.15-0.25	0.15- 0.25	0.1-0.25	0.2-0.4	0.2-0.4
Relativni azimut	°	129- 130	123-124	141- 142	124-125	122-123	141-142

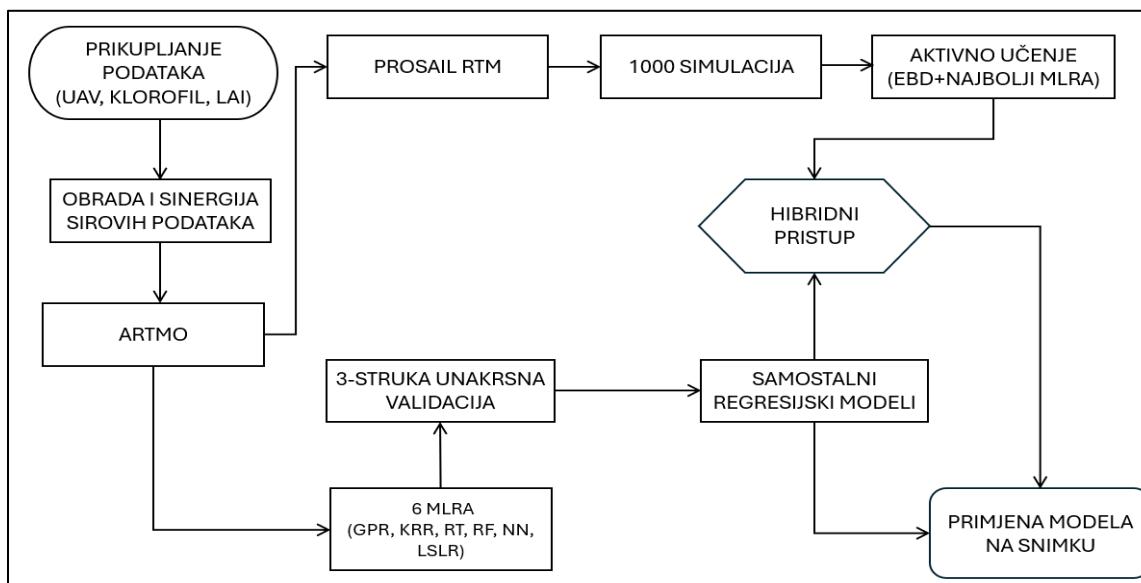
U okviru LUT metode inverzije, PROSAIL model generira sintetsku bazu podataka simulacijom spektralnih refleksija za sve kombinacije ulaznih parametara vegetacije (Tablica 5). Svaka kombinacija parametara, uključujući LAI, sadržaj klorofila, strukturu krošnje i optička svojstva lista, koristi se u izračunima koji stvaraju referentnu tablicu spektralnih odgovora. Ta tablica potom služi za inverziju stvarnih refleksijskih podataka u cilju procjene biokemijskih i biofizičkih svojstava vegetacije (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 promatranim spektralnim refleksijama daljinskih mjerena (snimke bespilotne letjelice). Nesigurnost koja se može pojaviti kod mnogobrojnih simulacija u LUT u sklopu pretraživanja je "problem slabo postavljenih sustava" (*ill-posed problems*), što se događa kada postoje različite kombinacije parametara vegetacije koje proizvode istu simulaciju refleksije. Da bi se taj efekt umanjio ili spriječio, ARTMO uključuje uzorkovanje početnih uzoraka i takozvano aktivno učenje (AL, od engl. *Active learning*), koje koristi algoritme strojnog učenja kako bi optimizirao procjenu biokemijskih varijabli poput LAI i sadržaja klorofila. Rezultati aktivnog učenja prikazani su u Prilogu 3.

Za generiranje početnih uzoraka korištena je metoda *Latin Hypercube Sampling* (LHS) s 1000 uzoraka, čime je osigurana reprezentativna 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 uzorce, 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 odabirom najboljih uzoraka iz simulacija temeljen je na Euclidovoj udaljenosti (EBD) i Gaussian processes regresion (GPR).

Nakon toga, dobiveni uzorci korišteni su za treniranje MLRA u sklopu hibridne metode (PROSAIL + MLRA), povećavajući točnost regresijskih algoritama (Verrelst i dr. 2021) tako što je iz LUT odabran broj uzoraka koji ima najmanji RMSE, čije su vrijednosti određene unutar ARTMO platforme na grafičkim prikazima (Prilog 1). Parametri senzora su ručno postavljeni za MLRA kako bi odgovarali četirima kanalima senzora Parrot Sequoia korištenog u ovom istraživanju. Procesirani podaci prikupljeni bespilotnom letjelicom korišteni su u ARTMO za

kreiranje mapa krošnje klorofila, što je jedan od glavnih ciljeva ovoga istraživanja. Svaka optičko reflektivna vrijednost sa snimaka prikupljenih bespilotnom letjelicom je upotrebom PROSAIL+MLRA preračunata u vrijednosti CCC.

Proces metoda modeliranja je prikazan na Slici 13.



Slika 13 Detaljni dijagram toka koji prikazuje metodologiju prikupljanja, obrade podataka te postupak modeliranja koncentracije klorofila korišten u istraživanju

Jedan od alata ARTMO softverskog paketa su algoritmi regresije strojnim učenjem (MLRA, od engl. *Machine Learning Regression Algorithms*), 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, tj. projekciju krošnje pod ploha na plohamu A i B. Za svaki poligon izračunate su srednje, maksimalne i minimalne vrijednosti refleksije pri čemu je za reprezentativan uzorak uzeto 50% srednjih vrijednosti, 40% maksimalnih i 10% minimalnih vrijednosti kako bi se osigurala ravnoteža između dominantnih i ekstremnih vrijednosti u podacima.

Analiza je primarno provedena odvojeno za zaraženu plohu A i kontrolnu plohu B, kako bi se omogućila preciznija identifikacija lokalnih obrazaca u prostornoj distribuciji CCC u odnosu na razinu zaraze. U drugom koraku, prikazanom u Prilogu 4, provedena je i analiza na kombiniranim podacima s obje plohe, kako bi se ispitao učinak heterogenosti okoline i testirala robustnost modela na širem skupu podataka.

MLRA modeli trenirani su izravno na CCC vrijednostima (koje su prethodno izračunate kao umnožak LCC i LAI). Modeliranje je provedeno na razini CCC-a, a ne na razini LCC-a koji bi se naknadno morao množiti s LAI. Takav pristup omogućio je jasnije povezivanje spektralnih informacija s ukupnim sadržajem klorofila u krošnji te bolju interpretabilnost rezultata i usporedbu. Modeli su validirani pomoću k-struke unakrsne validacije ($k=3$), čime se osigurava pouzdana procjena točnosti i smanjuje rizik od prekomjernog prilagođavanja modela podacima. Točnost modela procijenjena je statističkim parametrima (R^2 i RMSE) za svaku plohu (A i B) zasebno za svaki mjesec posebno (svibanj, srpanj i rujan). Kontrolna ploha (B) u ovoj analizi korištena je kao pokazatelj sposobnosti modela da razlikuje zaražena od zdravih stabala, dok je zaražena ploha A primarni predmet analize. Prikazani rezultati MLRA za pojedine mjesece (svibanj, srpanj, rujan) odnose se na podatke prikupljene tijekom istih mjeseci kroz tri godine (2021., 2022. i 2023. godina).

Osim toga, u skup podataka unutar ARTMO dodano je 10 referentnih vrijednosti spektralne refleksije tla, generiranih pomoću alata "*Label me*" kako bi se povećala heterogenost i realističnost simulacija. U modeliranju vegetacije putem modela poput PROSAIL-a, tlo je važan čimbenik jer znatno utječe na ukupnu refleksiju krošnje, osobito u slučajevima kada je vegetacijski pokrov rjeđi (npr. niži LAI). 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* (LSLR), *Neural network* (NN), *Random forest* (RF) i *Regression tree* (RT). Njihove osnovne karakteristike prikazane su u Tablici 6. MLRA s najboljim prediktivnim karakteristikama u ovom procesu korišteni su u hibridnom PROSAIL modeliranju kako bi se ispitala učinkovitost hibridnog PROSAIL+MLRA modeliranja u usporedbi s samostalnim regresijskim modeliranjem.

Tablica 6 Pregled korištenih algoritama regresije strojnim učenjem u analizi podataka: opis glavnih karakteristika i referenca

<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 (RF)</i>	Ensemble metoda učenja koja koristi skup stohastički generiranih regresijskih stabala za donošenje predikcija. Svako pojedinačno stablo trenira se na nasumično	Breiman 2001

odabranom podskupu podataka i značajki, čime se smanjuje osjetljivost na šum i preprilagodbu. Konačna predikcija dobiva se prosjekom predikcija svih stabala u šumi

Regression

tree

(RT)

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.

4. REZULTATI

4.1 Terenska mjerena

4.1.1. Procjena indeksa lisne površine (LAI)

Indirektna procjena LAI provedena je na temelju multispektralnih podataka prikupljenih na zaraženoj plohi A i kontrolnoj, nezaraženoj plohi B. Mjerena su obuhvatila tri vegetacijska perioda (svibanj, srpanj i rujan) 2021., 2022. i 2023. godine. Za Plohu A dostupni su podaci za sve tri godine (2021., 2022. i 2023.), dok su za Plohu B procjene LAI-a provedene samo za 2022. i 2023. godinu s obzirom na dostupnost podataka.

U svibnju 2022. i 2023. godine zabilježene su razlike u vrijednostima LAI između istraživanih ploha. Ploha A imala je niže vrijednosti LAI u usporedbi s Plohom B u svibnju 2022. i 2023. godine, pri čemu je ta razlika bila izraženija 2022. godine (Tablica 7). U 2021. godini podaci su prikupljeni isključivo na Plohi A, te nije bilo moguće usporediti plohe. Prosječne vrijednosti LAI na razini pod ploha, uključujući standardnu devijaciju (SD) kao mjeru varijabilnosti, prikazane su u Tablici 7.

Tablica 7 Vrijednosti indeksa lisne površine ($LAI \pm SD$) za Plohu A i Plohu B tijekom svibnja 2021., 2022. i 2023. godine

Godina	Ploha A ($LAI \pm SD$)	Ploha B ($LAI \pm SD$)
2021.	2.51 ± 0.23	–
2022.	2.89 ± 0.43	3.44 ± 0.80
2023.	2.36 ± 0.20	3.37 ± 0.91

U srpnju su vrijednosti LAI dosegnule svoje najviše vrijednosti, osobito na Plohi B. Ploha A imala je niže vrijednosti u svim godinama kada su provedena mjerena.

Tablica 8 Vrijednosti indeksa lisne površine ($LAI \pm SD$) za Plohu A i Plohu B tijekom srpnja 2021., 2022. i 2023. godine

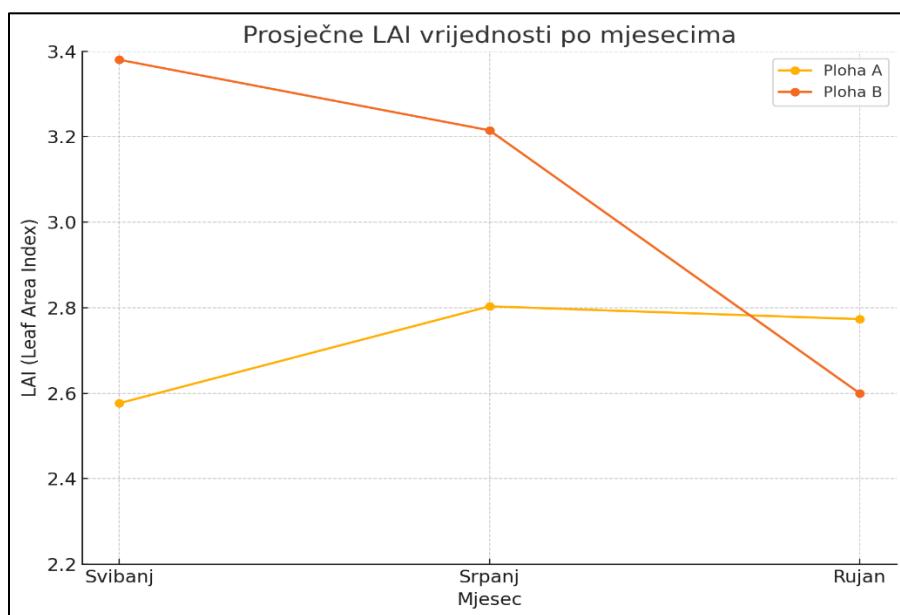
Godina	Ploha A ($LAI \pm SD$)	Ploha B ($LAI \pm SD$)
2021.	3.04 ± 0.41	–
2022.	2.73 ± 1.00	3.75 ± 0.88
2023.	2.50 ± 0.11	2.81 ± 0.21

U rujnu 2022. godine Ploha A imala je viši LAI od Plohe B, dok je 2023. godine zabilježena obrnuta situacija, s višim LAI na Plohi B (Tablica 9.)

Tablica 9 Vrijednosti indeksa lisne površine (LAI \pm SD) za Plohu A i Plohu B tijekom rujna 2021., 2022. i 2023. godine

Godina	Ploha A (LAI \pm SD)	Ploha B (LAI \pm SD)
2021.	3.03 \pm 0.19	—
2022.	3.90 \pm 0.90	2.60 \pm 0.21
2023.	2.37 \pm 0.08	2.82 \pm 0.12

Prosječne vrijednosti indeksa lisne površine (LAI) bile su niže na zaraženoj Plohi A u usporedbi s kontrolnom Plohom B u svibnju i srpnju, dok je u rujnu vrijednost LAI na Plohi B manja od vrijednosti na Plohi A (Slika 14). Najveća razlika zabilježena je u svibnju. Statistička analiza potvrdila je značajnu razliku između ploha A i B ($t = -2.85$, $p = 0.012$), što ukazuje na mjerljivu promjenu u količini lisne mase.



Slika 14 Usporedba prosječnih vrijednosti indeksa lisne površine (LAI) između zaražene plohe A (Šumarija Jastrebarsko) i kontrolne plohe B (Šumarija Buzet) tijekom mjeseca svibnja, srpnja i rujna u razdoblju od 2021. do 2023. godine

4.1.2. Rezultati izmjere koncentracije klorofila u listovima i krošnjama hrasta lužnjaka

Terenska mjerena LCC i podaci prikupljeni bespilotnom letjelicom korišteni su za kreiranje MLRA, s ciljem procjene CCC. Vrijednosti CCC izračunate su kao umnožak terenski izmjerene LCC vrijednosti i LAI, čime se dobiva integrirana procjena ukupne količine klorofila u krošnji po jedinici površine. Tijekom svibnja, srpnja i rujna), prosječne vrijednosti LCC-a bile su više na Plohi B u usporedbi s Plohom A (Tablica 10). Veći broj uzoraka na Plohi A rezultat je činjenice da Ploha B nije bila uključena u istraživanje tijekom 2021. godine. Rezultati t-testa pokazali su statistički značajne razlike u prosječnim vrijednostima LCC između ploha A i B u svim analiziranim mjesecima (svibanj, srpanj i rujan) tokom razdoblja istraživanja 2021., 2022. i 2023. godine. U svim slučajevima p-vrijednosti su bile manje od 0,05, što upućuje na značajne razlike u koncentraciji klorofila između ploha.

Tablica 10 Deskriptivna statistika koncentracije klorofila lista (LCC) izmjerene na terenu za zaraženu plohu A (Šumarija Jastrebarsko) i kontrolnu plohu B (Šumarija Buzet) tijekom svibnja, srpnja i rujna u razdoblju 2021., 2022. i 2023. godine. Veličina uzorka predstavlja broj pod ploha na kojima su provedena mjerena LCC-a, pri čemu je za svaku pod plohu korišten prosjek vrijednosti izmjerenih na 150 listova.

Mjesec	Ploha	Veličina uzorka	Prosjek LCC ($\mu\text{g}/\text{cm}^2$)	Standardna devijacija ($\mu\text{g}/\text{cm}^2$)	Min LCC ($\mu\text{g}/\text{cm}^2$)	Max LCC ($\mu\text{g}/\text{cm}^2$)
Svibanj	A	249	29,41	10,24	1,67	51,88
	B	90	53,35	8,38	34,84	69,62
Srpanj	A	249	37,88	11,36	9,21	66,00
	B	180	60,70	15,08	34,96	101,79
Rujan	A	270	34,32	11,21	7,88	94,25
	B	180	52,50	14,87	25,67	84,03

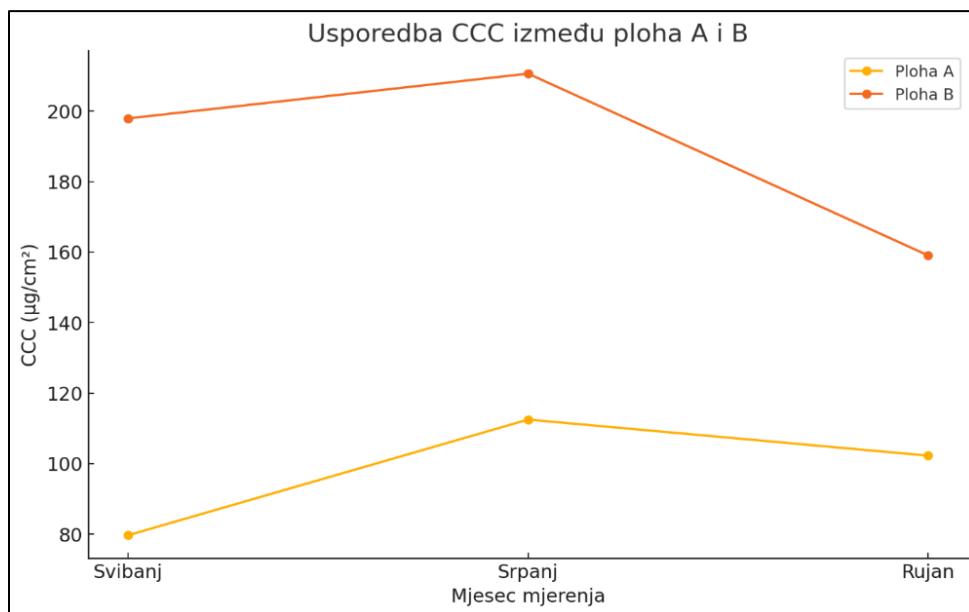
U svibnju, na plohi A ($N = 249$), prosječna vrijednost LCC iznosila je 29,41 ($SD = 10,24$), s minimalnom izmjereno vrijednošću od 1,67 i maksimalnom od 51,88. Na plohi B ($N = 90$), prosječna vrijednost bila je 53,35 ($SD = 8,38$), uz raspon od 34,84 do 69,62.

U srpnju, ploha A ($N = 249$) imala je prosječnu vrijednost LCC od 37,88 ($SD = 11,36$), s rasponom od 9,21 do 66,00, dok je ploha B ($N = 180$) pokazala višu prosječnu vrijednost od 60,70 ($SD = 15,08$), uz minimalnu izmjerenu vrijednost od 34,96 i maksimalnu od 101,79.

U rujnu, broj uzoraka na plohi A iznosio je 270, s prosječnim LCC od 34,32 (SD = 11,21) te rasponom od 7,88 do 94,25. Na plohi B (N = 180), prosječna vrijednost LCC bila je 52,50 (SD = 14,87), s minimalnom vrijednošću od 25,67 i maksimalnom od 84,03.

Na temelju Formule 3 izračunata je CCC za pod plohe na plohi A tijekom 2021., 2022., 2023 godine, dok je za plohu B CCC na pod plohamama izračunat za 2022. i 2023. godinu. Vrijednosti CCC omogućuju prostorno i vremenski usporediv prikaz promjena u ukupnom sadržaju klorofila u krošnji, pri čemu se istodobno uvažava fiziološko stanje listova i strukturalna gustoća vegetacije. Prikazani rezultati temelje se na kombinaciji terenskih LCC mjerjenja i LAI vrijednosti dobivenih iz multispektralnih podataka prikupljenih bespilotnom letjelicom na razini pod ploha na plohamama A i B.

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. Razlika između ploha prisutna je u svim fazama vegetacije, a najveća se razlika bilježi u svibnju i srpnju (Slika 15).



Slika 15 Usporedba koncentracije klorofila krošnje (CCC) na razini pod ploha za svibanj, srpanj i rujan između zaražene plohe A (šumarija Jastrebarsko) i kontrolne plohe B (šumarija Buzet) tijekom istraživanog razdoblja (2021., 2022. i 2023. godina)

4.1.3. Rezultati utjecaja temperature i broj jajnih legala na koncentraciju klorofila lista

Za analizu utjecaja temperature i prisutnosti hrastove mrežaste stjenice na koncentraciju klorofila u listu korišteni su akumulirani stupanj-dani (DD) i broj jajnih legala po listu, prikupljeni na Plohi A tijekom svibnja i srpnja 2021., 2022. i 2023. godine. Prikupljeni podaci korišteni su na način da su podaci LCC, broj jajnih legala i DD prikupljeni u svibnju služili kao prediktori za srpanjske vrijednosti LCC, dok su srpanjski podaci korišteni kao prediktori za rujanske vrijednosti LCC. Na taj način, analiziran je učinak broja jajnih legala i DD na LCC, pri čemu su rujanske LCC vrijednosti korištene isključivo kao ciljne varijable u regresijskim modelima.

U srpnju su vrijednosti DD-a bile veće (prosjek 751,87) u odnosu na svibanj (205,98), uz širi raspon i veću varijabilnost (DD 31,42 naspram 7,80). Broj jajnih legala u prosjeku se nije promijenio između mjeseci, no standardna devijacija (SD) i raspon bili su veći u srpnju (SD 7,21) u usporedbi sa svibnjem (SD 6,00) (Tablica 11)

Tablica 11 Deskriptivna statistika okolišnih parametara na zaraženoj plohi A u šumariji Jastrebarsko: vrijednosti stupnjeva-dana i broja jajnih legala tijekom svibnja i srpnja, korištenih kao prediktori u regresijskim analizama

Parametar	Svibanj	Srpanj
Srednja vrijednost stupanj dana	205,98	751,87
Minimalna vrijednost stupanj dana	196,04	685,43
Maksimalna vrijednost stupanj dana	220,63	779,98
Standardna devijacija stupanj dana	7,80	31,42
Prosječan broj jaja u leglu	8,95	9,10
Minimalni broj jaja u leglu	0,00	0,00
Maksimalni broj jaja u leglu	41,00	37,00
Standardna devijacija broja jaja u leglu	6,00	7,21

Iz podataka prikazanih u Tablici 11 može se vidjeti 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, kako je očekivano, prosjek stupnjeva-dana značajno veći (oko 752), dok raspon ide od 685 do 780, uz nešto veću standardnu devijaciju (31,42).

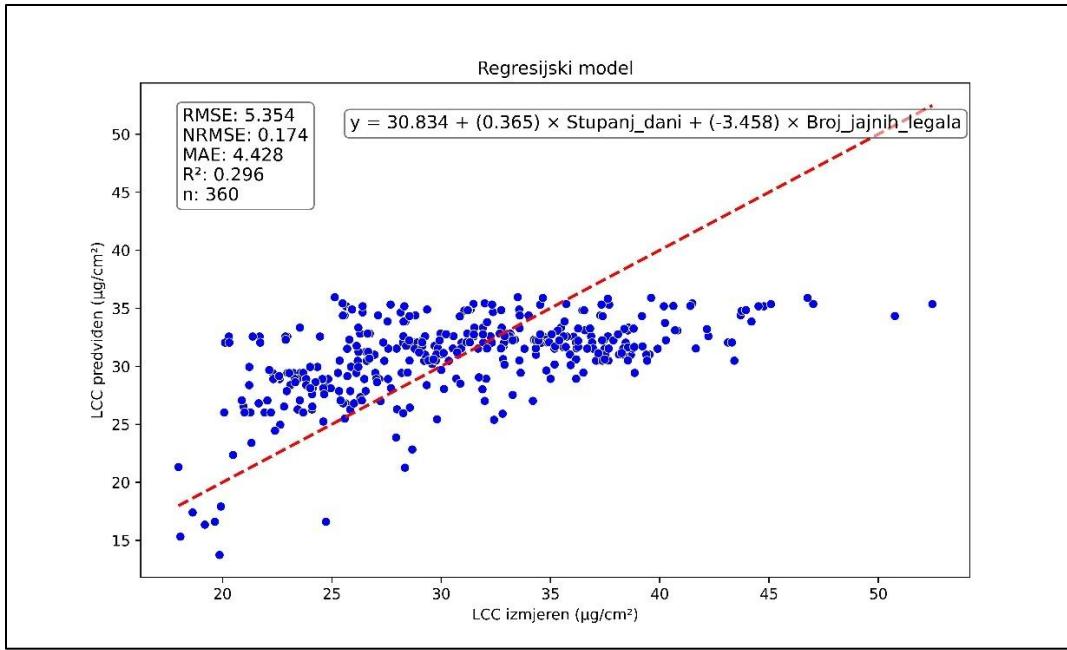
Broj jajnih legala bilježi blagi porast od svibnja do srpnja (Tablica 11). Prosječna vrijednost u svibnju je 8,95, a u srpnju 9,09. Maksimalne vrijednosti iznose 41 u svibnju i 37 u srpnju.

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.

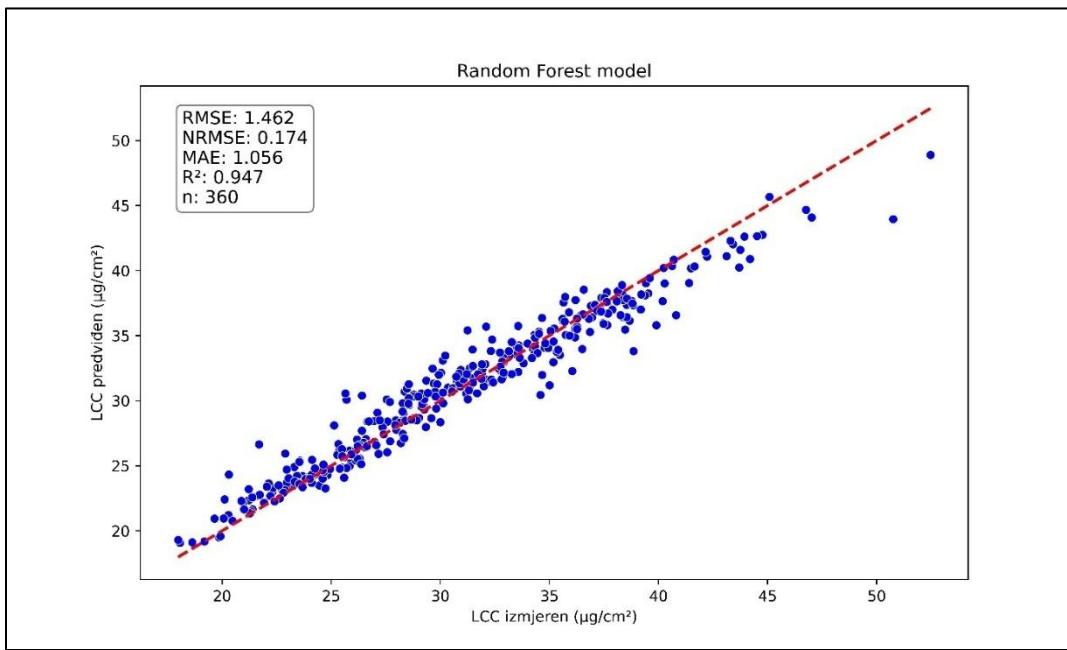
Linearni regresijski model pokazuje slabu sposobnost objašnjavanja varijance u koncentraciji klorofila, s koeficijentom determinacije (R^2) od 0,296. Procijenjena vrijednost korijena srednje kvadratne pogreške (RMSE) iznosila je 5,354, što ukazuje na značajnu razliku između predviđenih i stvarnih vrijednosti koncentracije klorofila (Slika 16).

Random forest (RF) model ostvaruje veću točnost u odnosu na linearnu regresiju. Ovaj model skoro u potpunosti obuhvaća nelinearne odnose između ulaznih varijabli i koncentracije klorofila, što rezultira izuzetno visokim koeficijentom determinacije ($R^2=0,95$) i nižim RMSE vrijednostima (RMSE=1,46). Većina mjerenih i simuliranih vrijednosti nalazi se blizu 1:1 linije (Slika 17).

S obzirom na rezultate dobivene primjenom Random Forest regresijskog modela, cilj analize bio je procijeniti koliko se dobro modelirane vrijednosti LCC, temeljene na DD i broju jajnih legala, podudaraju s terenski izmjerenim vrijednostima. Iako je ovaj model pokazao zadovoljavajuću razinu podudarnosti, u hibridnom modeliranju PROSAIL+GPR nije se koristila simulirana LCC, već stvarni rasponi izmjerениh LCC vrijednosti.



Slika 16 Usporedba između koncentracije klorofila u listu (LCC) izmjerene na terenu i vrijednosti LCC-a procijenjene pomoću modela višestruke linearne regresije s tri ulazne varijable: koncentracija klorofila (LCC), stupanj-dana (SD) vrijednosti refleksije i broj jajnih legala za plohu A



Slika 17 Grafički prikaz rezultata nelinearnog modela strojnog učenja Random Forest korištenog za predviđanje koncentracije klorofila temeljem akumuliranih stupanj-dana (SD) i broja jajnih legala hrastove mrežaste stjenice za plohu A

4.2. Rezultati analize samostalnih regresijskih algoritama strojnog učenja

Analiza prostorne distribucije klorofila provedena je primjenom samostalnih regresijskih algoritama strojnog učenja (MLRA) u sklopu ARTMO alatnog okvira, a sumarni prikaz rezultata prikazan je u Tablici 12. Mapirane vrijednosti CCC pokazale su jasne prostorne razlike između ploha, kao i unutar pojedinih ploha, u sva tri razdoblja u kojima su sakupljeni podaci (svibanj, srpanj, rujan) između 2021. i 2023. godine. Dodatno, u prilogu 4 prikazani su korelacijski dijagrami te prostorna distribucija CCC na kombiniranim podacima sa obje plohe kao usporedba pristupa.

Tablica 12 Rezultati Gaussian Processes Regression (GPR) modela unutar ARTMO MLRA alata, koji je u ovom istraživanju pokazao najbolje performanse tijekom svih analiziranih mjeseci (svibanj, srpanj, rujan) u razdoblju 2021.–2023. godine. Prikazana je osnovna metrika preciznosti modela: RMSE (korijen srednje kvadratne pogreške), NRMSE (normalizirani RMSE) i koeficijent determinacije (R^2), zasebno za svaku plohu i mjesec tokom istraživanog razdoblja.

Mjesec	Ploha	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE ($\mu\text{g}/\text{cm}^2$)	R^2
Svibanj	A	16,43	10,38	0,83
	B	74,72	15,41	0,45
Srpanj	A	28,23	10,33	0,73
	B	47,19	8,90	0,81
Rujan	A	33,09	9,93	0,45
	B	62,04	11,25	0,45

Za Plohu A, model je postigao najvišu točnost u svibnju, s RMSE-om od $16,43 \mu\text{g}/\text{cm}^2$ i $R^2 = 0,83$, dok su u srpnju i rujnu R^2 vrijednosti bile nešto niže (0,73 i 0,45). Na Plohi B, zadovoljavajući rezultat ostvaren je u srpnju ($R^2 = 0,81$), dok su u svibnju i rujnu zabilježene niže vrijednosti točnosti ($R^2 = 0,45$ za oba mjeseca) (Tablica 12).

4.2.1. Predviđanja sadržaja klorofila krošnje za svibanj

U mjesecu svibnju za period u kojem je provedeno istraživanje 2021., 2022. i 2023. godine, rezultati modeliranja CCC prikazani u Tablici 13 pokazuju da GPR model postiže zadovoljavajuće performanse među analiziranim modelima za zaraženu plohu A. GPR je ostvario najnižu pogrešku ($RMSE = 16,43 \mu\text{g}/\text{cm}^2$), najmanji NRMSE (10,38%) i najviši koeficijent determinacije ($R^2 = 0,83$), što ukazuje da model objašnjava 83% ukupne varijabilnosti u izmjer enim vrijednostima CCC-a.

KRR (Kernel Ridge Regression) za istu plohu bilježi $RMSE = 19,89 \mu\text{g}/\text{cm}^2$, $NRMSE = 12,57\%$ i $R^2 = 0,74$, dok Random Forest (RF) model pokazuje blago slabije performanse s $RMSE = 20,99 \mu\text{g}/\text{cm}^2$, $NRMSE = 13,27\%$ i $R^2 = 0,72$. Neural Network (NN) i Random Trees (RT) modeli ostvaruju iste vrijednosti koeficijenta determinacije ($R^2 = 0,63$), no uz veće pogreške ($RMSE$ od $24,07 \mu\text{g}/\text{cm}^2$ i $25,22 \mu\text{g}/\text{cm}^2$, te $NRMSE$ $15,21\%$ i $15,93\%$, redom). LSLR (Least Squares Linear Regression) pokazuje najslabije performanse za plohu A s $RMSE = 25,84 \mu\text{g}/\text{cm}^2$, $NRMSE = 16,32\%$ i $R^2 = 0,57$ (Tablica 13).

Tablica 13 Usporedba učinkovitosti različitih regresijskih modela strojnog učenja (MLRA) u procjeni koncentracije klorofila krošnje (CCC) za svibanj u istraživanom periodu između 2021.-2023.godine na ploham A i B: prikaz pogreške kvadratne sredine (RMSE), relativne pogreške (NRMSE) i koeficijenta determinacije (R^2)

MLRA	Ploha A			Ploha B		
	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE (%)	R^2	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE (%)	R^2
GPR	16,43	10,38	0,83	74,72	15,41	0,45
KRR	19,89	12,57	0,74	90,15	18,59	0,31
RF	20,99	13,27	0,72	70,62	14,56	0,48
NN	24,07	15,21	0,63	87,15	17,98	0,31
RT	25,22	15,93	0,63	75,86	15,65	0,45
LSLR	25,84	16,32	0,57	69,32	14,30	0,50

Na kontrolnoj plohi B, najbolju ukupnu točnost pokazao je LSLR, s najnižim vrijednostima pogrešaka ($RMSE = 69,32 \mu\text{g}/\text{cm}^2$; $NRMSE = 14,30\%$) i najvišim koeficijentom determinacije ($R^2 = 0,50$).

Random Forest (RF) model također je ostvario visoku razinu točnosti, s $R^2 = 0,48$ i $RMSE = 70,62$

$\mu\text{g}/\text{cm}^2$, vrlo blizu rezultatima LSLR-a, ali s nešto višim NRMSE-om (14,56%). GPR postigao je nešto niži R^2 (0,45) i veće pogreške (RMSE = $74,72 \mu\text{g}/\text{cm}^2$; NRMSE = 15,41%) u odnosu na LSLR i RF.

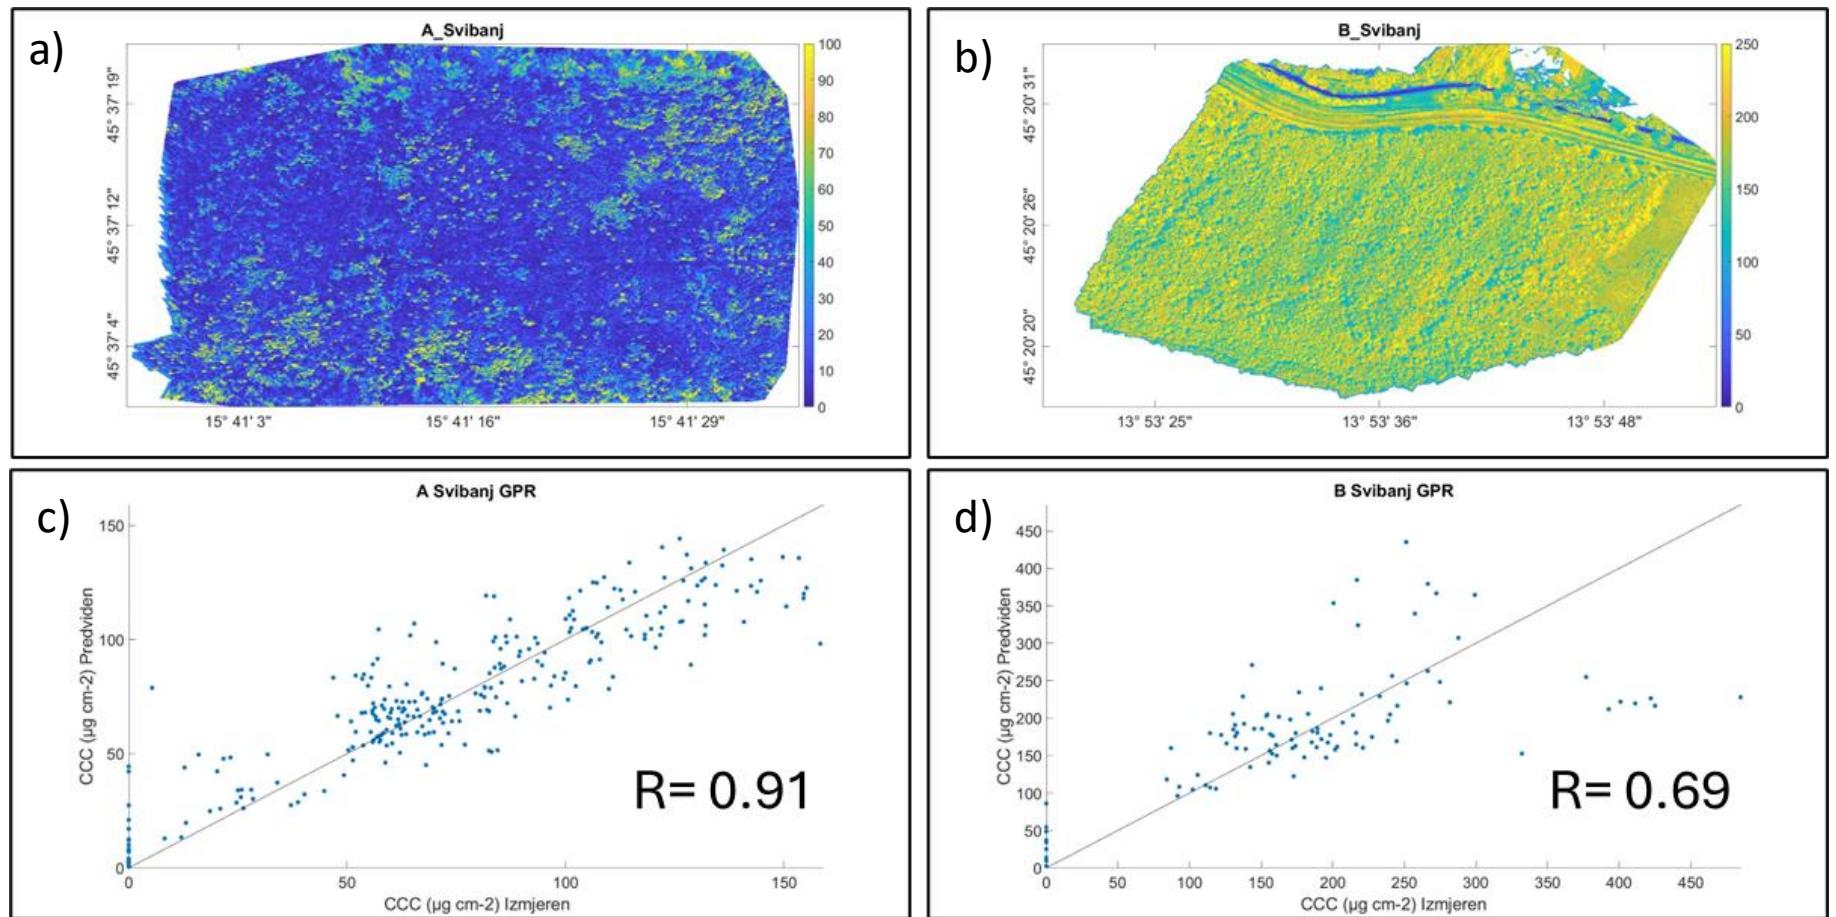
Ostali modeli, uključujući Kernel Ridge Regression (KRR), Neural Network (NN) i Regression Tree (RT), ostvarili su niže R^2 vrijednosti (0,31–0,45) i veće pogreške u odnosu na LSLR, RF i GPR. Posebno se izdvajaju KRR i NN, koji su postigli najviše RMSE vrijednosti ($90,15 \mu\text{g}/\text{cm}^2$ i $87,15 \mu\text{g}/\text{cm}^2$), ukazujući na nižu pouzdanost u predviđanju koncentracije klorofila na kontrolnoj plohi.

Na Slici 18a prikazana je prostorna raspodjela predviđenih vrijednosti CCC-a za zaraženu Plohu A u svibnju tijekom razdoblja 2021., 2022. i 2023. godine. Raspodjela je izrazito heterogena, s jasno izraženim prostornim kontrastima. U većem dijelu plohe prevladavaju snižene vrijednosti CCC-a, dok se povisene vrijednosti javljaju sporadično. Srednja vrijednost CCC-a iznosila je $39,04 \mu\text{g}/\text{cm}^2$, uz SD od $15,60 \mu\text{g}/\text{cm}^2$.

Slika 18b prikazuje raspodjelu CCC-a za kontrolnu Plohu B u svibnju tijekom razdoblja 2021., 2022. i 2023. godine. Vrijednosti su raspoređene ujednačeno, bez naglih prijelaza ili lokalnih odstupanja. Koncentracija klorofila prostorno je stabilna, a distribucija glatka i kontinuirana na cijeloj plohi. Srednja vrijednost CCC-a iznosila je $175,32 \mu\text{g}/\text{cm}^2$, uz SD od $34,18 \mu\text{g}/\text{cm}^2$.

Na Slici 18c prikazan je dijagram odnosa između izmjerениh i predviđenih vrijednosti CCC-a pomoću GPR modela za Plohu A. Točke podataka većinom se grupiraju uz liniju idealne podudarnosti (1:1), s povećanom koncentracijom oko srednjih vrijednosti. Ipak, u krajevima skale primjetna je nešto veća raspršenost. Korelacijski koeficijent iznosi $R = 0.91$, što ukazuje na visoku podudarnost između izmjerениh i modeliranih vrijednosti.

Na Slici 18d prikazan je dijagram odnosa između izmjerениh i predviđenih vrijednosti CCC-a pomoću GPR modela za Plohu B. Raspršenost točaka oko 1:1 linije izraženija je kroz cijeli raspon CCC-a, s većim odstupanjima u donjem i gornjem dijelu skale. Korelacijski koeficijent iznosi $R = 0.69$, što potvrđuje smanjenu preciznost modela u ovom slučaju.



Slika 18 Usporedba izmjerениh i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću MLRA GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca svibnja u razdoblju 2021., 2022. i 2023. godine. Slike 18 a i 18 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 18 c i 18 d prikazuju odnos izmjereni i predviđeni vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1)

4.2.2. Predviđanje sadržaja klorofila krošnje za srpanj

U srpnju za period u kojem je provedeno istraživanje 2021., 2022. i 2023. godine, rezultati modeliranja CCC (Tablica 14) pokazuju da GPR model ostvaruje najbolje performanse na obje plohe. Za zaraženu plohu A, GPR model bilježi najnižu pogrešku s RMSE = 28,23 $\mu\text{g}/\text{cm}^2$, NRMSE = 10,33%, uz najviši koeficijent determinacije $R^2 = 0,73$. Ostali modeli za plohu A ostvaruju slabije rezultate: KRR postiže RMSE = 32,31 $\mu\text{g}/\text{cm}^2$, NRMSE = 11,82%, $R^2 = 0,65$; RF RMSE = 33,29 $\mu\text{g}/\text{cm}^2$, NRMSE = 12,18%, $R^2 = 0,63$; NN RMSE = 33,77 $\mu\text{g}/\text{cm}^2$, NRMSE = 12,36%, $R^2 = 0,61$. LSLR model ostvaruje RMSE = 38,02 $\mu\text{g}/\text{cm}^2$, NRMSE = 13,91%, $R^2 = 0,51$. Najlošiji rezultat zabilježen je kod RT modela s RMSE = 39,75 $\mu\text{g}/\text{cm}^2$, NRMSE = 14,55% i $R^2 = 0,49$.

Tablica 14 Usporedba učinkovitosti različitih regresijskih modela strojnog učenja (MLRA) u procjeni koncentracije klorofila krošnje (CCC) za srpanj u istraživanom periodu 2021., 2022. i 2023. godine na plohama A i B: prikaz pogreške kvadratne sredine (RMSE), relativne pogreške (NRMSE) i koeficijenta determinacije (R^2)

MLRA	A			B		
	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE (%)	R^2	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE (%)	R^2
GPR	28,23	10,33	0,73	47,19	8,90	0,81
KRR	32,31	11,82	0,65	59,25	11,18	0,70
RF	33,29	12,18	0,63	56,14	10,59	0,73
NN	33,77	12,36	0,61	58,49	11,04	0,71
LSLR	38,02	13,91	0,51	61,49	11,60	0,68
RT	39,75	14,55	0,49	67,81	12,79	0,65

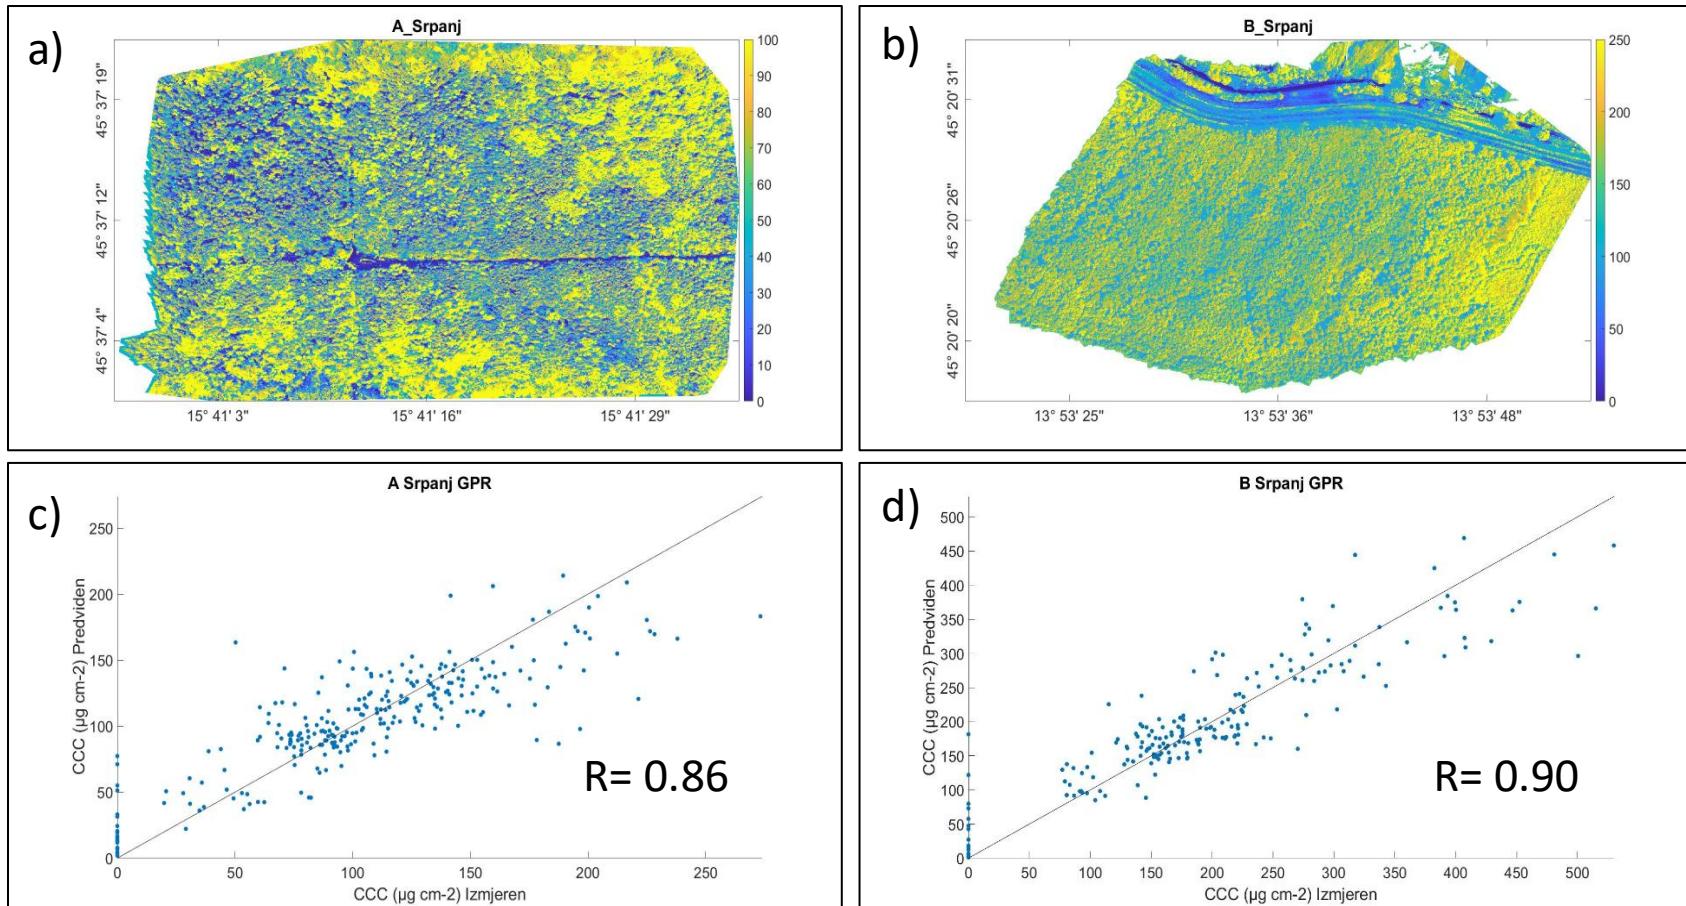
Na kontrolnoj plohi B, GPR bilježi rezultate s RMSE = 47,19 $\mu\text{g}/\text{cm}^2$, NRMSE = 8,90% i R^2 = 0,81. RF model ostvaruje RMSE = 56,14 $\mu\text{g}/\text{cm}^2$, NRMSE = 10,59%, R^2 = 0,73, dok NN model bilježi RMSE = 58,49 $\mu\text{g}/\text{cm}^2$, NRMSE = 11,04% i R^2 = 0,71. KRR postiže RMSE = 59,25 $\mu\text{g}/\text{cm}^2$, NRMSE = 11,18% i R^2 = 0,70. LSLR model na plohi B postiže RMSE = 61,49 $\mu\text{g}/\text{cm}^2$, NRMSE = 11,60%, R^2 = 0,68. RT model ima najniži R^2 od 0,65, uz RMSE = 67,81 $\mu\text{g}/\text{cm}^2$ i NRMSE = 12,79%.

Na Slici 19a prikazana je prostorna raspodjela predviđenih vrijednosti koncentracije klorofila krošnje pomoću GPR modela za zaraženu plohu A u srpnju tijekom razdoblja između 2021., 2022. i 2023. godine. Na Slici 19a vidljiva su područja nižih i viših vrijednosti CCC-a. Raspodjela je prostorno neujednačena s naglašenim razlikama između dijelova sastojine. Srednja vrijednost CCC-a iznosila je 64,76 $\mu\text{g}/\text{cm}^2$, uz SD od 20,42 $\mu\text{g}/\text{cm}^2$.

Na Slici 19b prikazana je prostorna raspodjela predviđenih vrijednosti CCC-a za kontrolnu plohu u srpnju tijekom 2021., 2022. i 2023. godine. Raspodjela je ujednačenija u odnosu na plohu A, s višim ukupnim vrijednostima CCC-a i bez značajnijih lokalnih odstupanja. Srednja vrijednost CCC-a iznosila je 164,62 $\mu\text{g}/\text{cm}^2$, uz SD od 37,83 $\mu\text{g}/\text{cm}^2$.

Na Slici 19c prikazan je dijagram odnosa između izmjerene i predviđene vrijednosti CCC-a za plohu A u srpnju tijekom 2021., 2022. i 2023. godine. Korelacijski koeficijent iznosi $R = 0.86$, uz najveću gustoću podataka uz liniju 1:1. Odnos ukazuje na usklađenost modeliranih i izmjerene vrijednosti, s izraženim linearnim trendom.

Na Slici 19d prikazan je dijagram odnosa između izmjerene i predviđene vrijednosti CCC-a za plohu B u srpnju tijekom 2021., 2022. i 2023. godine. Točke su blisko raspoređene uzduž linije idealne podudarnosti ($R = 0.90$), uz minimalnu raspršenost. Usklađenost predviđenih i izmjerene vrijednosti je izraženija nego na plohi A.



Slika 19 Usporedba izmjerениh i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću MLRA GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca srpnja u razdoblju 2021., 2022. i 2023. godine. Slike 18 a i 18 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 18 c i 18 d prikazuju odnos između izmjereni i predviđeni vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1)

4.2.3. Predviđanje sadržaja klorofila krošnje za rujan

U rujnu za period u kojem je provedeno istraživanje 2021., 2022. i 2023. godine, rezultati modeliranja CCC (Tablici 15) pokazuju da GPR model ostvaruje najbolje performanse na obje plohe (A i B), iako su ukupne vrijednosti točnosti niže nego u prethodnim mjesecima.

Za zaraženu plohu A između 2021. i 2023. godine, GPR model postiže najniži RMSE od 33,09 $\mu\text{g}/\text{cm}^2$, NRMSE od 9,93%, i najviši koeficijent determinacije $R^2 = 0,60$. Ostali modeli za plohu A bilježe slabije rezultate: KRR s RMSE = 34,82 $\mu\text{g}/\text{cm}^2$, NRMSE = 10,45%, $R^2 = 0,56$; RF s RMSE = 36,81 $\mu\text{g}/\text{cm}^2$, NRMSE = 11,05%, $R^2 = 0,52$; NN s RMSE = 38,57 $\mu\text{g}/\text{cm}^2$, NRMSE = 11,58%, $R^2 = 0,47$. LSLR ostvaruje RMSE = 40,55 $\mu\text{g}/\text{cm}^2$, NRMSE = 12,17%, $R^2 = 0,41$, dok RT model bilježi najniže performanse s RMSE = 49,99 $\mu\text{g}/\text{cm}^2$, NRMSE = 15,01% i $R^2 = 0,31$.

Tablica 15 Usporedba učinkovitosti različitih regresijskih modela strojnog učenja (MLRA) u procjeni koncentracije klorofila krošnje (CCC) za rujan u istraživanom periodu između 2021., 2022. i 2023. godine na plohama A i B: prikaz pogreške kvadratne sredine (RMSE), relativne pogreške (NRMSE) i koeficijenta determinacije (R^2)

MLRA	Ploha A			Ploha B		
	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE (%)	R^2	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE (%)	R^2
GPR	33,09	9,93	0,60	62,04	11,25	0,45
KRR	34,82	10,45	0,56	71,99	13,06	0,34
RF	36,81	11,05	0,52	69,10	12,53	0,33
NN	38,57	11,58	0,47	68,99	12,51	0,33
LSLR	40,55	12,17	0,41	71,23	12,92	0,28
RT	49,99	15,01	0,31	78,40	14,22	0,25

Na kontrolnoj plohi B između 2021. i 2023. godine, GPR model postiže RMSE = 62,04 $\mu\text{g}/\text{cm}^2$, NRMSE = 11,25% i $R^2 = 0,45$. Ostali modeli imaju niže vrijednosti koeficijenta determinacije: KRR RMSE = 71,99 $\mu\text{g}/\text{cm}^2$, $R^2 = 0,34$; RF RMSE = 69,10 $\mu\text{g}/\text{cm}^2$, $R^2 = 0,33$; NN RMSE = 68,99 $\mu\text{g}/\text{cm}^2$, $R^2 = 0,33$; LSLR RMSE = 71,23 $\mu\text{g}/\text{cm}^2$, $R^2 = 0,28$; RT RMSE = 78,40 $\mu\text{g}/\text{cm}^2$, $R^2 = 0,25$. NRMSE vrijednosti za ove modele kreću se od 12,51% do 14,22%.

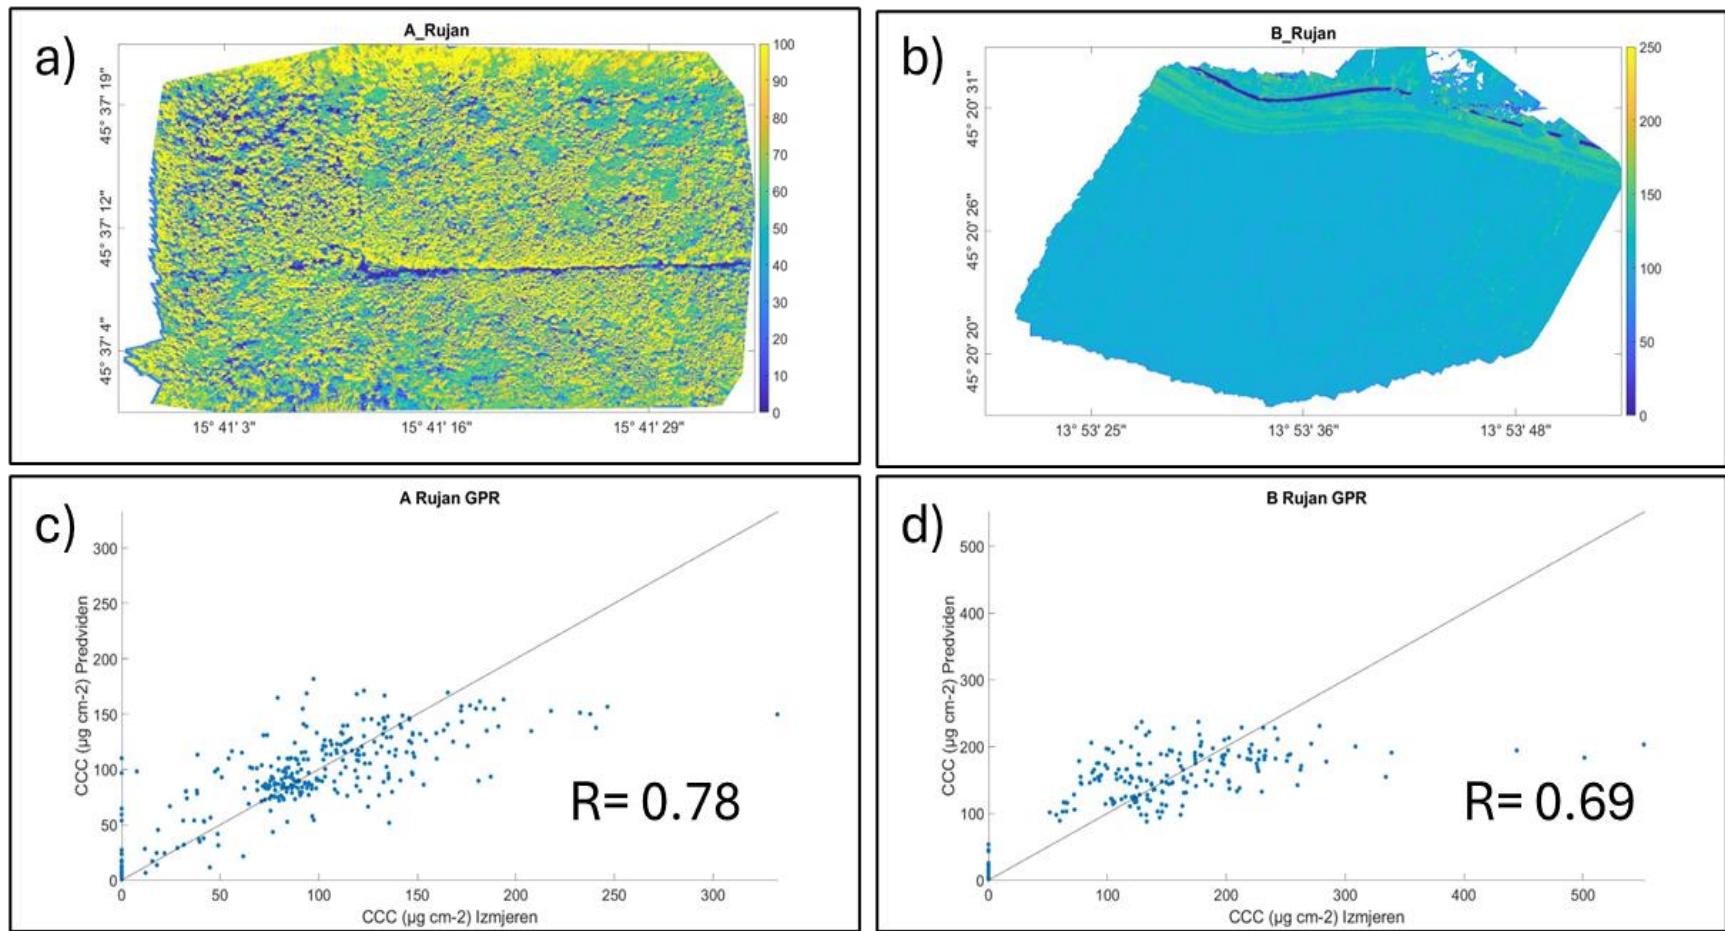
Na Slici 20a prikazana je prostorna raspodjela predviđenih vrijednosti koncentracije klorofila pomoću GPR modela za zaraženu plohu A u rujnu tijekom 2021., 2022. i 2023. godine.

Raspodjela pokazuje izraženu prostornu varijabilnost, s područjima sniženih vrijednosti CCC-a i prostorno definiranim zonama viših vrijednosti. Srednja vrijednost CCC-a iznosila je 66,93 $\mu\text{g}/\text{cm}^2$, uz SD od 19,33 $\mu\text{g}/\text{cm}^2$.

Na Slici 20b prikazana je prostorna raspodjela predviđenih vrijednosti CCC-a za kontrolnu Plohu B u rujnu tijekom 2021., 2022. i 2023. godine. Vrijednosti su prostorno izrazito homogene, uglavnom u rasponu od 50 do 100 $\mu\text{g}/\text{cm}^2$, bez izraženih lokalnih anomalija ili varijacija u distribuciji klorofila. Srednja vrijednost CCC-a iznosila je 141,00 $\mu\text{g}/\text{cm}^2$, uz SD od 19,46 $\mu\text{g}/\text{cm}^2$.

Na Slici 20c prikazan je dijagram odnosa između izmjerениh i predviđenih vrijednosti CCC za Plohu A u rujnu tijekom 2021., 2022. i 2023. godine. Većina točaka raspoređena je uzduž linije idealne podudarnosti (1:1), no u odnosu na prethodne mjesecce uočava se veća raspršenost podataka. Usklađenost između modeliranih i stvarnih vrijednosti je umjerena, s izraženijim odstupanjima na krajevima vrijednosne skale. Korelacijski koeficijent iznosi $R = 0.78$.

Na Slici 20d prikazan je dijagram odnosa između izmjerениh i predviđenih vrijednosti CCC za Plohu B u rujnu tijekom 2021., 2022. i 2023. godine. Točke su šire raspoređene oko linije 1:1, a podudarnost između izmjereni i predviđeni vrijednosti CCC-a je niža nego na Plohi A. Raspodjela podataka upućuje na smanjenu točnost predviđanja modela u rujanskim uvjetima. Korelacijski koeficijent iznosi $R = 0.69$.



Slika 20 Usporedba izmjerениh i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću MLRA GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca rujna u razdoblju 2021., 2022. i 2023. godine. Slike 18 a i 18 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 18 c i 18 d prikazuju odnos između izmjerenihs i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1)

4.3. Hibridni modeli

Rezultati hibridnog pristupa koji kombinira PROSAIL model s algoritmima regresije strojnim učenjem (MLRAs) su prikazani u ovom pod poglavlju za zaraženu plohu A i nezaraženu plohu B za mjesec svibanj, srpanj i rujan za period u kojem je provedeno istraživanje (2021., 2022. i 2023. godine). U hibridnom pristupu korišten je PROSAIL model zajedno sa GPR MLRA modelima, jer je GPR imao pokazao zadovoljavajuće rezultate u samostalnom pristupu modeliranju (MLRA) (Tablica 12)

U Tablici 15 prikazane su statističke mjere (R^2 , RMSE) kojima je procijenjena točnost hibridnog modela PROSAIL+MLRA (GPR) za predikciju CCC. Kao što je ranije prikazano, MLRA modeli trenirani su posebno za svaki mjesec odvojeno za zaraženu plohu A i kontrolnu plohu B. Hibridni pristup (PROSAIL + GPR) temelji se na kombinaciji najboljeg MLRA što je u ovom istraživanju bio GPR uz dodatni sloj - PROSAIL simulacije koje su bile parametarski prilagođene svakoj plohi zasebno.

Tablica 16 Usporedba performansi hibridnog PROSAIL+GPR modela za predviđanje koncentracije klorofila krošnje (CCC) za zaraženu (A) i kontrolnu plohu (B) tijekom 2021., 2022. i 2023. godine; prikaz pogreške kvadratne sredine (RMSE), relativne pogreške (NRMSE) i koeficijenta determinacije (R^2).

Mjesec	Ploha	RMSE ($\mu\text{g}/\text{cm}^2$)	NRMSE (%)	R2
Svibanj	A	30,53	19,23	0,50
	B	280,79	57,93	0,38
Srpanj	A	80,14	29,32	0,18
	B	110,82	20,91	0,49
Rujan	A	105,39	19,12	0,21
	B	165,33	49,64	0,06

4.3.1. Rezultati hibridnog pristupa za svibanj

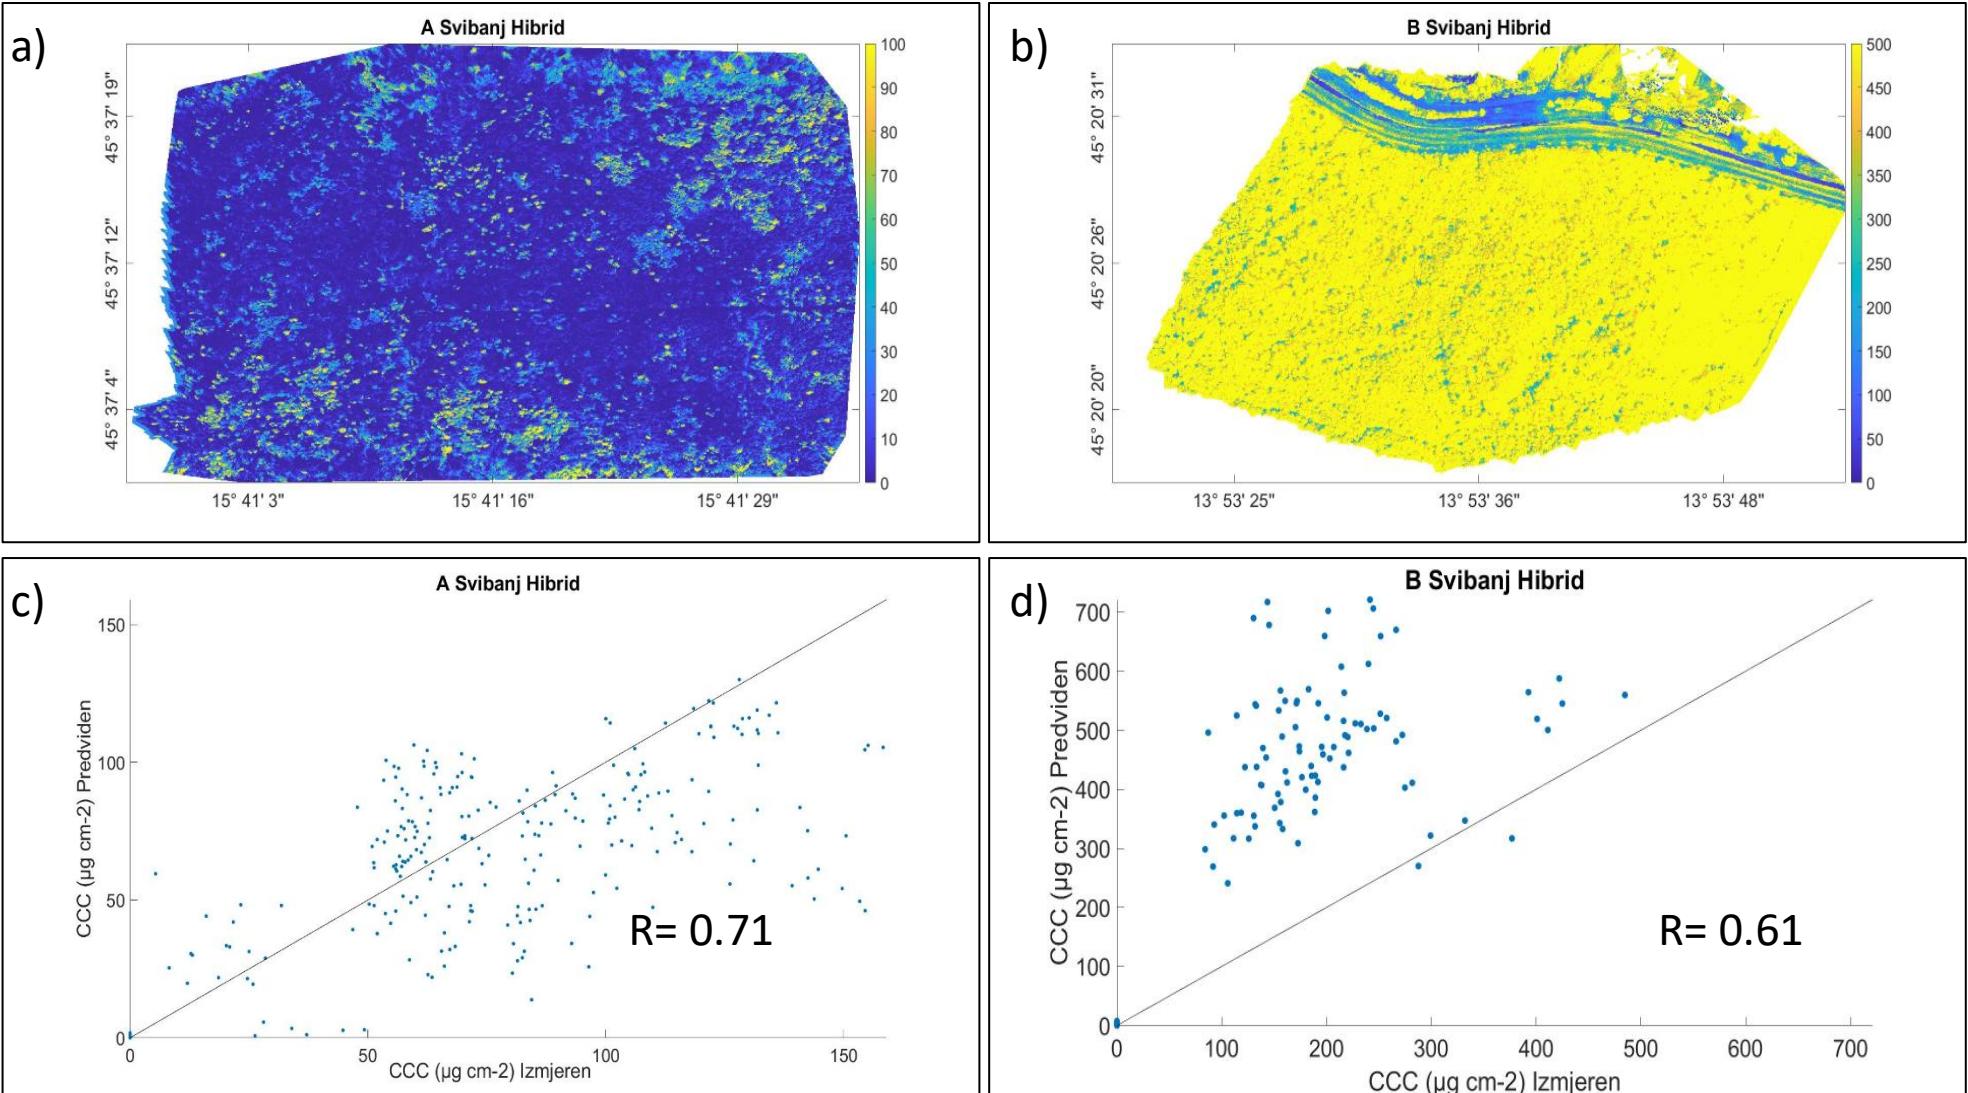
U svibnju, rezultati metrike za hibridni GPR model (PROSAIL + GPR) pokazuju umjerenu sposobnost predviđanja, pri čemu je RMSE na plohi A ($30,53 \mu\text{g}/\text{cm}^2$) niži nego na plohi B ($280,79 \mu\text{g}/\text{cm}^2$), dok su vrijednosti R^2 relativno niske za obje plohe (0,50 i 0,38).

Na Slici 21a prikazana je prostorna raspodjela predviđenih vrijednosti CCC pomoću hibridnog modela PROSAIL + MLRA za zaraženu Plohu A u svibnju tijekom 2021., 2022. i 2023. godine. Vidljive su varijacije u prostornoj distribuciji CCC-a, s tamnjim nijansama koje odgovaraju nižim vrijednostima klorofila u pojedinim zonama krošnje, dok su druge zone svjetlijе, s višim vrijednostima CCC-a. Srednja vrijednost CCC-a iznosila je $30,70 \mu\text{g}/\text{cm}^2$, uz SD od $15,40 \mu\text{g}/\text{cm}^2$.

Na Slici 21b prikazana je prostorna raspodjela CCC-a na kontrolnoj Plohi B u svibnju tijekom 2021., 2022. i 2023. godine. Vrijednosti su vizualno prostorno ujednačene međutim srednja vrijednost CCC-a iznosila je $410,62 \mu\text{g}/\text{cm}^2$, uz SD od $82,77 \mu\text{g}/\text{cm}^2$.

Na Slici 21c prikazan je dijagram odnosa između izmjerениh i modeliranih vrijednosti CCC-a za Plohu A u svibnju tijekom 2021., 2022. i 2023. godine. Uočena je disperzija od linije 1:1, a koeficijent korelacije iznosi $R = 0,71$.

Na Slici 21d prikazan je dijagram odnosa za Plohu B u istom periodu. Raspodjela točaka je šira u odnosu na Plohu A, uz nešto slabiju usklađenost modeliranih i izmjereniх vrijednosti. Koreacijski koeficijent iznosi $R = 0,61$.



Slika 21 Usporedba izmjerenih i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću hibridnog PROSAIL+GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca svibnja u razdoblju 2021., 2022. i 2023. godine. Slike 21 a i 21 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 21 c i 21 d prikazuju odnos između izmjerenih i predviđenih vrijednosti u obliku dijagrama s linijom idealne podudarnosti (1:1)

4.3.2. Rezultati hibridnog pristupa za srpanj

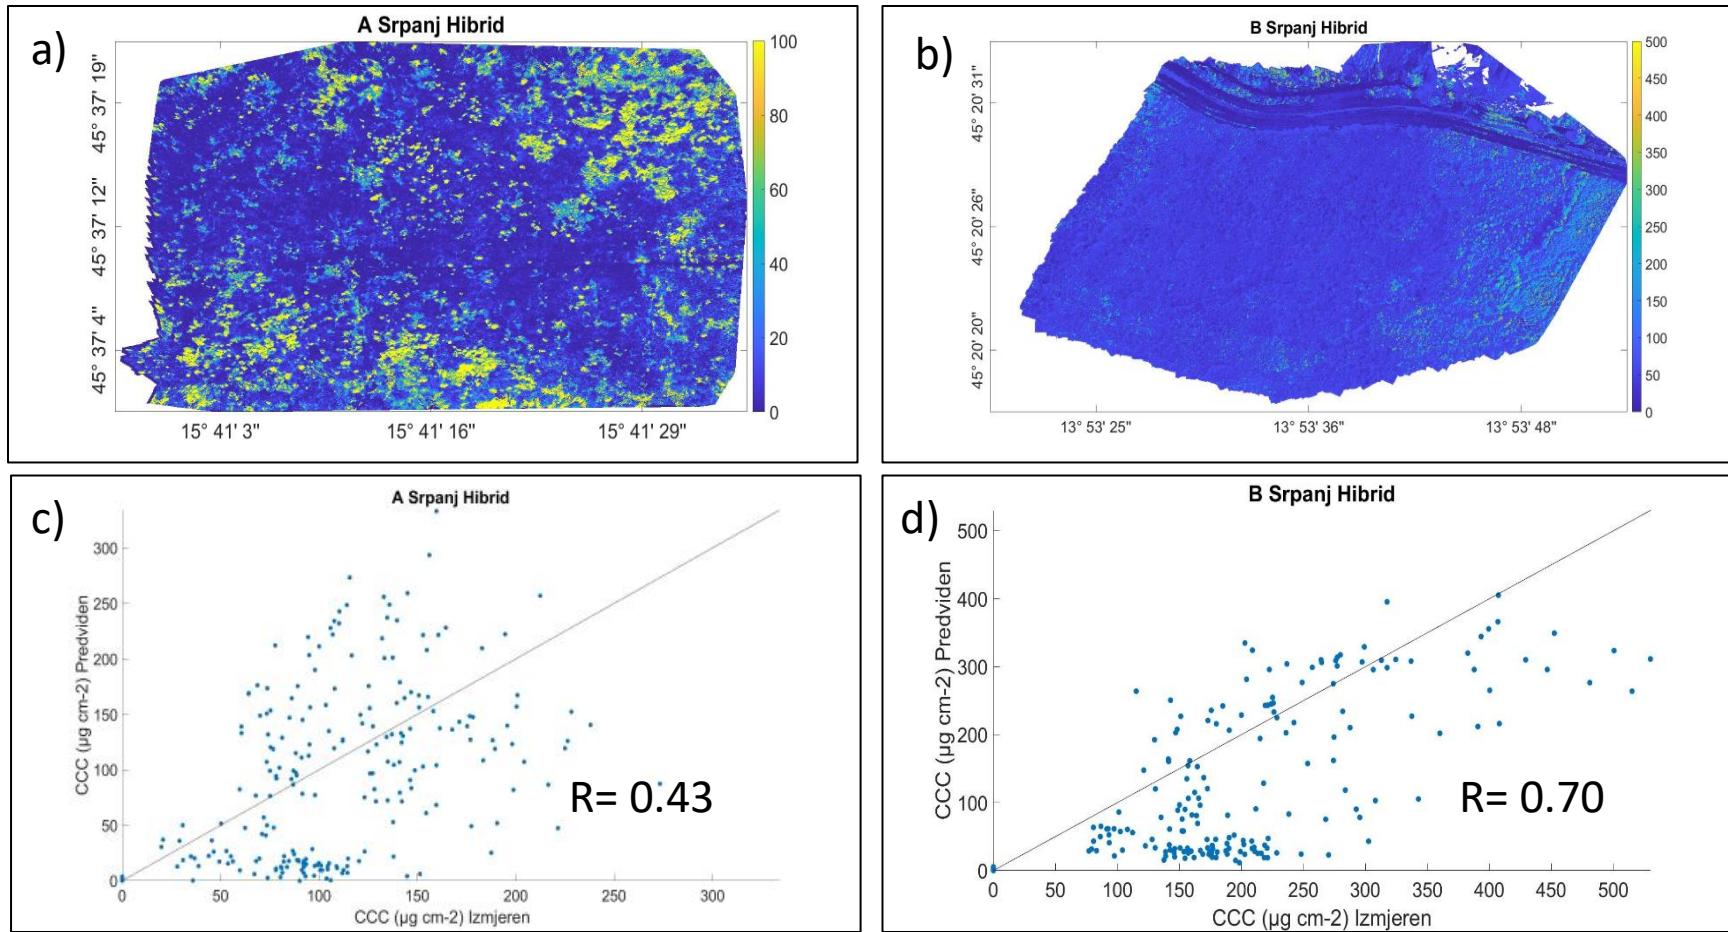
U srpnju, rezultati hibridnog modela PROSAIL + GPR pokazuju razlike u točnosti modeliranja između ploha. Na zaraženoj Plohi A, ostvarene su niže vrijednosti modelskih performansi, s RMSE-om od $80,14 \mu\text{g}/\text{cm}^2$, NRMSE-om od 29,32% i R^2 koeficijentom od 0,18. Na kontrolnoj Plohi B, iako su apsolutne pogreške veće (RMSE = $110,82 \mu\text{g}/\text{cm}^2$), relativna pogreška bila je manja (NRMSE = 20,91%), uz viši $R^2 = 0,49$, što ukazuje na veću konzistentnost modela u ovom slučaju.

Na Slici 22a, prikazana je prostorna raspodjela predviđenih vrijednosti CCC za Plohu A u srpnju tijekom 2021., 2022. i 2023. godine. Karta pokazuje izraženu prostornu fragmentaciju, s područjima nižih vrijednosti klorofila nepravilno raspoređenima unutar krošnje. Tamniji dijelovi karte ukazuju na zone potencijalno većeg stresa ili smanjenog lisnog sadržaja klorofila, dok su svjetlijе zone indikativne za stabilnije uvjete u krošnji. Srednja vrijednost CCC-a iznosila je $35,57 \mu\text{g}/\text{cm}^2$, uz SD od $19,75 \mu\text{g}/\text{cm}^2$.

Na Slici 22b, prikazana je prostorna raspodjela CCC-a na Plohi B u istom razdoblju. Za razliku od Plohe A, raspodjela je kompaktnija i prostorno homogenija, bez izraženih prijelaza ili oštih gradijenata u vrijednostima CCC-a. Prevladavaju vrijednosti srednjeg intenziteta, s ograničenim prostornim ekstremima. Srednja vrijednost CCC-a iznosila je $163,08 \mu\text{g}/\text{cm}^2$, uz SD od $54,71 \mu\text{g}/\text{cm}^2$.

Na Slici 22c, dijagram odnosa između izmjerениh i modeliranih vrijednosti CCC-a za Plohu A u srpnju pokazuje raštrkan uzorak točaka, s izraženijim odstupanjima od linije 1:1. Koeficijent korelacije iznosi $R = 0,43$, što ukazuje na nižu usklađenost rezultata u uvjetima zaraze tijekom ljetnog razdoblja.

Na Slici 22d, dijagram za Plohu B prikazuje kompaktniji raspored točaka uzduž linije idealne podudarnosti, što je rezultiralo višim koeficijentom korelacije $R = 0,70$. Time je na Plohi B zabilježena bolja podudarnost modeliranih i izmjerениh vrijednosti CCC-a za srpanj u promatranom trogodišnjem razdoblju.



Slika 22 Usporedba izmjerениh i predviđenih vrijednosti koncentracije klorofila krošnje (CCC) pomoću hibridnog PROSAIL+GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca srpnja u razdoblju 2021., 2022. i 2023. godine. Slike 22 a i 22 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 22 c i 22 d prikazuju odnos između izmjereni i predviđeni vrijednosti u obliku dijagrama s linijom podudarnosti (1:1)

4.3.3. Rezultati hibridnog pristupa za rujan

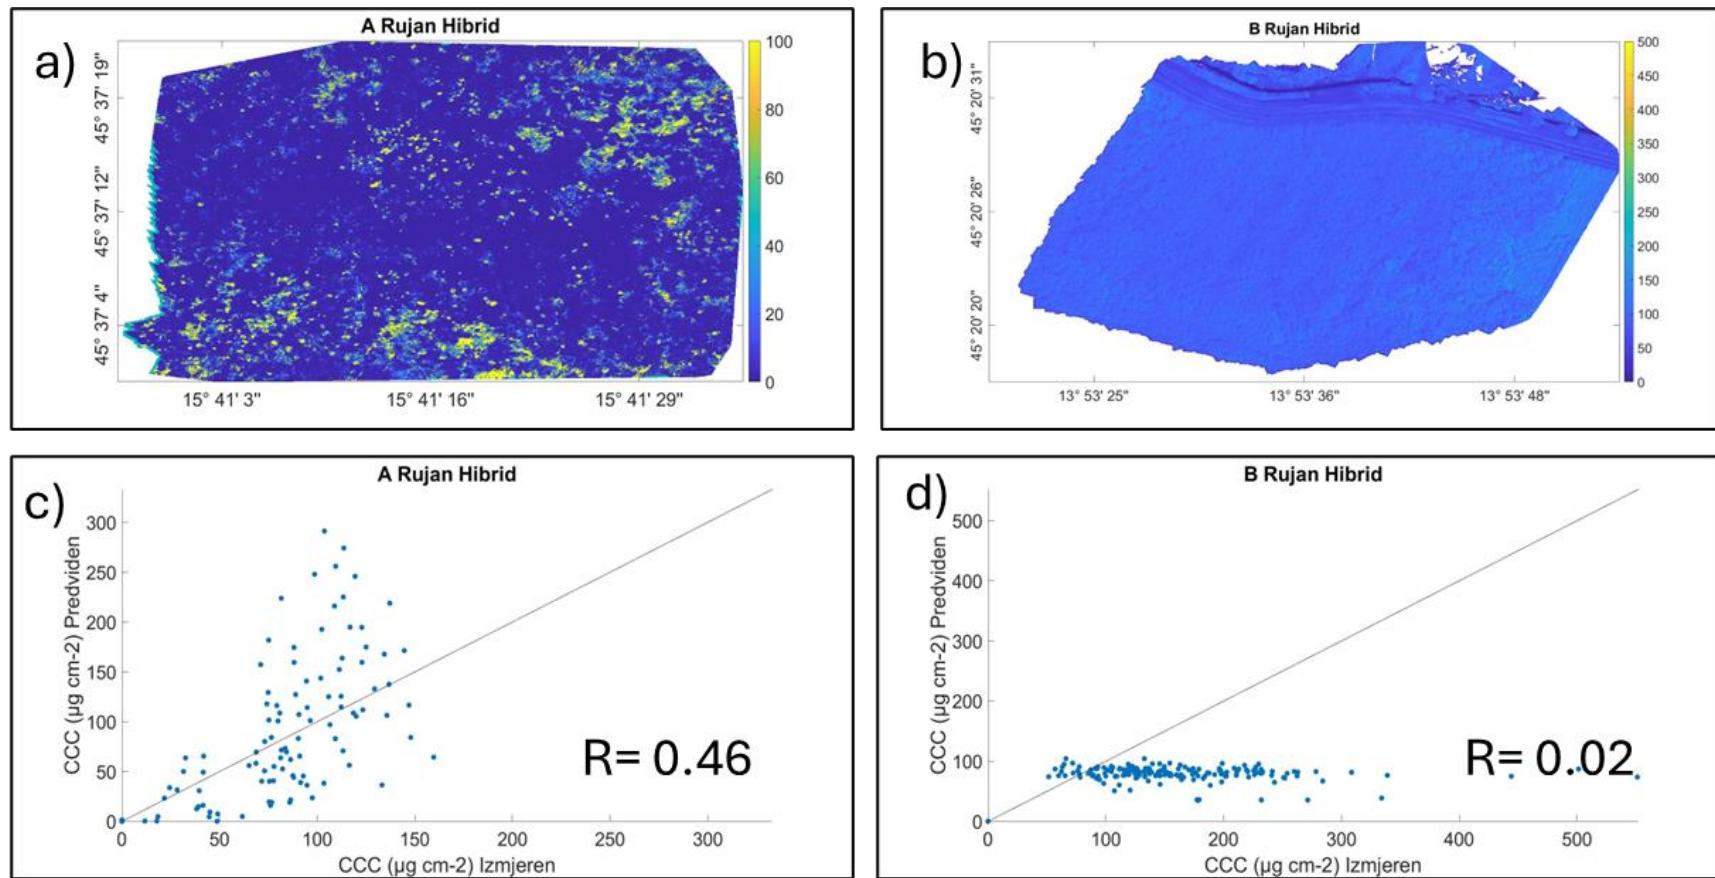
U rujnu, hibridni model PROSAIL + GPR pokazao je nižu ukupnu točnost u usporedbi s prethodnim mjesecima, uz izraženiju razliku u performansama između ploha. Na zaraženoj Plohi A, model je ostvario RMSE od $105,39 \mu\text{g}/\text{cm}^2$, NRMSE od 19,12% i koeficijent determinacije $R^2 = 0,21$. Na kontrolnoj Plohi B, pogreške su bile veće (RMSE = $165,33 \mu\text{g}/\text{cm}^2$; NRMSE = 49,64%), a vrijednost R^2 značajno niža ($R^2 = 0,06$), što ukazuje na smanjenu sposobnost modela za točnu procjenu CCC-a u jesenskom razdoblju.

Na Slici 23a, prikazana je prostorna raspodjela modeliranih vrijednosti CCC-a za Plohu A u rujnu tijekom 2021., 2022. i 2023. godine. Snimka prikazuje mješavinu tamnijih i svjetlijih nijansi, s vidljivom prostornom neujednačenošću i jasno izraženim lokalnim varijacijama u koncentraciji klorofila. Srednja vrijednost CCC-a iznosila je $28,13 \mu\text{g}/\text{cm}^2$, uz SD od $16,71 \mu\text{g}/\text{cm}^2$.

Na Slici 23b, prostorna raspodjela CCC-a za Plohu B u istom u rujnu tijekom 2021., 2022. i 2023. godine pokazuje nepravilnu i diskontinuiranu raspodjelu, s nekoliko izoliranih područja nižih vrijednosti, dok su ostale zone značajno svjetlijе. Srednja vrijednost CCC-a iznosila je $199,83 \mu\text{g}/\text{cm}^2$, uz SD od $40,58 \mu\text{g}/\text{cm}^2$.

Na Slici 23c, dijagram odnosa između izmjerene i modelirane vrijednosti CCC-a za Plohu A prikazuje umjerenu usklađenost, s koeficijentom korelacije $R = 0,46$. Iako su podaci djelomično raspoređeni uzduž linije idealne podudarnosti, primjetna je veća raspršenost u odnosu na proljetne i ljetne mjeseca.

Na Slici 23d, dijagram za Plohu B prikazuje vrlo nisku razinu usklađenosti između izmjerene i modelirane vrijednosti, s koeficijentom korelacije $R = 0,02$. Većina točaka koncentrirana je u donjem desnom kvadrantu dijagrama, što ukazuje na sustavno podcenjivanje viših vrijednosti CCC-a. Ova distribucija odražava vrlo nisku korelaciju između izmjerene i modelirane vrijednosti.



Slika 23 Usporedba izmjerene i predviđene vrijednosti koncentracije klorofila krošnje (CCC) pomoću hibridnog PROSAIL+GPR modela za zaraženu plohu A (a, c) i kontrolnu plohu B (b, d) tijekom mjeseca rujna u razdoblju 2021., 2022. i 2023. godine. Slike 23 a i 23 b prikazuju prostornu raspodjelu modeliranih vrijednosti CCC-a, dok Slike 23 c i 23 d prikazuju odnos između izmjerene i predviđene vrijednosti u obliku dijagrama s linijom podudarnosti (1:1)

5. RASPRAVA

Rezultati ovog istraživanja temelje se na višegodišnjem prikupljanju podataka (2021., 2022. i 2023. godine) tijekom različitih fenoloških faza hrasta lužnjaka (svibanj, srpanj i rujan) s ciljem praćenja dinamike oštećenja hrasta lužnjaka uzrokovanih HMS. U istraživanju je primjenjena integracija daljinskih podataka, dobivenih multispektralnim snimanjem pomoću bespilotne letjelice te terenskih podataka, koji su uključivali koncentraciju klorofila u listovima mjerenu SPAD klorofilmetrom, broj jajnih legala HMS i podatke o temperaturi zraka.

Glavni cilj bio je testirati dvije hipoteze: (1) da se pomoću multispektralnih podataka prikupljenih bespilotnim letjelicama mogu pouzdano utvrditi promjene u koncentraciji klorofila uzrokovane zarazom HMS, te (2) da je moguće korištenjem podataka prikupljenih na terenu, okolišnih parametara i snimaka bespilotne letjelice uz pomoć regresijskih modela i strojnog učenja modelirati koncentraciju klorofila u listovima i krošnjama hrasta lužnjaka

Prva hipoteza djelomično je potvrđena integracijom izravno izmjerениh vrijednosti sadržaja klorofila u listovima (LCC), dobivenih SPAD klorofilmetrom, i indeksa lisne površine (LAI) procijenjenog iz podataka prikupljenih bespilotnom letjelicom, čime je omogućena kvantifikacija prostorne distribucije CCC-a. Detektirane razlike između zaražene (ploha A) i nezaražene plohe (ploha B), uključujući značajno niže vrijednosti CCC-a i LCC-a na plohi A, jasno ukazuju na fiziološki stres izazvan biotičkim čimbenicima. Rezultati su u skladu s ranijim radovima koji potvrđuju korisnost CCC-a kao integrativnog pokazatelja zdravstvenog stanja šuma (Talebzadeh i Valeo 2022, Moustaka i Moustakas 2023).

Samostalni Gaussian Process Regression (GPR) model pokazao se boljim u odnosu na hibridni PROSAIL+GPR pristup u svim analiziranim mjesecima i na obje plohe (zaražena ploha A i kontrolna ploha B). Iako hibridni modeli konceptualno nude veću interpretabilnost integracijom spektralnih simulacija i statističkog modeliranja (Alam i dr., 2024), njihova izvedba bila je ograničena zbog izazova u parametrizaciji fizičkog modela za heterogene šumske sastojine. GPR se pokazao robusnim i prilagodljivim u modeliranju nelinearnih odnosa između spektralnih karakteristika i CCC-a kroz sve fenofaze vegetacije.

5.1. Procjena indeksa lisne površine (LAI)

Rezultat procjene LAI (Poglavlje 4.1.1.) pokazuju da je korištenje multispektralnih podataka prikupljenih pomoću bespilotnih letjelica (izračunom NDRE i CHM) omogućilo pouzdanu procjenu LAI. Dobiveni rezultati, koji potvrđuju statistički značajne razlike između ploha ($t = -2.85$, $p = 0.012$, Slika 14), u skladu su s istraživanjima koja su također istaknula učinkovitost multispektralnih podataka prikupljenih bespilotnim letjelicama u kvantitativnoj procjeni LAI-a u mješovitim sastojinama (Wang i dr., 2023; Li i dr., 2025).

Vegetacijski indeksi u crveno-rubnom spektralnom području, poput NDRE, pokazali su veću osjetljivost na varijacije LAI-a pri višim vrijednostima krošnje, u odnosu na NDVI koji često pati od zasićenja. Takva svojstva čine NDRE pogodnjim za gustu vegetaciju (Li i dr., 2024), a integracija s modelima visine dodatno pojačava interpretaciju strukture i dinamike krošnje u vremenu. Potrebno je napomenuti da LAI nije direktno izmjerena već je indirektno procijenjen na temelju refleksije spektralnog signala, što sa sobom nosi niz metodoloških ograničenja kao što su ovisnost o sadržaju klorofila i geometriji listova, te potreba za lokalnom kalibracijom modela (Tavakoli i dr., 2014, Sun i dr., 2018).

Uočene promjene LAI-a tijekom vegetacijske sezone ukazuju na moguću povezanost sa stresom izazvanim prisutnošću hrastove mrežaste stjenice (HMS) na Plohi A, što je vidljivo na Slici 14. Tijekom svibnja i srpnja, vrijednosti LAI-a na Plohi A bile su niže u odnosu na Plohu B, što može biti posljedica različitih stupnjeva zaraze ili otpornosti vrste na štete na listu. U rujnu je LAI na Plohi A bio nešto viši nego na Plohi B. Ovakav rezultat može odražavati lokalne razlike u fenološkom razvoju, primjerice sporiji ulazak u senescenciju na Plohi A ili mikroklimatske čimbenike koji pogoduju duljoj zadržanosti lisne mase. Iako su razlike statistički značajne ($t = -2.85$, $p = 0.012$), takve fenološke varijacije nisu nužno povezane s prisutnošću HMS-a, već s kombinacijom okolišnih i fizioloških čimbenika koji utječu na dinamiku lisne površine te mogu značajno doprinijeti procijenjenim vrijednostima LAI (Bequet i dr., 2011; Li i Guo, 2013).

Rezultati pokazuju da se procjena LAI-a uz pomoć podataka prikupljenih metodama daljinskog istraživanja može koristiti kao učinkovit alat za utvrđivanje promjena u vegetacijskoj strukturi, ali njezinu interpretaciju treba usmjeriti prema analizi koja uključuje i biotičke i abiotičke stresne čimbenike te terensku validaciju.

5.2. Koncentracija klorofila u listovima i krošnjama hrasta lužnjaka

U ovom istraživanju, SPAD mjerena su kao metoda za kvantifikaciju LCC-a, provedena tijekom svibnja, srpnja i rujna na dvjema pokusnim ploham (Ploha A i Ploha B). Na plohi A mjerena su napravljena između 2021., 2022. i 2023. godine, dok su mjerena na plohi B izvršena 2022. i 2023. godine. Ovakav pristup omogućio je sezonsku i međuprostornu usporedbu između zaraženih i zdravih stabala.

Kao što su dosadašnja istraživanja pokazala (Shibaeva i dr., 2020) i ovo istraživanje potvrđuje da SPAD može služiti kao pouzdan alat za procjenu LCC. U kombinaciji s multispektralnim snimkama prikupljenima bespilotnom letjelicom, SPAD vrijednosti omogućuju kvantifikaciju utjecaja zaraze HMS na razini pojedinačnih stabala, čime se olakšava praćenje zdravstvenog stanja. Upotreba SPAD instrumenta je jednostavna i pruža mogućnost sakupljanja velikog broja podataka u kratkom vremenu, te je tako ekonomičnije i cjenovno povoljnije nego ekstrakcija klorofila u laboratorijima.

Rezultati pokazuju niže vrijednosti LCC-a na Plohi A (Tablica 10), što može upućivat na stres izazvan zarazom HMS, koja uzrokuje oštećenja u obliku smanjenja koncentracije klorofila, a pokazano je da promjene povezane s koncentracijom klorofila omogućuju rano utvrđivanje stresnih stanja u vegetaciji (Jia i dr., 2022). Više vrijednosti standardne devijacije na Plohi A (Tablica 10) odražavaju izraženu varijabilnost koncentracije klorofila među stablima, što može ukazivati na neujednačen fiziološki odgovor na stres izazvan zarazom HMS. Ovakva pojava, gdje pojedina stabla pokazuju izražen pad sadržaja klorofila dok druga zadržavaju stabilnije razine, tipična je u stresnim uvjetima i potvrđena je kao indikator prostorne heterogenosti stresnog odgovora (Kancheva i dr., 2014, Pacheco-Labrador i dr., 2024)

Kako bi se omogućila validacija ukupne količine klorofila na razini krošnje dobivene modelima MLRA ili hibridnim pristupom (PROSAIL + MLRA), vrijednosti LCC uparene su s procijenjenim vrijednostima LAI. Na temelju tih podataka izračunat je CCC na razini pod ploha na kojima su sakupljeni podaci. Ova metoda omogućuje jednostavnu i integriranu procjenu CCC jer istodobno uzima u obzir fiziološke karakteristike vegetacije (putem LCC) i njezinu strukturnu komponentu (putem LAI) (Parida i dr., 2024). Metodološka relevantnost ovakvog pristupa potvrđena je i u istraživanju gdje su modeli bazirani na podacima prikupljenim bespilotnim letjelicama uspješno procjenjivali CCC pomoću LiDAR i multispektralnih podataka (Vignali i ostali 2024). LiDAR se pokazao kao napredan sistem za izračun LAI, jer obuhvaća trodimenzionalno praćenja gustoće

listova. Vrijednost podataka SPAD-a i LAI-a može se koristiti i u fenotipskom kartiranju stresnih odgovora (Jiang i dr., 2022).

Dosadašnja istraživanja su pokazala da kombinacija SPAD mjerena i metoda daljinskog istraživanja može pružiti visoku razinu točnosti u procjeni koncentracije klorofila krošnje (Uddling i ostali 2007, Zhang i ostali 2022). U ovom istraživanju, modeliranje CCC tijekom više godina (2021., 2022. i 2023. godina) pokazalo je da kombinacija podataka prikupljenih bespilotnom letjelicom i terenskih podataka nudi zadovoljavajuću prostornu i vremensku razlučivost potrebnu za rano prepoznavanje stresnih promjena. Takva metodologija prikupljanja podataka bespilotnim letjelicama u kombinaciji s terenskim podacima može imati vrijednost u operativnom šumarstvu, jer bi se mogla koristiti za monitoring zdravstvenog stanja šuma i rano prepoznavanje stresnih promjena.

5.3. Utjecaj temperature i broja jajnih legala na koncentraciju klorofila u listu hrasta lužnjaka

Fiziološki stres u biljkama često se manifestira kroz rane promjene u pigmentnom sastavu listova, pri čemu je koncentracija klorofila (LCC) pouzdan pokazatelj smanjene fotosintetske aktivnosti i općeg fiziološkog stanja biljke (Sun i dr., 2021). U okviru ovog istraživanja, izražene razlike u LCC (Tablica 10) između zaražene plohe A i kontrolne plohe B ukazale su na utjecaj biotičkog stresnog čimbenika u vidu štete koju HMS radi sisanjem listova hrasta, dok je terensko prikupljanje podataka o temperaturi i broju jajnih legala ukazalo na moguću povezanost između akumuliranih DD i broja jajnih legala HMS s opaženim promjenama u koncentraciji klorofila u listu hrasta lužnjaka.

S obzirom na to da razvoj HMS ovisi o temperturnim kumulacijama (Bălăcenoiu i dr., 2021), povećane vrijednosti DD u ljetnim mjesecima mogu doprinijeti većem intenzitetu zaraze (Cui i dr., 2018), što se posljedično odražava na fotosintetski aparat stabala (Nikolić i dr., 2019). Stoga se LCC potvrđuje kao funkcionalni indikator u procjeni zdravstvenog stanja šuma hrasta lužnjaka.

Važno je naglasiti da je analiza utjecaja DD i broja jajnih legala HMS na LCC provedena isključivo za Plohu A, budući da na Plohi B nije zabilježena prisutnost štetnika, pa nije bilo dostupnih podataka o jajnim leglima za usporedbu. Ova metodološka ograničenost onemogućuje prostornu ekstrapolaciju rezultata, no omogućuje ciljanu procjenu odnosa između klimatskih uvjeta, intenziteta zaraze i fiziološkog odgovora stabala uzrokovanih stresom (Leckey i dr., 2014). RF model korišten je isključivo kao alat za ispitivanje potencijala predviđanja LCC temeljem broja

jajnih legala i DD, a ne za konačnu kvantifikaciju. Kako je navedeno u rezultatima (Sekcija 4.1.3), dobivene vrijednosti iz RF modela nisu upotrijebljene kao pouzdane procjene već kao eksplorativni alat za identifikaciju mogućih poveznica te nisu korištene u izradi dalnjih modela s obzirom na dostupnost stvarno izmjerениh vrijednosti.

Rezultati regresijskih modela ističu prednosti primjene algoritama strojnog učenja, osobito RF model, u modeliranju vegetacijskog odgovora na klimatske i biotičke čimbenike. U usporedbi s linearnim pristupima, RF modeli često postižu višu točnost i bolje obuhvaćaju nelinearne odnose i interakcije varijabli (Simon i ostali 2023) što je potvrđeno i u ovom istraživanju..

U rezultatima ovog istraživanja linearna regresija objašnjava tek 30% varijance, a Random Forest (RF) model obuhvaća gotovo cijelokupnu varijabilnost, uz nisku pogrešku predviđanja koncentracije klorofila (Slike 16 i 17). Ova visoka sposobnost predviđanja potvrđena je i u sličnim istraživanjima koje su koristile RF za modeliranje fenoloških promjena tijekom zaraza biljnim patogenima (Meno i dr., 2023).

RF pristup, osim što omogućuje interpolaciju podataka za period između terenskih mjerjenja, nudi operativnu vrijednost u modeliranju dinamike odgovora stabala na biotički stres. Povezivanjem broja jajnih legala HMS, DD i LCC moguće je prepoznati kritične faze u razvoju zaraze koje se vremenski podudaraju s fiziološkim promjenama u listovima. Takav model omogućuje određivanje temperaturnih pragova koji prethode porastu zaraze, predviđanju vremenskih okvira najveće osjetljivosti fotosintetskog aparata te usmjeravanje optimalnog termina za primjenu mjera kontrole (Legros i dr., 2024).

Unatoč visokoj točnosti, RF modeli ostaju djelomično ograničeni u tumačenju zbog složene strukture stabala odluke (engl. *decision trees*), a njihova učinkovitost može varirati ovisno o lokalnim uvjetima. Kvaliteta i dostupnost ulaznih podataka, posebno onih vezanih za mikroklimu i fenologiju štetnika, ključni su za pouzdanu primjenu modela (Aria i dr., 2021; Ghafarian i dr., 2022). Ovakav pristup pokazuje potencijal za razvoj alata koji omogućuju bolje razumijevanje dinamike zaraze i njenih posljedica na fiziologiju stabala.

5.4. Modeliranje vrijednosti klorofila krošnje (CCC)

Provedeno istraživanje identificiralo je pouzdane modele strojnog učenja (MLRA) te hibridne modele, koji najbolje opisuju promjene u kao posljedicu zaraze hrastovom mrežastom stjenicom (HMS). Najuspješniji modeli za svaki mjesec i plohu prikazani su u Tablici 17. Iako je Tablica 17 dio poglavlja Rezultati, prikazana je u poglavljju Rasprava zbog lakšeg praćenja teksta rasprave.

Tablica 17 Sažetak rezultata modeliranja koncentracije klorofila krošnje (CCC) za sve promatrane mjesece (svibanj, srpanj i rujan) tokom perioda istraživanja (2021., 2022. i 2023. godine) i sve primjenjene metode (MLRA i hibridni PROSAIL+GPR pristup). Tablica prikazuje koeficijent determinacije (R^2) i pogrešku kvadratne sredine (RMSE) za svaku kombinaciju mjeseca, metode i plohe (A - zaražena; B - kontrolna).

Mjesec	Ploha	Metoda modeliranja	RMSE ($\mu\text{g}/\text{cm}^2$)	R^2
Svibanj	A	MLRA GPR	16,43	0,83
		Hibridni PROSAIL+GPR	30,53	0,50
	B	MLRA GPR	74,72	0,45
		Hibridni PROSAIL+GPR	280,79	0,38
Srpanj	A	MLRA GPR	28,23	0,73
		Hibridni PROSAIL+GPR	80,14	0,18
	B	MLRA GPR	47,19	0,81
		Hibridni PROSAIL+GPR	110,82	0,49
Rujan	A	MLRA GPR	33,09	0,60
		Hibridni PROSAIL+GPR	165,33	0,06
	B	MLRA GPR	62,04	0,45
		Hibridni PROSAIL+GPR	105,39	0,21

Samostalni MLRA GPR pokazao se boljim u odnosu na hibridni PROSAIL+GPR pristup pri predviđanju CCC kroz sva tri promatrana mjeseca i za obje plohe. Najveća točnost zabilježena je u srpnju, mjesecu optimalne fenološke razvijenosti vegetacije, kada su spektralni signali bili najstabilniji i najmanje podložni signalnom šumu. Prednosti GPR modela proizlaze iz njegove nelinearne, neparametarske prirode, čime je omogućeno učenje kompleksnih obrazaca u podacima bez prepostavki o obliku regresijske funkcije. Ovakva fleksibilnost omogućuje visoku točnost predviđanja i u uvjetima velike prostorne i vremenske heterogenosti kao što su šume gdje struktura krošnje i stresni faktori znatno variraju (Verrelst i dr., 2012).

GPR uključuje mogućnost kvantifikacije nesigurnosti predviđanja, što bi moglo biti korisno kod

utvrđivanja predviđanja širenja invazivnih stranih vrsta i donošenja odluka o potrebi primjene mjera suzbijanja. Takva svojstva modela čine ga pogodnim za rano otkrivanje promjena uzrokovanih stresnim čimbenicima, kao što mogu biti i štete od invazivnih stranih vrsta, čime se potvrđuje njegova učinkovitost u otkrivanju i kartiranju ranih simptoma stresa (Simberloff i dr., 2013; Alam i dr., 2024).

Fizičko-statistički hibridni modeli poput PROSAIL+GPR predstavljaju konceptualno napredniji pristup od samostalnih MLRA jer kombiniraju spektralne simulacije temeljene na fizičkim zakonima s fleksibilnošću strojnog učenja, ali njihova primjena u ovom istraživanju nije rezultirala boljim performansama (Tablica 17). Hibridni modeli pokazali su ograničenu učinkovitost, osobito u srpnju i rujnu, gdje su R^2 vrijednosti ostale niske, a RMSE visoke. Niska R^2 vrijednost upućuje na slabiju sposobnost modela da objasni varijabilnost opaženih podataka, dok visoka RMSE vrijednost označava veća odstupanja između predviđenih i stvarnih vrijednosti, odnosno nižu preciznost modela.

Slabija učinkovitost hibridnih modela može se objasniti kombinacijom više faktora, uključujući nedovoljnu preciznost parametrizacije PROSAIL simulacija za kompleksne i mješovite šumske krošnje, povećani rizik od prekomjerne prilagodbe (engl. *overfitting*) zbog visoke složenosti modela te činjenicu da PROSAIL, kao fizikalni model, nije izvorno razvijen za heterogene sastojine (Gu i ostali 2016). Ograničenja hibridnog pristupa potvrđena su i u istraživanjima koja pokazuju da složeni hibridni modeli, ako nisu pažljivo kalibrirani i validirani za specifične lokalne uvjete, često ne ostvaruju bolju učinkovitost od jednostavnijih statističkih pristupa, osobito u prostorno ograničenim i uvjetima različitog vegetacijskog pokrova (Berger i dr., 2021; Alam i dr., 2024)

5.4.1. Analiza MLRA pristupa

GPR pokazao se kao stabilan i učinkovit regresijski model u svim analiziranim vremenskim razdobljima i na obje plohe (A i B) (Tablica 17) što potvrđuje njegovu sposobnost da precizno modelira kompleksne, nelinearne odnose između spektralnih značajki i CCC. GPR se u dosadašnjim istraživanjima prikazuje kao jedan od osobito robusnih modela za predviđanje biofizičkih parametara iz spektralnih podataka zahvaljujući svojoj fleksibilnosti i sposobnosti kvantificiranja nesigurnosti u predviđanjima različitih biofizičkih parametara (Verrelst i dr., 2012). GPR i Kernel Ridge Regression (KRR) pokazale su se kao učinkovite metode za procjenu CCC-a u različitim agroekološkim i šumskim uvjetima, osobito kada se primjenjuju na podatke dobivene bespilotnim letjelicama i satelitskim senzorima (Alam i dr., 2024)

U svibnju, kada vegetacija ulazi u početne faze rasta, GPR je ostvario visoku točnost na zaraženoj plohi A ($RMSE = 16.43 \mu\text{g}/\text{cm}^2$, $R^2 = 0.83$) (Poglavlje 4.2.1.). Ova razina preciznosti važna je jer rano otkrivanje fizioloških promjena u vegetaciji omogućuje pravovremenu reakciju u slučaju stresnih čimbenika poput npr. invazivnih štetnika. Pravovremeno prepoznavanje simptoma napada štetnikom bitan je preduvjet za uspješno upravljanje invazivnim vrstama u šumskim ekosustavima (Simberloff i dr., 2013). Uspješnost GPR-a u ovom kontekstu može se objasniti njegovom sposobnošću učenja lokalnih obrazaca, osobito u uvjetima izražene razlike između zdravih i oštećenih dijelova krošnje, što je tipično za ranoproljetnu fenofazu.

U srpnju, fenološki najstabilnijem mjesecu kada je lišće maksimalno razvijeno i LAI doseže najviše vrijednosti, GPR ponovno bilježi visoku točnost, posebno na kontrolnoj plohi B ($R^2 = 0.81$, $RMSE = 47.19 \mu\text{g}/\text{cm}^2$) (Poglavlje 4.2.2.). To je razdoblje optimalnih spektralnih uvjeta za modeliranje, jer se bilježe najniže varijacije u optičkim svojstvima listova i krošanja, a reflektancije vegetacije su intenzivne i stabilne. U takvim uvjetima, svi modeli pokazuju poboljšane performanse, ali GPR ostaje najprecizniji zahvaljujući svojoj sposobnosti detekcije suptilnih gradijenata u podacima. Stabilnost modela u srpnju potvrđena je i u ranijim istraživanjima koja su pokazala da predikcija CCC-a najbolje funkcioniра u razdoblju maksimalne vegetacijske aktivnosti (Van Wittenberghe i dr., 2014).

U rujnu, kada se ulazi u fazu mirovanja vegetacije, dolazi do pogoršanja performansi svih modela (Poglavlje 4.2.3.), što može biti uzrokovano smanjenim kontrastom u spektralnom odgovoru vegetacije uslijed degradacije pigmenta klorofila i promjena u strukturi lista. Unatoč takvim

uvjetima, GPR i dalje ostvaruje najviše vrijednosti točnosti ($R^2 = 0.60$ za plohu A) što ukazuje na njegovu otpornost na degradaciju signala. Visoka raspršenost podataka u ovom razdoblju otežava precizno modeliranje, što je vidljivo i u sniženim Pearsonovim koeficijentima korelacije (R) (Slike 20 c i 20 d), ali GPR pokazuje veću konzistenciju u odnosu na ostale pristupe. U takvim uvjetima bitno je koristiti napredne nelinearne modele, gdje tradicionalne linearne metode često podbacuju zbog niske osjetljivosti na kompleksne obrasce spektralnih promjena (Caicedo i dr., 2014).

Rezultati samostalnih MLRA modela pokazuju da je GPR pristup pouzdan i prilagodljiv u modeliranju prostorne varijabilnosti CCC unutar oštećenih šumskih sastojina tijekom različitih fenoloških faza, osobito u uvjetima fiziološke i strukturne neujednačenosti uzrokovane stresnim biotičkim čimbenicima. Njegova sposobnost da adaptivno uči iz podataka, uz mogućnost kvantifikacije nesigurnosti, čini ga pogodnim za primjene u daljinskom istraživanju vegetacije u heterogenim ekološkim uvjetima. To je vidljivo i u usporedbi s jednostavnijim modele poput LSLR ili pristupa stablima odlučivanja (RT), čija ograničena fleksibilnost i osjetljivost na varijabilnost rezultira smanjenom točnošću, posebno u graničnim fenofazama poput svibnja i rujna (Tablica 12).

5.4.2. Analiza hibridnih modela (PROSAIL+GPR)

Za razliku od čisto empirijskih MLRA modela, koji koriste isključivo izmjerene vrijednosti spektralnih i okolišnih varijabli za modeliranje CCC-a, hibridni pristup PROSAIL+GPR integrira fizikalno zasnovane simulacije refleksije krošnje (putem PROSAIL modela) s snagom predviđanja strojnim učenjem (GPR) (Verrelst i ostali 2016a, 2019). Cilj takvog pristupa je objediniti fiziološki vjerodostojan prikaz stanja krošnje, koji pružaju fizikalni modeli, s fleksibilnošću statističkih pristupa strojnog učenja, čime se teoretski omogućuje bolja generalizacija na različite okolišne uvjete. Međutim, iako konceptualno napredan, ovaj pristup u praksi ne pokazuje konzistentnu prednost pred samostalnim MLRA modelima (Berger i dr., 2021, Alam i dr., 2024), što je vidljivo i u rezultatima ovog istraživanja.

Najbolji rezultati hibridnog modela ostvareni su u svibnju (Tablica 16), što je u skladu s teorijskim pretpostavkama o snazi fizikalnih modela u uvjetima niskog sadržaja klorofila i jasne fiziološke diferencijacije između zdravih i zaraženih ploha (Gupta i Pandey 2022; Xu i dr., 2024). U svim slučajevima, ovaj hibridni pristup podrazumijeva generiranje LUT spektralnih simulacija pomoću

PROSAIL modela, pri čemu su parametri poput LAI-a i koncentracije klorofila unaprijed definirani, a zatim se te simulacije koriste kao ulazni skup za treniranje GPR modela. GPR je odabran jer je u prethodnoj usporedbi MLRA modela pokazao najbolje performanse. Ovakav pristup omogućuje da GPR „uči“ iz fiziološki smislenih i dobro strukturiranih simulacija PROSAIL-a, što posebno dolazi do izražaja u fenofazama kad su razlike između zdravih i biljaka pod stresom najveće (Poglavlje 4.3.1).

Unatoč tome, rezultati pokazuju da čak i u optimalnim uvjetima u svibnju, samostalni GPR model konzistentno nadmašuje hibridni pristup, što upućuje na ograničenu preciznost fizikalne parametrizacije i smanjenu osjetljivost hibridnog modela na lokalne heterogenosti u složenim šumskim sastojinama.

U srpnju se performanse hibridnog modela pogoršavaju. Na zaraženoj plohi A bilježi se pad točnosti predviđanja na svega $R^2 = 0.18$ (Poglavlje 4.3.2.). Ova kontradikcija ukazuje na nekoliko mogućih uzroka. Prvo, PROSAIL model u srpnju može teško uhvatiti varijacije u koncentraciji klorofila uzrokovane zarazom HMS, s obzirom na to da koristi standardizirane vrijednosti ulaznih parametara koji možda ne odražavaju točne lokalne uvjete (npr. strukturu krošnje, kut lista, distribuciju pigmenta). Drugo, povećana gustoća vegetacije i jača refleksija u zelenom spektralnom rasponu dovode do smanjenog kontrasta među klasama, čime fizikalna komponenta modela gubi diskriminativnu moć. GPR komponenta tada djeluje nad pojednostavljenim ili previše generaliziranim ulazima, što umanjuje njegov kapacitet predviđanja (Pasolli i dr., 2010).

U rujnu, na početku senescencije, hibridni model pokazuje slabe rezultate: R^2 iznosi 0.21 na zaraženoj plohi A i tek 0.06 na kontrolnoj plohi B (Poglavlje 4.3.3.). Uzrok tome vjerojatno je u kombinaciji nekoliko čimbenika. Prvo, spekralna osjetljivost na klorofil značajno se smanjuje kako pigmenti degradiraju, što PROSAIL modelu otežava razlikovanje zdravih i senescentnih listova (Botha i dr., 2007). Drugo, iako PROSAIL model uključuje parametre za sadržaj vode u listu, ne obuhvaća promjene u distribuciji dušika ni druge dinamične fiziološke procese, što može rezultirati gubitkom relevantnih informacija u simulaciji vegetacijskog odgovora (Gupta i Pandey 2022). Treće, u kasnoj fazi vegetacije dolazi do povećane spektralne i fiziološke homogenosti među plošnim jedinicama, što dodatno smanjuje informacijski kontrast i otežava učenje statističkog modela (Wu i dr., 2022).

Jedan od izazova hibridnih modela u kontekstu ovog istraživanja, koje se odvijalo na prostorno

ograničenim i fenološki različitim šumskim plohamama, jest njihova osjetljivost na lokalne razlike u vegetacijskoj strukturi jer je pokazano da uspješnost fizičko-statističkih hibrida ovisi o prostornoj primjenjivosti (Alam i dr., 2025). Na velikim i uniformnim poljoprivrednim površinama hibridni modeli postižu izvrsne rezultate, dok u šumama njihova učinkovitost pada (Berger i dr., 2018). Lokalna varijabilnost u vegetacijskoj strukturi i stupnju zaraze unutar svake plohe predstavljalaje izazov za preciznu kalibraciju PROSAIL simulacija u hibridnom modelu. Budući da su svi hibridni modeli trenirani i evaluirani odvojeno za svaku plohu, razlike u performansama modela između ploha A i B odražavaju stvarne ekološke i fiziološke kontraste, a ne metodološko miješanje podataka. Samo je u dodatnoj analizi prikazanoj u Prilogu 4 procijenjena robusnost modela na kombiniranom skupu, ali primarni rezultati i interpretacije temelje se na odvojenoj evaluaciji.

5.6. Ograničenja istraživanja i mogući izvori pogrešaka

Jedno od temeljnih ograničenja ovog istraživanja odnosi se na način procjene indeksa lisne površine (LAI), koji je korišten kao ulazni parametar u fizičkom PROSAIL modelu. Umjesto izravnog terenskog mjerjenja, LAI je dobiven posredno, što može dovesti do smanjenog raspona i točnosti vrijednosti koje unose nesigurnost u simulacije refleksije. Takve pogreške potencijalno utječu na valjanost ulaznih podataka za hibridne modele (Varvia i dr., 2017).

Iako su fizički modeli poput PROSAIL-a dizajnirani kako bi pružili robusne i interpretabilne procjene biofizičkih parametara, njihova učinkovitost snažno ovisi o preciznosti ulaznih parametara kao što su LAI, LCC, kut listova, struktura krošnje i atmosferski uvjeti (Gu i dr., 2016). U šumskim ekosustavima, gdje dominira složena struktura sastojina i prostorna heterogenost, čak i male pogreške u parametrizaciji mogu rezultirati značajnim odstupanjima u simuliranoj refleksiji (Morcillo-Pallarés i ostali 2019). Fizički RTM modeli postaju osjetljivo nelinearni u uvjetima slabe kalibracije, što može dovesti do prekomjerne generalizacije ili pogrešnog predstavljanja lokalnih uvjeta (Berger i dr., 2021, Alam i dr., 2024).

Dodatni tehnički izazov u ovom istraživanju predstavlja ograničena spektralna rezolucija multispektralne kamere korištene na bespilotnoj letjelici. U usporedbi s hiperspektralnim senzorima, multispektralni senzori pokrivaju širi dio spektralnih kanala, što smanjuje sposobnost modela da razlikuje suptilne promjene refleksije povezane s različitim razinama klorofila ili stupnjevima stresa u vegetaciji (Campbell i dr., 2007). Zbog toga je otežano rano prepoznavanje zaraze te precizno razlikovanje zdravih i zaraženih stabala, osobito kada su fiziološke razlike male. Ovo ograničenje posebno utječe na učinkovitost hibridnih modela, jer ograničen broj spektralnih kanala smanjuje pouzdanost u procjeni biofizičkih parametara i otežava finu kalibraciju modela na razini krošnje.

Kako bi se djelomično kompenzirala navedena ograničenja, u ovom istraživanju primijenjena je napredna metoda aktivnog učenja u okviru Matlab (R2021a) implementacije GPR-a. Korištena je tehnika raznolikosti uzorka temeljena na euklidskoj udaljenosti (EBD), kojom su odabrani najinformativniji uzorci za treniranje modela. Ova metoda omogućila je bolju usklađenost simuliranih i stvarnih spektralnih vrijednosti te poboljšala ukupnu učinkovitost modela, osobito u kontekstu ograničene količine spektralnih informacija i prostorne kompleksnosti (Alam i dr., 2024).

5.7. Smjernice za buduća istraživanja i primjenu rezultata

Daljnja istraživanja trebala bi biti usredotočena na proširenje spektralne i prostorne razlučivosti korištenih podataka kako bi se unaprijedilo otkrivanje i kvantifikacija stresnih promjena u šumskim ekosustavima. Primjena hiperspektralnih podataka prikupljenih pomoću bespilotnih letjelica omogućila bi precizniju identifikaciju fizioloških promjena povezanih sa stresom vegetacije, koje multispektralne kamere zbog ograničenog broja spektralnih kanala često ne uspijevaju adekvatno zabilježiti. Prednost ovog istraživanja u usporedbi s satelitskim podacima je u detaljnijoj prostornoj rezoluciji snimaka prikupljenih bespilotnom letjelicom, ali manji broj spektralnih kanala doprinosi ograničenju rezultata. Zato se može očekivati da bi detaljnija spektralna i prostorna rezolucija korištenjem hiperspektralnih snimaka prikupljenih bespilotnom letjelicom unaprijedila modeliranje. Rana zaraza potkornjakom (*Dendroctonus valens* LeConte Coleoptera; Curculionidae) na individualnoj razini stabala uspješno je otkrivena korištenjem hiperspektralnih snimkama prikupljenih bespilotnom letjelicom. Uspoređene su spektralne karakteristike *Pinus tabuliformis* Carr. na tri razine (zdravo, zaraženo i mrtvo), te uspješno uspostavljeni klasifikacijski modeli koristeći tri skupine značajki (refleksija, derivati i spektralni indeksi vegetacije) i dva algoritma (RF i NN) (Gao i dr., 2023).

Slična istraživanja (Pasolli i dr., 2010, Mateo-Sanchis i dr., 2018) potvrđuju da se varijable poput sadržaja klorofila, dušika, vode u listu i LAI-a mogu pouzdano modelirati primjenom GPR i KRR modela na hiperspektralnim podacima punog raspona. KRR postigže visoku točnost u predikciji sadržaja klorofila i dušika ($R^2 = 0.93$ i 0.94) na EnMAP hiperspektralnim podacima, dok se GPR potvrdio kao najstabilniji model u hibridnom pristupu PROSAIL + GPR za procjenu CCC ($R^2 = 0.84$) (Alam i sur. 2025). Time se pokazao GPR ne samo kao točan, već i robustan model za obradu visokodimenzionalnih, spektralno kompleksnih podataka u ekološki raznolikim sredinama (Pasolli i ostali 2010, Mateo-Sanchis i ostali 2018).

Posebna prednost GPR-a jest njegova sposobnost identifikacije najrelevantnijih valnih duljina unutar spektra, što omogućuje optimizaciju modelskih ulaza i bolju interpretaciju rezultata. Ova karakteristika naročito dolazi do izražaja u šumskim sustavima, gdje se morfološka i biokemijska svojstva listova znatno razlikuju među vrstama, razinama oštećenja i fenološkim fazama (Van Wittenberghe i dr. 2014).

Unapređenje inverzijskih metoda i reduciranja neodređenosti LUT generiranih iz fizičkih modela

poput PROSAIL-a potrebno je zbog veće prilagodljivošću takvih modela realnim terenskim uvjetima, koji su često nelinearni i heterogeni (Sun i dr., 2022). Aktivno učenje može znatno poboljšati efikasnost modeliranja vegetacijskih varijabli smanjenjem potrebe za velikim količinama podataka za treniranje (Verrelst i dr., 2016; Tagliabue i dr., 2022). Selekcija najinformativnijih uzoraka pomoći aktivnog učenja povećava točnost predviđanja i optimizira proračunske resurse, što je posebno važno kod rada s velikim hiperspektralnim setovima podataka (Berger i dr. 2021).

Sinergija naprednih regresijskih metoda poput GPR-a, hiperspektralnih i termalnih podataka prikupljenih bespilotnim letjelicama i satelitskih podataka te algoritama aktivnog učenja predstavlja snažan istraživački okvir za daljnje unaprjeđenje modeliranja biofizičkih varijabli u šumskim ekosustavima. Takav integrirani pristup mogao bi pomoći kod pravovremenog otkrivanja, kvantifikacije i praćenja stresnih promjena na stablima uzrokovanih biotičkim i abiotičkim čimbenicima.

6. ZAKLJUČAK

Provedeno istraživanje pokazalo je da multispektralne snimke prikupljene bespilotnim letjelicama predstavljaju učinkovito sredstvo za kvantifikaciju koncentracije klorofila u šumskim ekosustavima. Utvrđivanjem smanjenja koncentracije klorofila u listu (LCC) i krošnji (CCC) stabala hrasta lužnjaka na plohi zaraženoj HMS potvrđeno je da se podaci prikupljeni bespilotnom letjelicom mogu koristiti za utvrđivanje prostorne distribucije zaraze HMS, čime se omogućuje precizno i pravovremeno prepoznavanje stabala pod stresom. Visoka podudarnost između podataka dobivenih pomoću multispektralnih snimaka prikupljenih bespilotnim letjelicama i SPAD terestričkih mjerena pokazuje da snimke prikupljene bespilotnim sustavima omogućuju rano otkrivanje biotičkog stresa i imaju potencijal za operativnu primjenu u praćenju vitalnosti šumskih sastojina.

Gaussian Process Regression (GPR) pokazao se kao precizan i stabilan model strojnog učenja za predikciju CCC-a tijekom cijelog vegetacijskog ciklusa, zahvaljujući svojoj sposobnosti učenja nelinearnih obrazaca i kvantifikacije nesigurnosti. Hibridni modeli koji su uključivali PROSAIL simulacije nisu bili precizniji od GPR modela, a u nekim slučajevima pokazali su i nižu točnost, osobito u kasnijim fazama vegetacije kada su spektralne razlike među stablima bile manje izražene. Ograničenja hibridnih pristupa uključuju osjetljivost na pogreške u parametrizaciji, slabiju prilagodbu složenim šumskim strukturama i ograničenu učinkovitost na prostorno malim i heterogenim uzorcima.

Rezultatima istraživanja djelomično je potvrđena prva hipoteza, a to je da multispektralne snimke prikupljene bespilotnim letjelicama omogućuju pouzdanu detekciju promjena u koncentraciji klorofila. Druga hipoteza je djelomično potvrđena jer su regresijski modeli strojnog učenja uspješno modelirali CCC, ali hibridni modeli (PROSAIL+GPR) nisu ostvarili očekivano poboljšanje predviđanja sadržaja klorofila u odnosu na samostalne regresijske algoritme strojnog učenja. Ipak, njihova vrijednost nije zanemariva jer su, unatoč ograničenim rezultatima u ovom istraživanju koje je provedeno na prostorno malim i heterogenim uzorcima, pokazali potencijalnu primjenjivost u šumskim ekosustavima većeg prostornog opsega, osobito u uvjetima ograničenog terenskog uzorkovanja što otvara prostor za buduće unaprjeđenje njihove točnosti.

Multispektralne snimke prikupljene bespilotnim letjelicama u kombinaciji s naprednim regresijskim modelima mogu se koristiti kao alat za rano otkrivanje i kvantifikaciju stresnih

promjena u šumama. Potpuni potencijal hibridnog modeliranja zahtijeva daljnju optimizaciju ulaznih podataka, poboljšanje spektralne rezolucije i validaciju u različitim fenološkim i ekološkim uvjetima. Integracija ovih metoda sa podacima prikupljenih pomoću satelita, automatizacija procesa obrade te razvoj sustava za kontinuirano praćenje u stvarnom vremenu predstavljaju smjer za buduća istraživanja koja bi dodatno unaprijedila monitoring zdravstvenog stanja šuma u kontekstu globalnih promjena i rastućih pritisaka invazivnih vrsta.

7. POPIS LITERATURE

- Agathokleous E, Feng ZZ, Peñuelas J, 2020. Chlorophyll hormesis: Are chlorophylls major components of stress biology in higher plants? *Sci. Total Environ.* 726: 138637. <https://doi.org/10.1016/j.scitotenv.2020.138637>.
- Ahmad AM, Minallah N, Ahmed N, Ahmad AM, Fazal N, 2020. Remote sensing based vegetation classification using machine learning Algorithms. *2019 Int. Conf. Adv. Emerg. Comput. Technol. AECT 2019*. <https://doi.org/10.1109/AECT47998.2020.9194217>.
- 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 MMT, Simic Milas A, Verrelst J, Tian Q, Kripal AS, Osei HP, Rahman MA, 2025. Optimizing Empirical and Hybrid Modeling for Advanced Canopy Chlorophyll and Nitrogen Retrieval Technique Using EnMAP Data. *Environ. Challenges* 18: 101114. <https://doi.org/10.1016/J.ENVC.2025.101114>.
- 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>.
- Ali AM, Abdullah H, Darvishzadeh R, Skidmore AK, Heurich M, Roeoesli C, Paganini M, Heiden U, Marshall D, 2021. Canopy chlorophyll content retrieved from time series remote sensing data as a proxy for detecting bark beetle infestation. *Remote Sens. Appl. Soc. Environ.* 22: 100524. <https://doi.org/10.1016/j.rsase.2021.100524>.
- Ančić M, Pernar R, Cindrić FB, Seletković A, Kolić J, 2019. Hyperspectral sensors and application in forestry. *Nov. Meh. Sumar.* 40: 71–78. <https://doi.org/10.5552/nms.2019.7>.
- 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>.
- Aria M, Cuccurullo C, Gnasso A, 2021. A comparison among interpretative proposals for Random Forests. *Mach. Learn. with Appl.* 6: 100094. <https://doi.org/10.1016/j.mlwa.2021.100094>.
- Bălăcenoiu F, Japelj A, Bernardinelli I, Castagneyrol B, Csóka G, Glavendekić M, Hoch G,

- Hrašovec B, Krajter Ostoic S, Paulin M, Williams D, Witters J, de Groot M, 2021a. Corythucha arcuata (Say, 1832) (Hemiptera, Tingidae) in its invasive range in Europe: perception, knowledge and willingness to act in foresters and citizens. *NeoBiota* 69: 133–153. <https://doi.org/10.3897/NEOBIOTA.69.71851>.
- 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>.
- Bălăcenoiu F, Simon DC, Nețoiu C, Toma D, Petrițan IC, 2021b. The Seasonal Population Dynamics of Corythucha arcuata (Say, 1832) (Hemiptera: Tingidae) and the Relationship between Meteorological Factors and the Diurnal Flight Intensity of the Adults in Romanian Oak Forests. *Forests* 12: 1774. <https://doi.org/10.3390/F12121774>.
- 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>.
- Bauerle WL, Weston DJ, Bowden JD, Dudley JB, Toler JE, 2004. Leaf absorptance of photosynthetically active radiation in relation to chlorophyll meter estimates among woody plant species. *Sci. Hortic. (Amsterdam)*. 101: 169–178. <https://doi.org/10.1016/j.scientia.2003.09.010>.
- Belov ML, Belov AM, Gorodnichev VA, Alkov S V., 2022. MULTISPECTRAL OPTICAL REFLECTOMETRY METHOD OF FOREST RESOURCE MONITORING. *Light Eng.* 30: 51–59. <https://doi.org/10.33383/2021-104>.
- Benko M, Balenovic I, 2011. Prošlost, sadašnjost i budućnost primjene metoda daljinskih istraživanja pri inventuri šuma u Hrvatskoj. *Sumar. List*.
- Bequet R, Campioli M, Kint V, Vansteenkiste D, Muys B, Ceulemans R, 2011. Leaf area index development in temperate oak and beech forests is driven by stand characteristics and weather conditions. *Trees-structure Funct.* 25: 935–946. <https://doi.org/10.1007/S00468-011-0568-4>.

- 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.
- Beumier C, Rubio J, Andreo V, Guzman C, Porcasi X, Scavuzzo CM, Shimoni M, 2021. Semi-Automatic Tool to Count Mosquito Eggs in Ovitrap Stick Images. *Int. Geosci. Remote Sens. Symp.*: 80–83. <https://doi.org/10.1109/IGARSS47720.2021.9555005>.
- Botha EJ, Leblon B, ZebARTH B, Watmough J, 2007. Non-destructive estimation of potato leaf chlorophyll from canopy hyperspectral reflectance using the inverted PROSAIL model. *Int. J. Appl. Earth Obs. Geoinf.* 9: 360–374. <https://doi.org/10.1016/j.jag.2006.11.003>.
- 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](https://doi.org/10.1023/A:1010933404324).
- Brockerhoff EG, Liebold AM, 2017. Ecology of forest insect invasions. *Biol. Invasions* 2017 19(11) 3141–3159. <https://doi.org/10.1007/S10530-017-1514-1>.
- Brockerhoff EG, Corley JC, Jactel H, Miller DR, Rabaglia RJ, Sweeney J, 2023. Monitoring and

Surveillance of Forest Insects. In: *For. Entomol. Pathol. Vol. 1 Entomol.*, Vol. 1, Springer International Publishing, p.669–705.

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>.

Campbell PKE, Middleton EM, McMurtrey JE, Corp LA, Chappelle EW, 2007. Assessment of Vegetation Stress Using Reflectance or Fluorescence Measurements. *J. Environ. Qual.* 36: 832–845. <https://doi.org/10.2134/jeq2005.0396>.

Camps-Valls G, Bruzzone L, 2009. Kernel Methods for Remote Sensing Data Analysis. John Wiley and Sons, 1–403p [10.1002/9780470748992p](https://doi.org/10.1002/9780470748992p).

Camps-Valls G, Gómez-Chova L, Muñoz-Marí J, Vila-Francés J, Amorós J, Del Valle-Tascon S, Calpe-Maravilla J, 2009. Biophysical parameter estimation with adaptive Gaussian processes. *Int. Geosci. Remote Sens. Symp.* 4: 69–72. <https://doi.org/10.1109/IGARSS.2009.5417372>.

Cardil A, Otsu K, Pla M, Silva CA, Brotons L, 2019. Quantifying pine processionary moth defoliation in a pine-oak mixed forest using unmanned aerial systems and multispectral imagery. *PLoS One* 14: e0213027. <https://doi.org/10.1371/journal.pone.0213027>.

Choi W Il, Park YS, 2019. Monitoring, Assessment and Management of Forest Insect Pests and Diseases. *Forests* 10: 865. <https://doi.org/10.3390/F10100865>.

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, Gninenko Y, Dautbašić M, Muzejinović O, Zúbrik M, Netoiu C, Buzatu A, Bălăcenoiu F, Jurec M, Jurec 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>.

Cui J, Zhu SY, Bi R, Xu W, Gao Y, Shi S Sen, 2018. Effect of Temperature on the Development, Survival, and Fecundity of *Heliothis viriplaca* (Lepidoptera: Noctuidae). *J. Econ. Entomol.* 111: 1940–1946. <https://doi.org/10.1093/JEE/TOY151>.

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>.

Du L, Luo S, 2024. Spectral-Frequency Conversion Derived from Hyperspectral Data Combined with Deep Learning for Estimating Chlorophyll Content in Rice. *Agric.* 2024, Vol. 14, Page 1186 14: 1186. <https://doi.org/10.3390/AGRICULTURE14071186>.

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>.

Ecke S, Dempewolf J, Frey J, Schwaller A, Endres E, Klemmt HJ, Tiede D, Seifert T, 2022a. UAV-Based Forest Health Monitoring: A Systematic Review. *Remote Sens.* 2022, Vol. 14, Page 3205 14: 3205. <https://doi.org/10.3390/RS14133205>.

Ecke S, Dempewolf J, Frey J, Schwaller A, Endres E, Klemmt HJ, Tiede D, Seifert T, 2022b. UAV-Based Forest Health Monitoring: A Systematic Review. *Remote Sens.* 2022, Vol. 14, Page 3205 14: 3205. <https://doi.org/10.3390/RS14133205>.

Franjević M, Drvodelić D, Kolar A, Gradečki-Poštenjak M, Hrašovec B, 2018. Impact of oak lace bug *Corythucha arcuata* (Heteroptera: Tingidae) on pedunculate oak (*Quercus robur*) seed quality. : 161–165.

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>.

Ghafarian F, Wieland R, Lütschwager D, Nendel C, 2022. Application of extreme gradient boosting and Shapley Additive explanations to predict temperature regimes inside forests from standard open-field meteorological data. *Environ. Model. Softw.* 156: 105466–105466. <https://doi.org/10.1016/j.envsoft.2022.105466>.

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>.

Gu C, Du H, Mao F, Han N, Zhou G, Xu X, Sun S, Gao G, 2016. Global sensitivity analysis of PROSAIL model parameters when simulating Moso bamboo forest canopy reflectance. *Int. J. Remote Sens.* 37: 5270–5286. <https://doi.org/10.1080/01431161.2016.1239287>.

Guo A, Ye H, Li G, Zhang B, Huang W, Jiao Q, Qian B, Luo P, 2023. Evaluation of Hybrid Models for Maize Chlorophyll Retrieval Using Medium- and High-Spatial-Resolution Satellite Images. *Remote Sens.* 2023, Vol. 15, Page 1784 15: 1784. <https://doi.org/10.3390/RS15071784>.

Gupta SK, Pandey AC, 2022. PROSAIL and empirical model to evaluate spatio-temporal heterogeneity of canopy chlorophyll content in subtropical forest. *Model. Earth Syst. Environ.* 8: 2151–2165. <https://doi.org/10.1007/s40808-021-01214-4>.

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>.

Huo L, Persson HJ, Lindberg E, 2021. Early detection of forest stress from European spruce bark beetle attack, and a new vegetation index: Normalized distance red & SWIR (NDRS). *Remote Sens. Environ.* 255. <https://doi.org/10.1016/j.rse.2020.112240>.

Hutomo E. P. E, Adibawa MAS, Prilanti KR, Heriyanto H, Brotosudarmo THP, 2016. Low-cost chlorophyll meter (LCCM): portable measuring device for leaf chlorophyll. *Second Int. Semin. Photonics, Opt. Its Appl. (ISPhOA 2016)* 10150: 101500V. <https://doi.org/10.1117/12.2243607>.

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>.
- Jiao Z, 2024. The Application of Remote Sensing Techniques in Ecological Environment Monitoring. *Highlights Sci. Eng. Technol.* 81: 449–455. <https://doi.org/10.54097/7dqegz64>.
- Jovanović D, Gavrilović M, Borisov M, Govedarica 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>.
- Kanaskie CR, Routhier MR, Fraser BT, Congalton RG, Ayres MP, Garnas JR, 2024. Early Detection of Southern Pine Beetle Attack by UAV-Collected Multispectral Imagery. *Remote Sens.* 16: 2608. <https://doi.org/10.3390/RS16142608/S1>.
- Kancheva R, Borisova D, Georgiev G, 2014. CHLOROPHYLL ASSESSMENT AND STRESS DETECTION FROM VEGETATION OPTICAL PROPERTIES. *Ecol. Eng. Environ. Prot.*: 34–43.
- Kern A, Marjanović H, Csóka G, Móricz N, Pernek M, Hirka A, Matošević D, Paulin M, Kovač G, 2021. Detecting the oak lace bug infestation in oak forests using MODIS and meteorological data. *Agric. For. Meteorol.* 306: 108436. <https://doi.org/10.1016/j.agrformet.2021.108436>.
- Kwak SG, Kim JH, 2017. Central limit theorem: the cornerstone of modern statistics. *Korean J. Anesthesiol.* 70: 144. <https://doi.org/10.4097/KJAE.2017.70.2.144>.
- Lary DJ, Alavi AH, Gandomi AH, Walker AL, 2016. Machine learning in geosciences and remote

- sensing. *Geosci. Front.* 7: 3–10. <https://doi.org/10.1016/J.GSF.2015.07.003>.
- Le TS, Harper R, Dell B, 2023. Application of Remote Sensing in Detecting and Monitoring Water Stress in Forests. *Remote Sens.* 15: 3360–3360. <https://doi.org/10.3390/rs15133360>.
- Leckey EH, Smith DM, Nufio CR, Fornash KF, 2014. Oak-insect herbivore interactions along a temperature and precipitation gradient. *Acta Oecologica* 61: 1–8. <https://doi.org/10.1016/j.actao.2014.08.001>.
- Legros Q, Pontet C, Robert C, 2024. Using random forest algorithm to improve *Ceutorhynchus napi* GYLL. (Coleoptera: Curculionidae) occurrence forecasting. *J. Appl. Entomol.*. <https://doi.org/10.1111/jen.13316>.
- Li D, Chen JM, Yu W, Zheng H, Yao X, Zhu Y, Cao W, Cheng T, 2024. A chlorophyll-constrained semi-empirical model for estimating leaf area index using a red-edge vegetation index. *Comput. Electron. Agric.* 220: 108891–108891. <https://doi.org/10.1016/j.compag.2024.108891>.
- Li X, Zhang T, Yang Z, Chen J, 2022. Site Selection of New PM2.5 Mobile Monitoring Station Based on Ordinary Kriging Interpolation. *Int. Conf. Geoinformatics* 2022-August: 1–5. <https://doi.org/10.1109/GEOINFORMATICS57846.2022.9963798>.
- Li Y, Wang B, Zhao X, Zhang Y, Qiao L, 2025. Inversion and analysis of leaf area index (LAI) of urban park based on unmanned aerial vehicle (UAV) multispectral remote sensing and random forest (RF). *PLoS One* 20: e0320608. <https://doi.org/10.1371/JOURNAL.PONE.0320608>.
- Li Z, Guo X, 2013. Leaf area index estimation in semiarid mixed grassland by considering both temporal and spatial variations. *J. Appl. Remote Sens.* 7: 073567–073567. <https://doi.org/10.1117/1.JRS.7.073567>.
- Lichtenthaler HK, Wenzel O, Buschmann C, Gitelson A, 1998. Plant stress detection by reflectance and fluorescence. *Ann. N. Y. Acad. Sci.* 851: 271–285. <https://doi.org/10.1111/j.1749-6632.1998.tb09002.x>.
- Liebhold AM, Tobin PC, 2008. Population ecology of insect invasions and their management. *Annu. Rev. Entomol.* 53: 387–408. <https://doi.org/10.1146/annurev.ento.52.110405.091401>.

Liu X, Rohr JR, Li X, Deng T, Li W, Li Y, 2021. Climate extremes, variability, and trade shape biogeographical patterns of alien species. *Curr. Zool.* 67: 393–402. <https://doi.org/10.1093/CZ/ZOAA068>.

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

Longbotham N, Pacifici F, Malitz S, Baugh W, Camps-Valls G, 2015. Measuring the Spatial and Spectral Performance of WorldView-3. *Hyperspectral Imaging Sound. Environ. HISE 2015*. <https://doi.org/10.1364/HISE.2015.HW3B.2>.

Lu Y, 2025. Sustainable Forestry Approaches for Combating Invasive Species: A Global Perspective. *Theor. Nat. Sci.* 75: 27–33. <https://doi.org/10.54254/2753-8818/2024.LA19344>.

Maciej Serda, Becker FG, Cleary M, Team RM, Holtermann H, The D, Agenda N, Science P, Sk SK, Hinnebusch R, Hinnebusch A R, Rabinovich I, Olmert Y, Uld DQGLQ, Ri WKHU, Lq V, Frxqwu WKH, Zklfk E, Edvhg L V, Wkh RQ, Becker FG, Aboueldahab N, Khalaf R, De Elvira LR, Zintl T, Hinnebusch R, Karimi M, Mousavi Shafaee SM, O 'driscoll D,i ostali, 2024. Predicting the European Invasion of the Oak Lace Bug: A Species Distribution Modelling Perspective. *Uniw. śląski* 7: 740–741. <https://doi.org/10.2/JQUERY.MIN.JS>.

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>.

Mateo-Sanchis A, Muñoz-Marí J, Pérez-Suay A, Camps-Valls G, 2018. Warped Gaussian Processes in Remote Sensing Parameter Estimation and Causal Inference. *IEEE Geosci. Remote Sens. Lett.* 15: 1647–1651. <https://doi.org/10.1109/LGRS.2018.2853760>.

McCullough DG, 2020. Challenges, tactics and integrated management of emerald ash borer in North America. *For. An Int. J. For. Res.* 93: 197–211. <https://doi.org/10.1093/FORESTRY/CPZ049>.

Meno L, Escuredo O, Abuley IK, Seijo MC, 2023. Predicting Daily Aerobiological Risk Level of Potato Late Blight Using C5.0 and Random Forest Algorithms under Field Conditions. *Sensors* 23: 3818–3818. <https://doi.org/10.3390/s23083818>.

Minařík R, Langhammer J, 2016. Use of a multispectral UAV photogrammetry for detection and tracking of forest disturbance dynamics. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* - ISPRS Arch. 41: 711–718. <https://doi.org/10.5194/ISPRSARCHIVES-XLI-B8-711-2016>.

Moley LM, Goodin DG, Winslow WP, 2022. Leaf-Level Spectroscopy for Analysis of Invasive Pest Impact on Trees in a Stressed Environment: An Example Using Emerald Ash Borer (*Agrilus planipennis* Fairmaire) in Ash Trees (*Fraxinus* spp.), Kansas, USA. *Environ.* 2022, Vol. 9, Page 42 9: 42. <https://doi.org/10.3390/ENVIRONMENTS9040042>.

Molnár T, Király G, 2023. Forest Monitoring Based on Sentinel-2 Satellite Imagery, Google Earth Engine Cloud Computing, and Machine Learning. <https://doi.org/10.20944/PREPRINTS202307.0800.V1>.

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>.

Morcillo-Pallarés P, Rivera-Caicedo JP, Belda S, De Grave C, Burriel H, Moreno J, Verrelst J, 2019. Quantifying the robustness of vegetation indices through global sensitivity analysis of homogeneous and forest leaf-canopy radiative transfer models. *Remote Sens.* 11: 2418. <https://doi.org/10.3390/rs11202418>.

Moustaka J, Moustakas M, 2023. Early-Stage Detection of Biotic and Abiotic Stress on Plants by Chlorophyll Fluorescence Imaging Analysis. *Biosensors* 13: 796. <https://doi.org/10.3390/BIOS13080796/S1>.

Nikolić N, Pilipović A, Drekić M, Kojić D, Poljaković-Pajnik L, Orlović S, Arsenov D, 2019. Physiological responses of pedunculate oak (*Quercus robur* L.) to *Corythucha arcuata* (Say, 1832) attack. *Arch. Biol. Sci.* 71: 167–176. <https://doi.org/10.2298/ABS180927058N>.

Nofrizal AY, Sonobe R, Yamashita H, Morita A, Ikka T, 2022. Estimating chlorophyll content of *Zizania latifolia* with hyperspectral data and random forest. *Int. J. Eng. Geosci.* 7: 221–228. <https://doi.org/10.26833/ijeg.953188>.

Oswalt S, Oswalt C, Crall A, Rabaglia R, Schwartz MK, Kerns BK, 2021. Inventory and Monitoring of Invasive Species. In: *Invasive Species For. Rangelands United States A Compr. Sci. Synth. United States For. Sect.*, Springer, Cham, p.231–242.

Pacheco-Labrador J, Cendrero-Mateo MP, Van Wittenberghe S, Hernandez-Sequeira I, Koren G, Prikaziuk E, Fóti S, Tomelleri E, Maseyk K, Čereković N, Gonzalez-Cascon R, Malenovsky Z, Albert-Saiz M, Antala M, Balogh J, Buddenbaum H, Dehghan-Shoar MH, Fennell JT, Feret J-B, Balde H, Machwitz M, Mészáros Á, Miao G, Morata M, Naethe P, Nagy Z, Pintér K, Pullanagari RR, Rastogi A, i ostali, 2024. Ecophysiological variables retrieval and early stress detection: insights from a synthetic spatial scaling exercise. *Int. J. Remote Sens.*: 1–26. <https://doi.org/10.1080/01431161.2024.2414435>.

Pasolli L, Melgani F, Blanzieri E, 2010. Gaussian Process Regression for Estimating Chlorophyll Concentration in Subsurface Waters From Remote Sensing Data. *IEEE Geosci. Remote Sens. Lett.* 7: 464–468. <https://doi.org/10.1109/LGRS.2009.2039191>.

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>.

Pearson TC, Edwards RH, Mossman AP, Wood DF, Yu PC, Miller EL, 2002. Insect egg counting on mass rearing oviposition pads by image analysis. *Appl. Eng. Agric.* 18: 129–135. <https://doi.org/10.13031/2013.7696>.

Preti M, Verheggen F, Angeli S, 2021. Insect pest monitoring with camera-equipped traps: strengths and limitations. *J. Pest Sci. (2004)*. 94: 203–217. <https://doi.org/10.1007/S10340-020-01309-4>.

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>.

Rouse RWH, Haas JAW, Schell JA, Deering DW, 1974. Monitoring vegetation systems in the Great Plains with ERTS (Earth Resources Technology Satellites). *Goddard Sp. Flight Cent. 3d ERTS-1* 1: 309–317.

Roy DP, Huang H, Houborg R, Martins VS, 2021. A global analysis of the temporal availability of PlanetScope high spatial resolution multi-spectral imagery. *Remote Sens. Environ.* 264:

112586. <https://doi.org/10.1016/J.RSE.2021.112586>.

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>.

Savinelli B, Tagliabue G, Vignali L, Garzonio R, Gentili R, Panigada C, Rossini M, 2024. Integrating Drone-Based LiDAR and Multispectral Data for Tree Monitoring. *Drones 2024*, Vol. 8, Page 744 8: 744. <https://doi.org/10.3390/DRONES8120744>.

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

Simberloff D, Martin JL, Genovesi P, Maris V, Wardle DA, Aronson J, Courchamp F, Galil B, García-Berthou E, Pascal M, Pyšek P, Sousa R, Tabacchi E, Vilà M, 2013. Impacts of biological invasions: what's what and the way forward. *Trends Ecol. Evol.* 28: 58–66. <https://doi.org/10.1016/J.TREE.2012.07.013>.

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>.

Simic Milas A, Romanko M, Reil P, Abeysinghe T, Marambe A, 2018. The importance of leaf area index in mapping chlorophyll content of corn under different agricultural treatments using UAV images. *Int. J. Remote Sens.* 39: 5415–5431. <https://doi.org/10.1080/01431161.2018.1455244>.

Simon SM, Glaum P, Valdovinos FS, 2023. Interpreting random forest analysis of ecological models to move from prediction to explanation. *Sci. Rep.* 13. <https://doi.org/10.1038/s41598-023-30313-8>.

Singhal G, Bansod B, Mathew L, Goswami J, Choudhury BU, Raju PLN, 2019. Chlorophyll estimation using multi-spectral unmanned aerial system based on machine learning

techniques. *Remote Sens. Appl. Soc. Environ.* 15: 100235.
<https://doi.org/10.1016/J.RSASE.2019.100235>.

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>.

Skidmore AK, 1989. Extracting forest resource information from remotely sensed and ancillary data: use of an expert system. . <https://doi.org/10.25911/5D67B45A1DDA8>.

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, 2021a. 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>.

Sun J, Yang L, Yang X, Wei J, Li L, Guo E, Kong Y, 2021b. Using Spectral Reflectance to Estimate the Leaf Chlorophyll Content of Maize Inoculated With Arbuscular Mycorrhizal Fungi Under Water Stress. *Front. Plant Sci.* 12: 646173.
<https://doi.org/10.3389/FPLS.2021.646173/FULL>.

Sun J, Wang L, Shi S, Li Z, Yang J, Gong W, Wang S, Tagesson T, 2022. Leaf pigment retrieval using the PROSAIL model: Influence of uncertainty in prior canopy-structure information. *Crop J.* 10: 1251–1263. <https://doi.org/10.1016/j.cj.2022.04.003>.

Sun Y, Ren H, Zhang T, Zhang C, Qin Q, 2018. Crop Leaf Area Index Retrieval Based on Inverted Difference Vegetation Index and NDVI. *IEEE Geosci. Remote Sens. Lett.* 15: 1662–1666.
<https://doi.org/10.1109/LGRS.2018.2856765>.

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>.

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>.
- Talebzadeh F, Valeo C, 2022. Evaluating the Effects of Environmental Stress on Leaf Chlorophyll Content as an Index for Tree Health. *IOP Conf. Ser. Earth Environ. Sci.* 1006: 012007–012007. <https://doi.org/10.1088/1755-1315/1006/1/012007>.
- Tavakoli H, Mohtasebi SS, Alimardani R, Gebbers R, 2014. Evaluation of different sensing approaches concerning to nondestructive estimation of leaf area index (lai) for winter wheat. *Int. J. Smart Sens. Intell. Syst.* 7: 337–359. <https://doi.org/10.21307/IJSSIS-2017-659>.
- 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>.
- Ugolini F, Massetti L, Pedrazzoli F, Tognetti R, Vecchione A, Zulini L, Maresi G, 2014. Ecophysiological responses and vulnerability to other pathologies in European chestnut coppices, heavily infested by the Asian chestnut gall wasp. *For. Ecol. Manage.* 314: 38–49. <https://doi.org/10.1016/J.FORECO.2013.11.031>.
- Varvia P, Rautiainen M, Seppänen A, 2017. Modeling uncertainties in estimation of canopy LAI from hyperspectral remote sensing data – A Bayesian approach. *J. Quant. Spectrosc. Radiat. Transf.* 191: 19–29. <https://doi.org/10.1016/j.jqsrt.2017.01.029>.
- Vedurmudi AP, Janzen K, Nagler M, Eichstaedt S, 2023. Uncertainty-aware temperature interpolation for measurement rooms using ordinary Kriging. *Meas. Sci. Technol.* 34: 064007–064007. <https://doi.org/10.1088/1361-6501/ACC2D8>.
- 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).
- 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, 2016a. 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, Dethier S, Rivera JP, Munoz-Mari J, Camps-Valls G, Moreno J, 2016b. 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, Malenovský Z, Van der Tol C, Camps-Valls G, Gastellu-Etchegorry JP, Lewis P, North P, Moreno J, 2019. Quantifying Vegetation Biophysical Variables from Imaging Spectroscopy Data: A Review on Retrieval Methods. *Surv. Geophys.* 40: 589–629. <https://doi.org/10.1007/s10712-018-9478-y>.
- 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>.
- Wang Q, Lu X, Zhang H, Yang B, Gong R, Zhang J, Jin Z, Xie R, Xia J, Zhao J, 2023. Comparison of Machine Learning Methods for Estimating Leaf Area Index and Aboveground Biomass of *Cinnamomum camphora* Based on UAV Multispectral Remote Sensing Data. *For.* 2023, Vol. 14, Page 1688 14: 1688. <https://doi.org/10.3390/F14081688>.
- 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>.
- Wittenberg R, Cock MJW, 2001. Invasive Alien Species: A Toolkit of Best Prevention and Management Practices. *CAB Int.*: 228.
- Wu Z, Zhao C, Qin Q, 2022a. Evaluating the Impact of Spatial Heterogeneity on the Prosail Model and Lai Inversion. *Int. Geosci. Remote Sens. Symp.* 2022-July: 6260–6263. <https://doi.org/10.1109/IGARSS46834.2022.9884257>.
- Wu Z, Zhao C, Qin Q, 2022b. Evaluating the Impact of Spatial Heterogeneity on the Prosail Model and Lai Inversion. *Int. Geosci. Remote Sens. Symp.* 2022-July: 6260–6263. <https://doi.org/10.1109/IGARSS46834.2022.9884257>.
- Xie Q, Dash J, Huang W, Peng D, Qin Q, Mortimer H, Casa R, Pignatti S, Laneve G, Pascucci S, Dong Y, Ye H, 2018. Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 11: 1482–1492. <https://doi.org/10.1109/JSTARS.2018.2813281>.
- 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 51 5: 1–12. <https://doi.org/10.1038/srep13389>.
- Xu Z, Zhang C, Xiang S, Chen L, Yu X, Li H, Li Z, Guo X, Zhang H, Huang X, Guan F, 2024. A Hybrid Method of PROSAIL RTM for the Retrieval Canopy LAI and Chlorophyll Content of Moso Bamboo (*Phyllostachys Pubescens*) Forests from Sentinel-2 MSI Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*. <https://doi.org/10.1109/JSTARS.2024.3522774>.
- 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>.

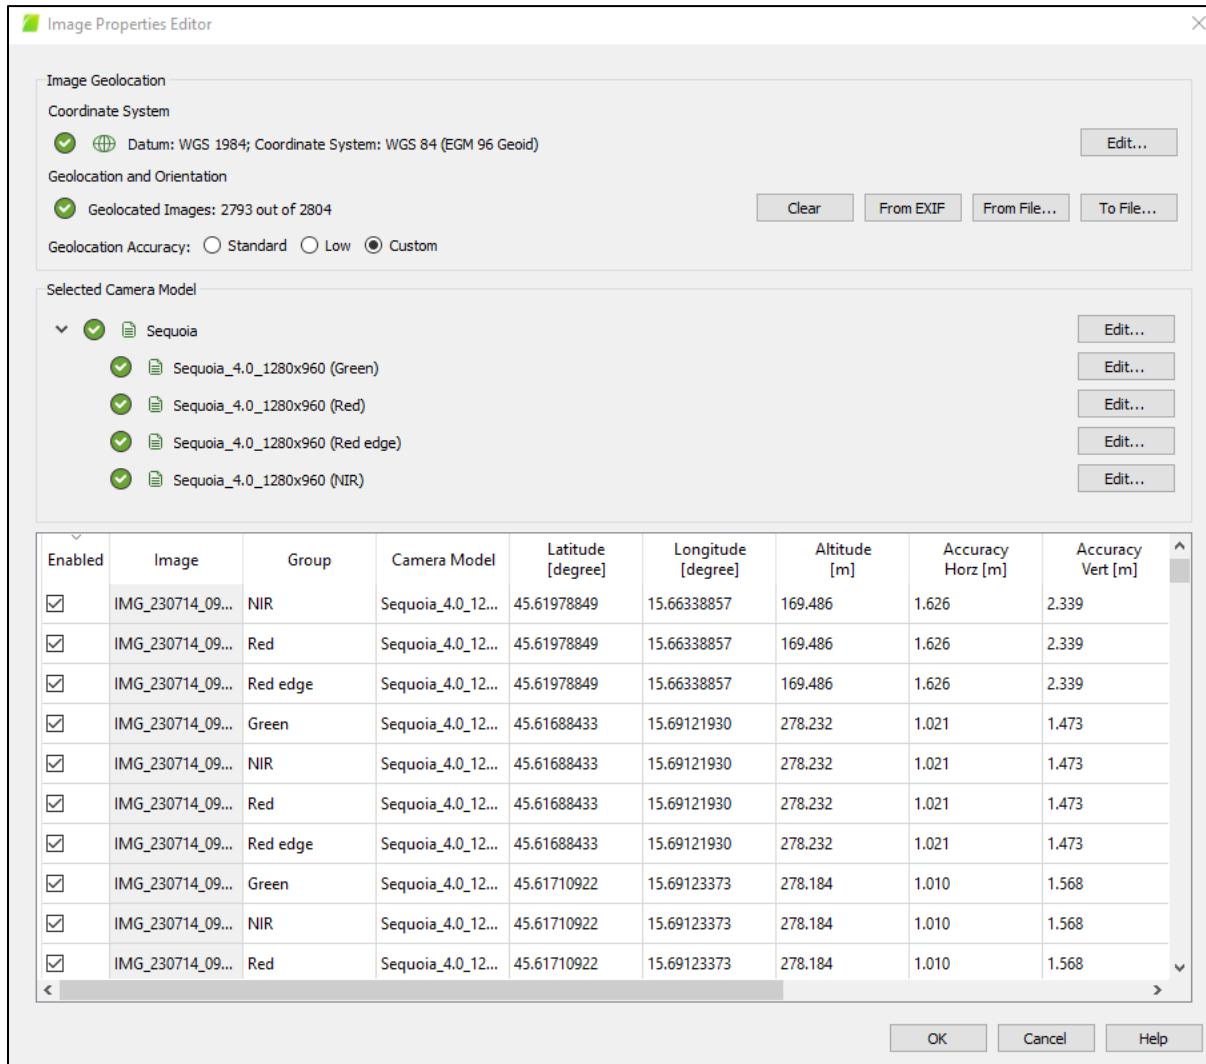
Zarco-Tejada PJ, Miller JR, Mohammed GH, Noland TL, Sampson PH, 2002. Vegetation Stress Detection through Chlorophyll a + b Estimation and Fluorescence Effects on Hyperspectral Imagery. *J. Environ. Qual.* 31: 1433–1441. <https://doi.org/10.2134/JEQ2002.1433>.

Zhang R, Yang P, Liu S, Wang C, Liu J, 2022. Evaluation of the Methods for Estimating Leaf Chlorophyll Content with SPAD Chlorophyll Meters. *Remote Sens.* 2022, Vol. 14, Page 5144 14: 5144. <https://doi.org/10.3390/RS14205144>.

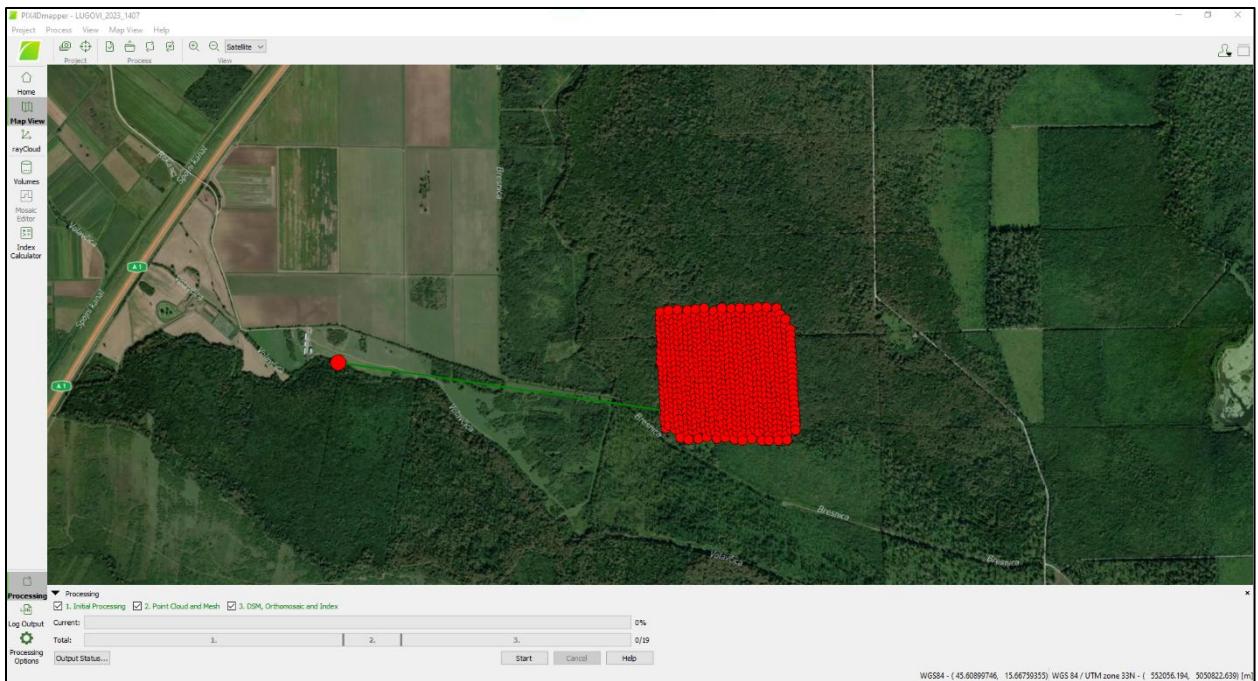
Zorić N, Franjević M, Matošević D, 2023. Further Spread of *Corythucha arcuata* (Hemiptera; Tingidae) in Croatia. *South-east Eur. For.* SEEFOR 14: 111–115. <https://doi.org/10.15177/SEEFOR.23-06>.

8. PRILOZI

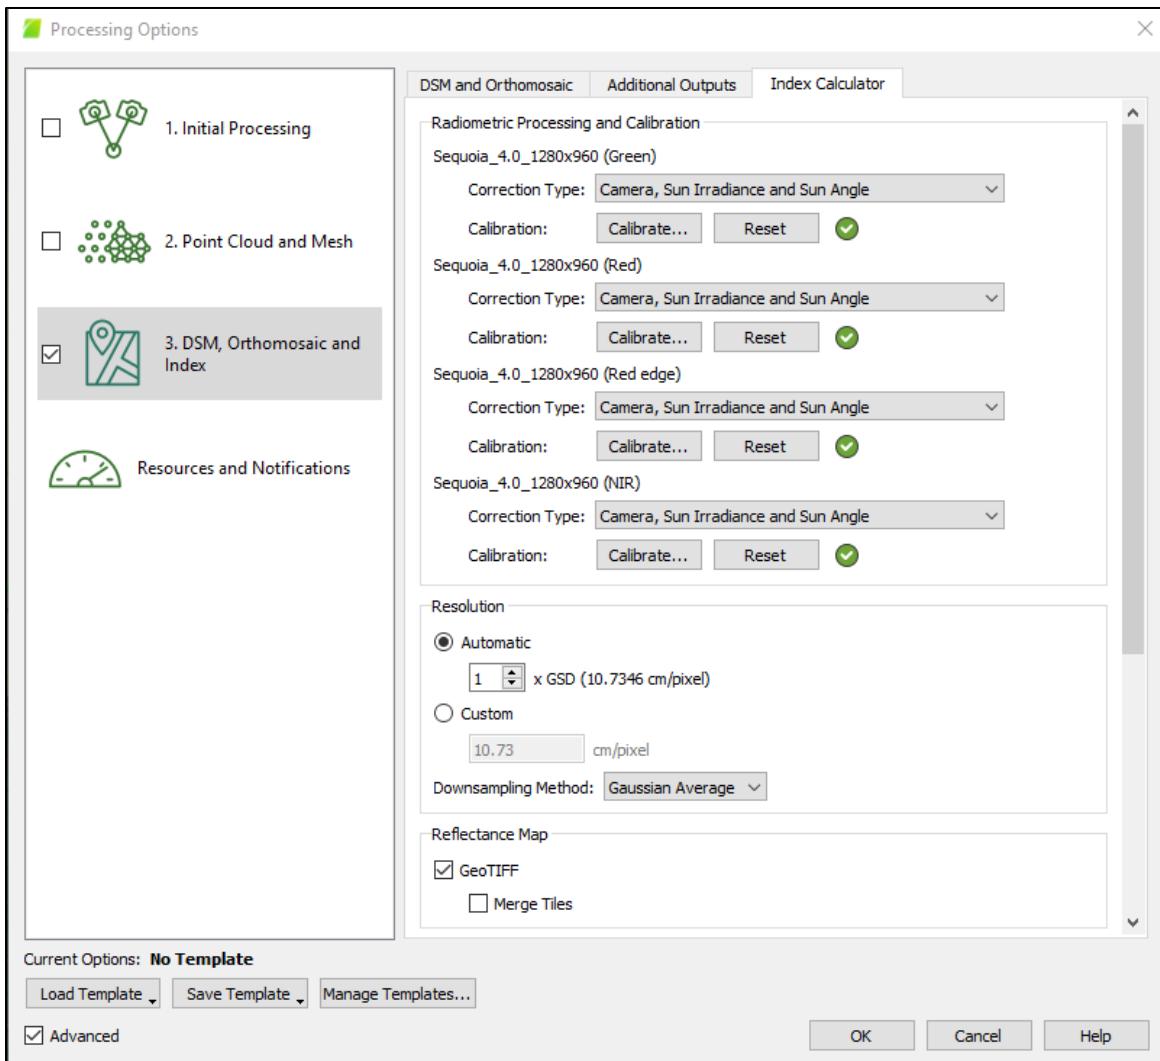
PRILOG 1 Obrada multispektralnih podataka u softveru Pix4D. Prilog prikazuje ključne korake pretprocesiranja podataka prikupljenih multispektralnim senzorom Parrot Sequoia pomoću bespilotne letjelice (UAV). Prikazane su snimke zaslona svih faza obrade: inicijalni pregled i uvoz snimaka, kalibracija reflektivnosti pomoću referentnih ploča, georeferenciranje, generiranje ortomozaika i pojedinačnih reflektivnih slojeva po kanalima (550, 668, 735 i 790 nm)



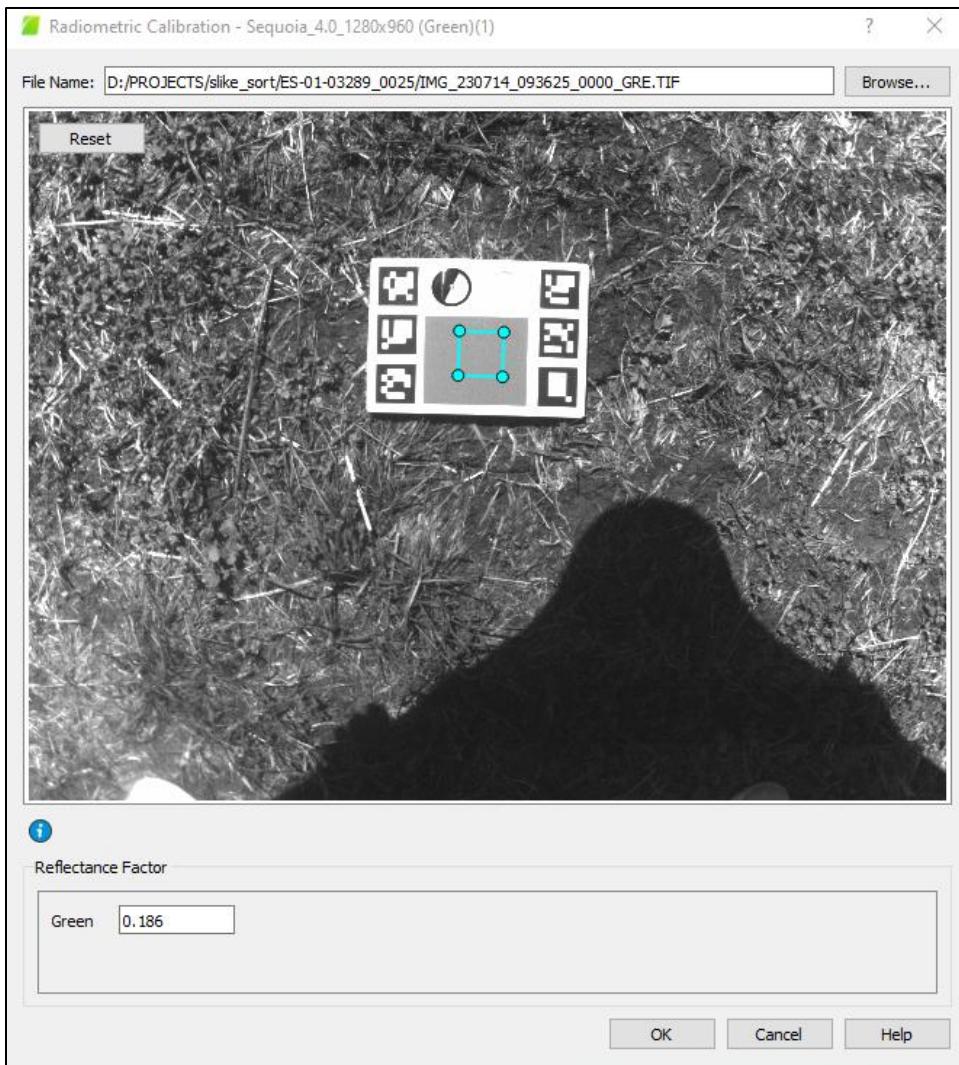
P1 - 1 Inicijalni pregled i učitavanje multispektralnih snimaka u Pix4D programskoj podršci. Prikaz sučelja nakon kreiranja novog projekta i učitavanja snimki prikupljenih multispektralnim senzorom Parrot Sequoia. Vidljive su informacije o broju snimki, rasporedu leta i osnovnim metapodacima (npr. visina leta, vremenska oznaka), što čini prvi korak u obradi i validaciji kvalitete ulaznog materijala.



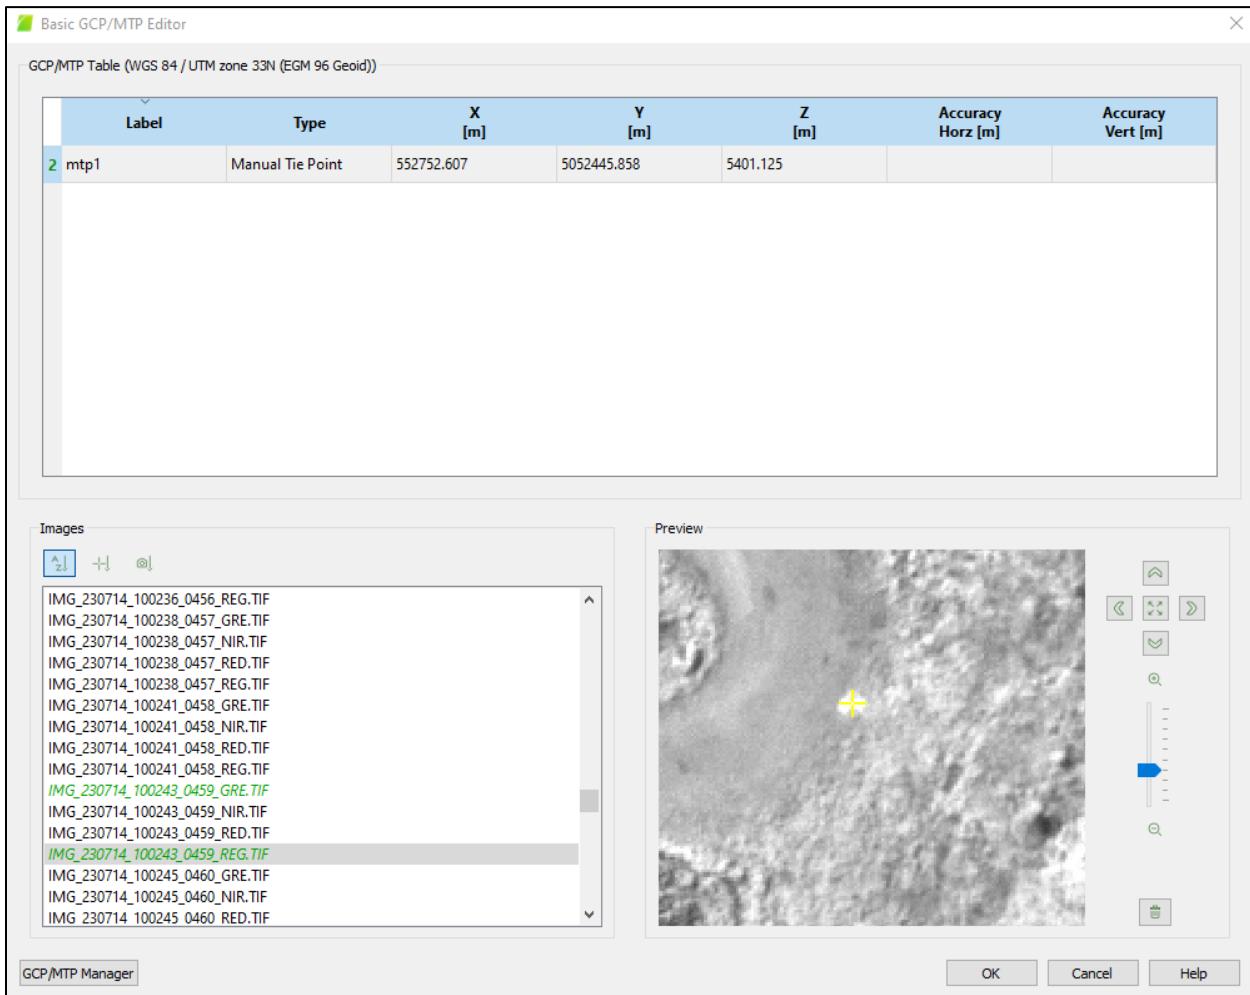
P1 - 2 Osnovni pregled snimaka unutar Pix4D programske podrške nakon učitavanja podataka. Crvene oznake prikazuju geolocirane snimke koje su uspješno učitane u programsko sučelje. Prikaz služi za provjeru pokrivenosti područja snimanja, rasporeda letova i eventualnih praznina u podatkovnom setu prije nastavka obrade.



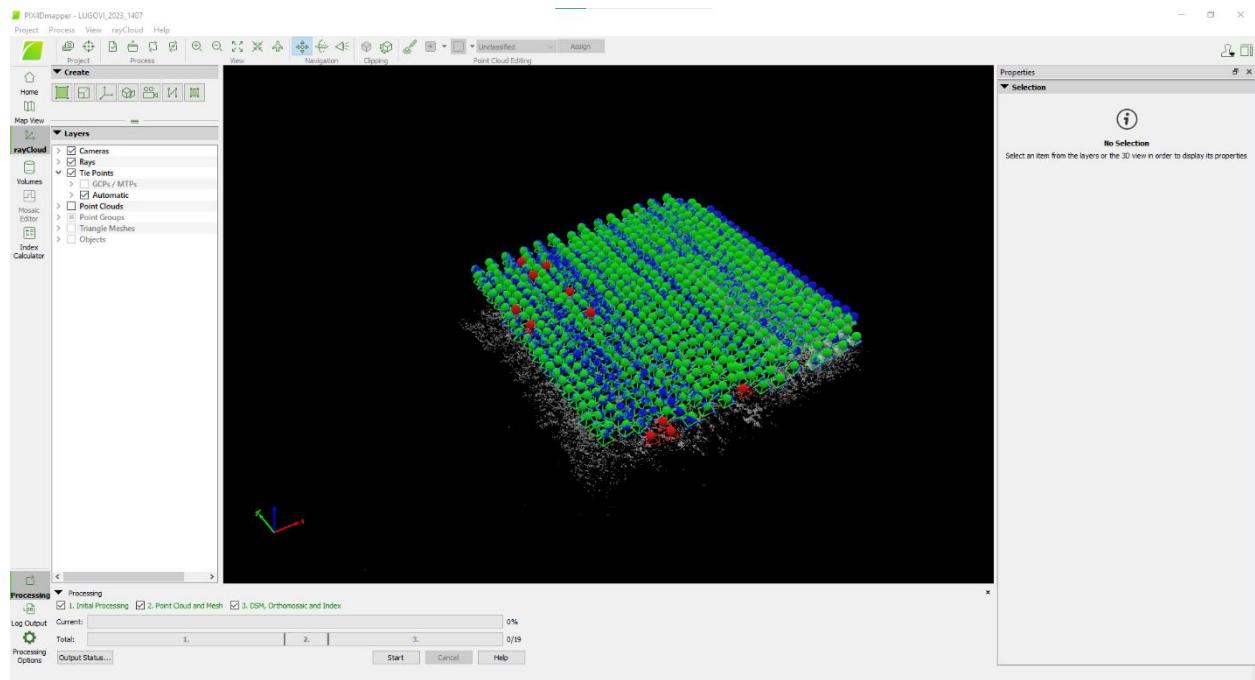
P1 - 3 Prikaz sučelja za provedbu radijometrijske kalibracije prije pokretanja procesa obrade. Kalibracija se temelji na referentnim površinama (reflektivnim pločama) snimljenima tijekom leta, čime se osigurava transformacija digitalnih vrijednosti u apsolutne reflektivnosti.



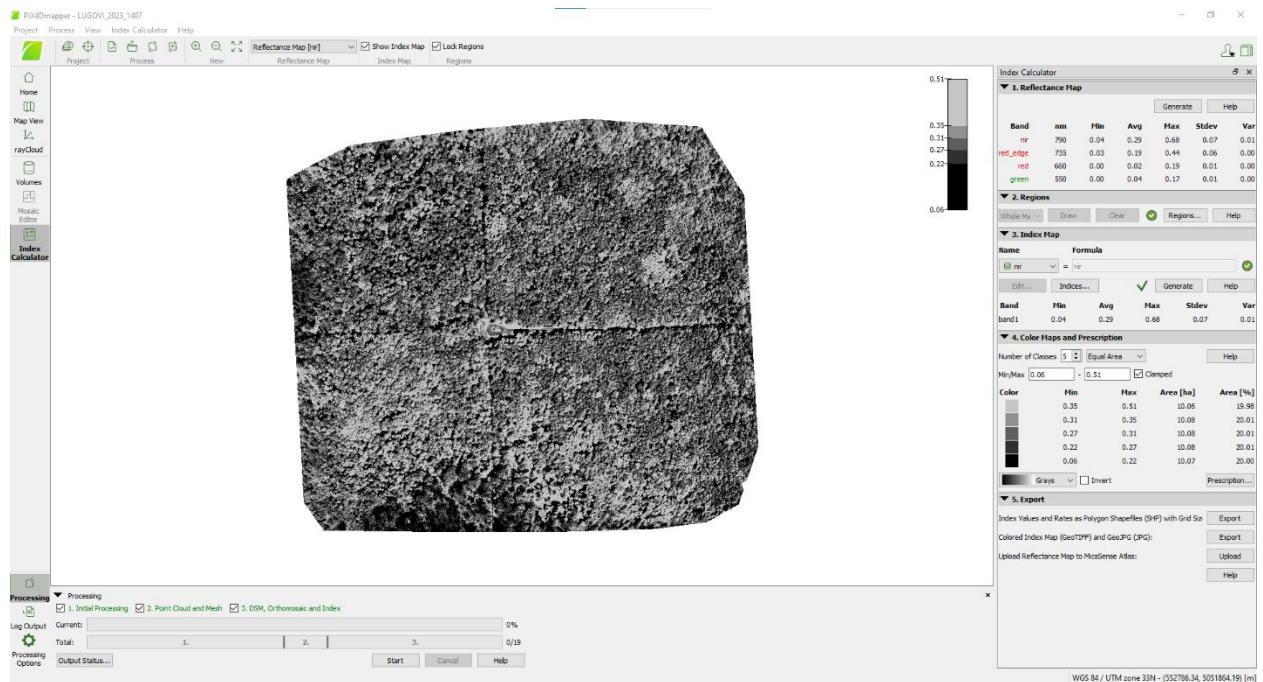
P1 - 4 Očitavanje reflektivnosti s kalibracijskog panela u Pix4D softveru. Na prikazanoj snimci vidljiv je kalibracijski panel koji se koristi za određivanje referentnih vrijednosti reflektivnosti. Označeno je područje kalibracije unutar panela te je očitan faktor refleksije, koji se koristi za korekciju svih snimki u projektu.



P1 - 5 Označavanje terenskih kontrolnih točaka (GCP) unutar sučelja Basic GCP/MTP Editor u Pix4D programskoj podršci

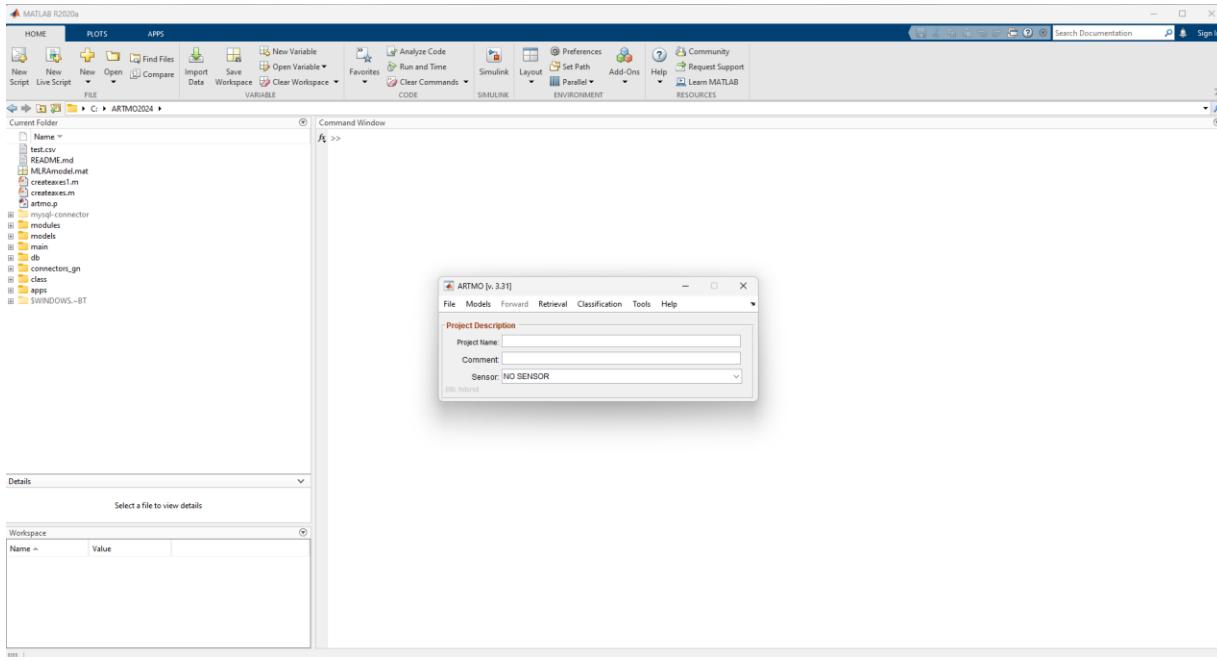


P1 - 6 Oblak točaka prikazuje pozicije snimki, rekonstrukciju 3D točaka te poveznice između GCP točaka i njihovih projekcija na slike

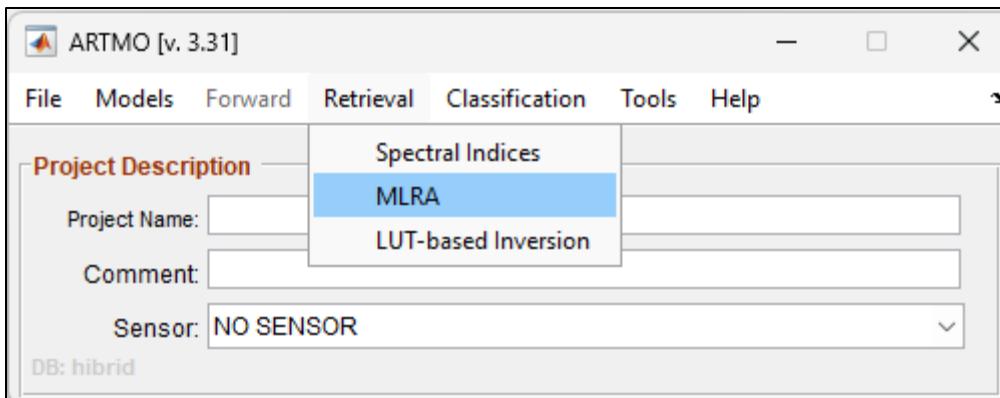


P1 - 7 Prikazana je karta reflektivnosti NIR kanala, generirana nakon uspješne fotogrametrijske obrade i radijometrijske kalibracije u Pix4D programskoj podršci. Ova karta korištena je kao osnovni ulaz za daljnju analizu, odnosno očitavanje vrijednosti refleksije unutar definiranih poligona pomoću Zonal Statistics alata u QGIS-u, što je služilo kao temelj za treniranje regresijskih modela u ARTMO platformi.

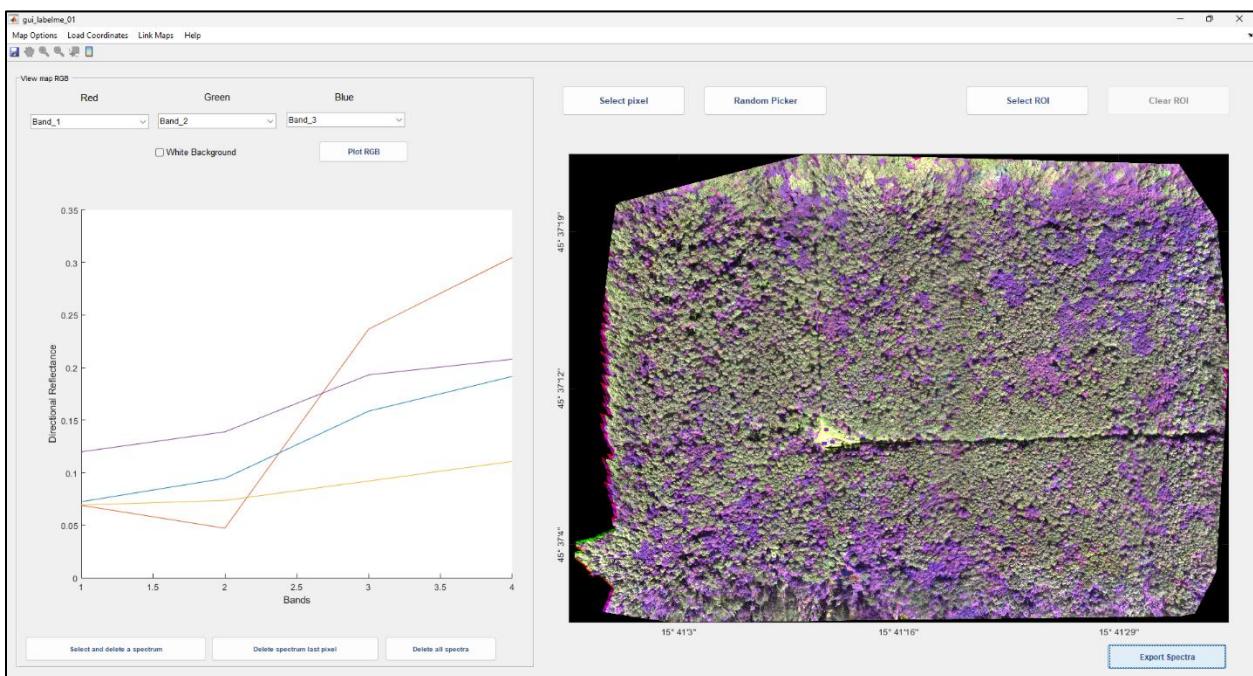
Prilog 2 Vizualni prikaz tijeka modeliranja u ARTMO platformi. Prilog prikazuje niz snimki zaslona koji dokumentiraju ključne faze rada u ARTMO platformi, razvijenoj u MATLAB okruženju, korištene za regresijsko modeliranje koncentracije klorofila krošnje (CCC).



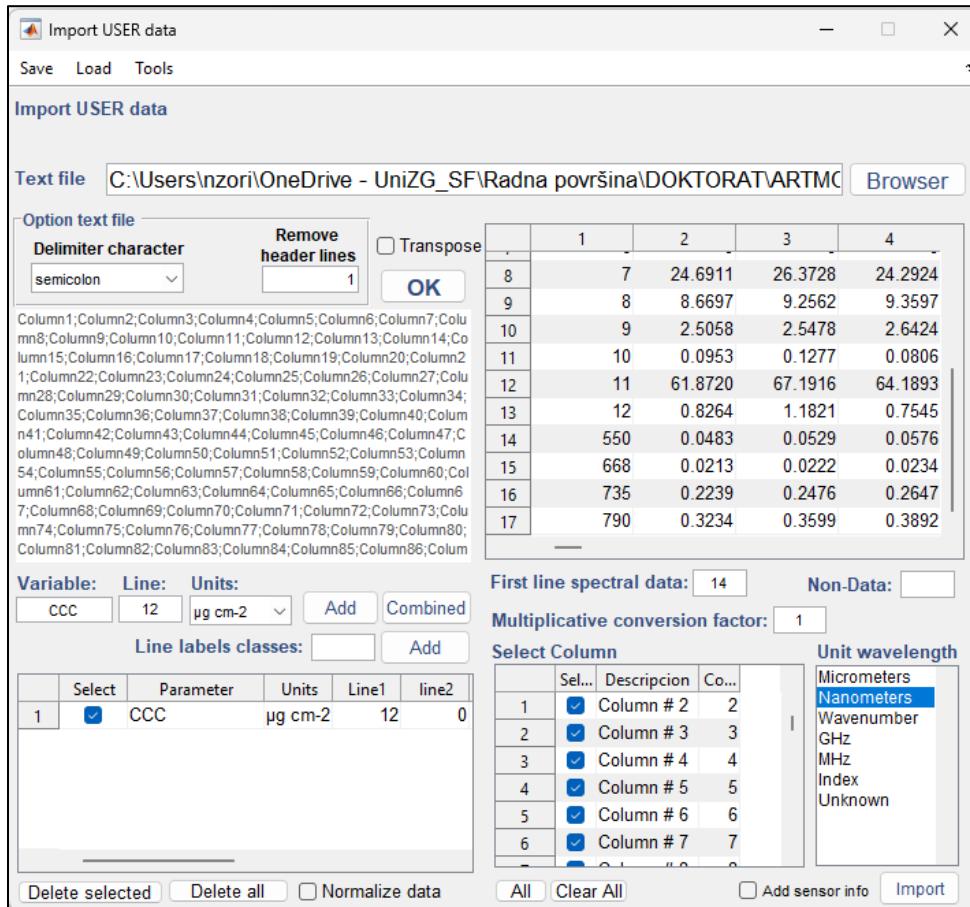
P2 - 1 Prikaz početnog grafičkog sučelja ARTMO platforme u MATLAB programskom jeziku, unutar koje se provode regresijske analize, upravljanje ulaznim podacima i izvođenje modela strojnog učenja



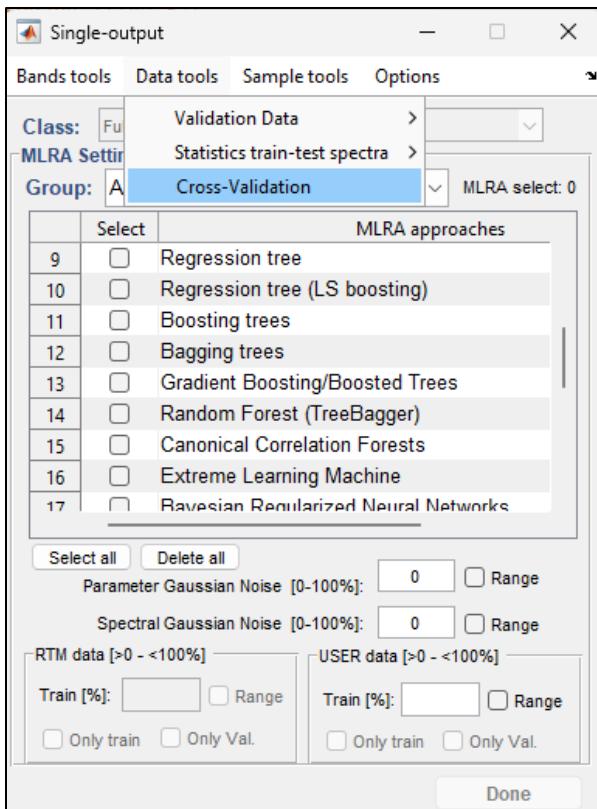
P2 - 2 Modul za MLRA (Machine Learning Regression Algorithms) u kojem se integriraju različiti regresijski algoritmi te konfiguriraju opcije za treniranje, testiranje i evaluaciju modela.



P2 - 3 LABEL ME sučelje korišteno za identifikaciju i selekciju spektralnih vrijednosti tla unutar seta podataka. Reflektivnost tla očitana je sa UAV snimki i dodana u ulazne podatke s ciljem povećanja varijabilnosti modela. Biofizičkim varijablama za tlo pridružene su vrijednosti jednake nuli, budući da se odnose na nepokrivene površine bez vegetacije.

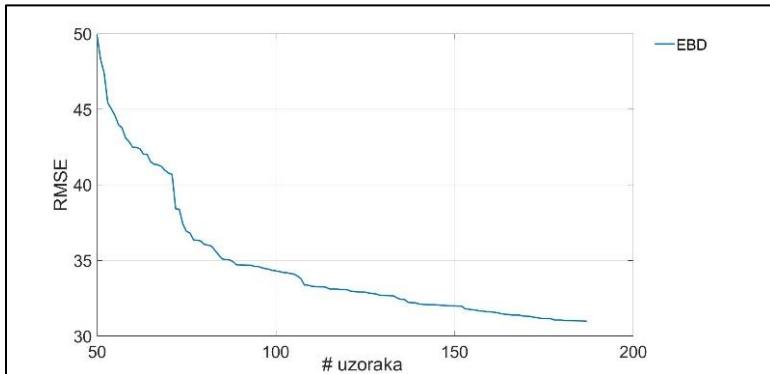


P2 - 4 Prikaz sučelja u kojem se unose ulazni podaci uključujući reflektivnosti po kanalima i terenska mjerena (npr. CCC, LAI). Podaci su strukturirani u skladu s ARTMO zahtjevima.

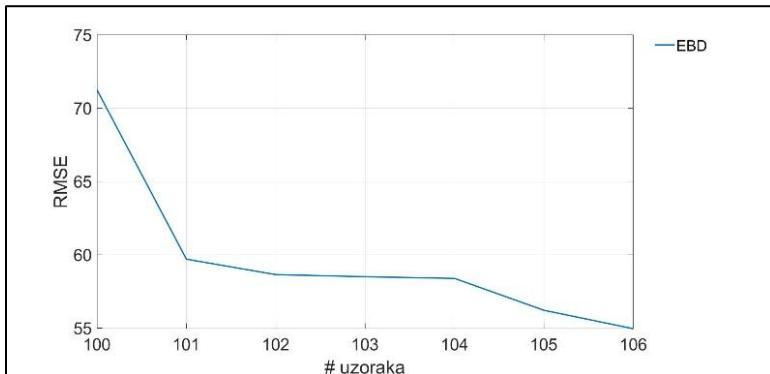


P2 - 5 Korisničko sučelje za izbor regresijskog algoritma (npr. GPR, RF, LSRL) i definiranje parametara validacije (npr. k-struka unakrsna validacija), čime se procjenjuje robusnost i točnost modela.

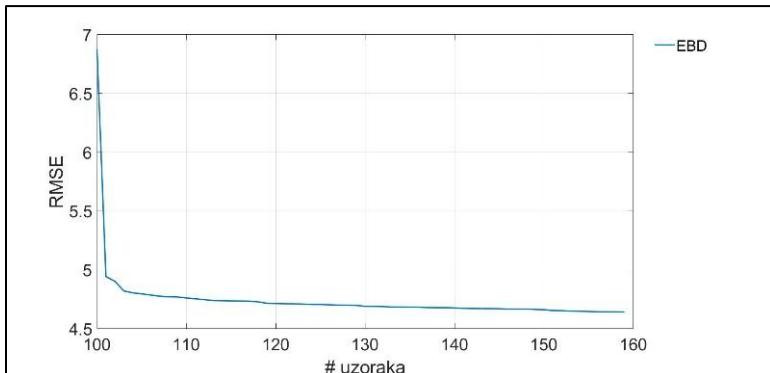
Prilog 3 Rezultati aktivnog učenja (*Active Learning*) za odabir optimalnog broja uzoraka iz LUT-a (*Look up Table*) korištenog u hibridnom modeliranju koncentracije klorofila krošnje (CCC) pomoću PROSAIL+GPR pristupa. Aktivno učenje je provedeno zasebno za plohu A (zaražena) i plohu B (kontrolna) u svibnju, srpnju i rujnu tijekom razdoblja 2021.-2023. godine. Prikazane vrijednosti RMSE po iteracijama omogućile su određivanje broja informativnih uzoraka iz LUT-a s ciljem balansiranja između točnosti i računalne efikasnosti modela.



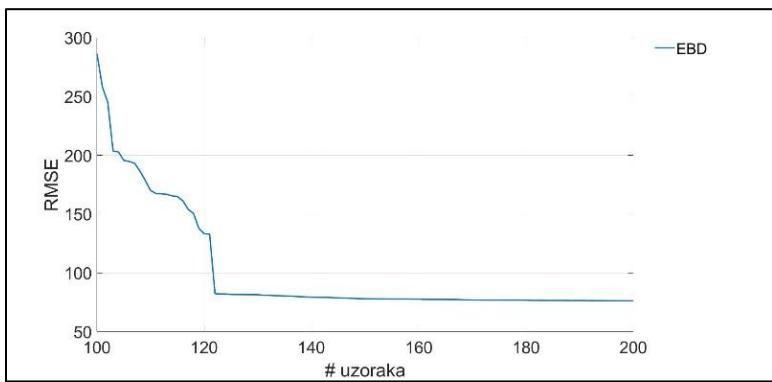
P3 - 1 Performanse aktivnog učenje za mjesec svibanj na zaraženoj plohi



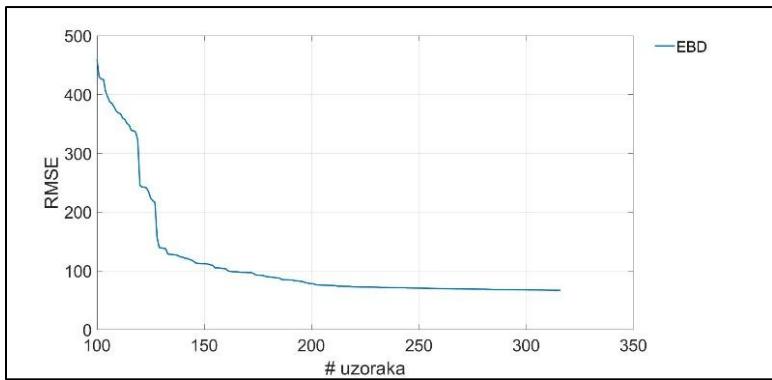
P3 - 2 Performanse aktivnog učenje za mjesec srpanj na zaraženoj plohi



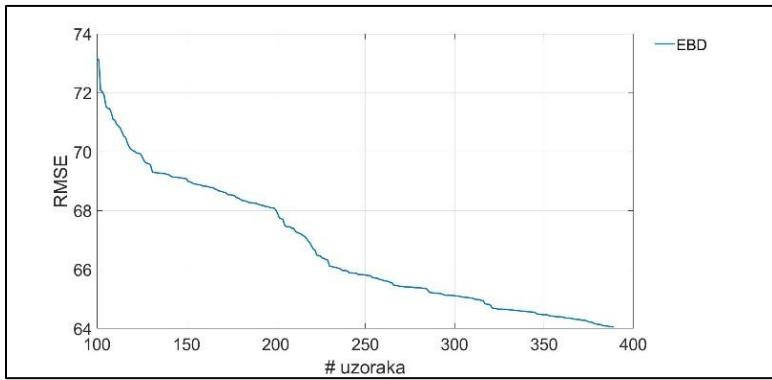
P3 - 3 Performanse aktivnog učenje za mjesec rujan na zaraženoj plohi



P3 - 4 Performanse aktivnog učenje za mjesec svibanj na kontrolnoj plohi

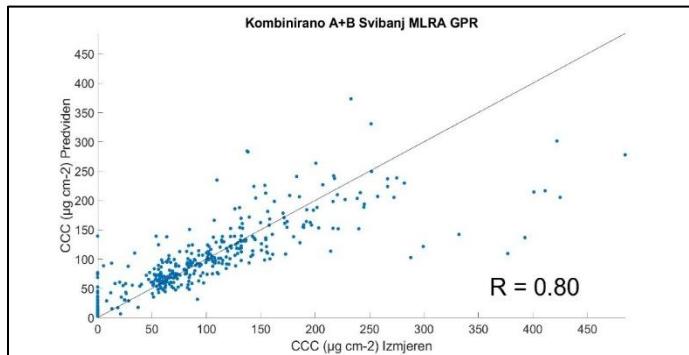


P3 - 5 Performanse aktivnog učenje za mjesec srpanj na kontrolnoj plohi

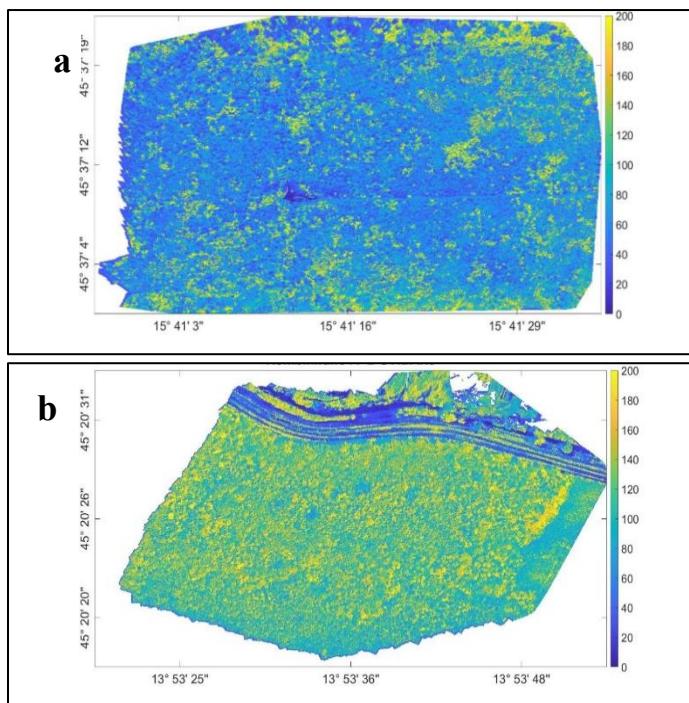


P3 - 6 Performanse aktivnog učenje za mjesec rujan na kontrolnoj plohi

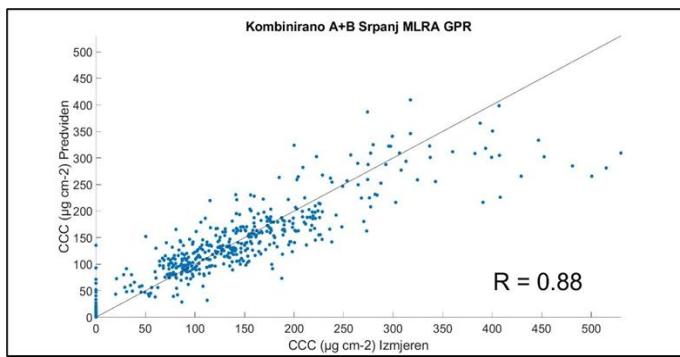
Prilog 4 Korelacijske između izmjerene i predviđene vrijednosti koncentracije klorofila krošnje (CCC) prikazane su kombinirani za plohu A (zaraženu) i plohu B (kontrolnu), kao i za svaki pojedini mjesec (svibanj, srpanj i rujan) tijekom istraživanog razdoblja 2021.–2023. Dok su u glavnim rezultatima prikazani modeli trenirani na odvojenim podacima skupu podataka radi detaljnijeg uvida u prostorne razlike u učinkovitosti modela za svaku plohu i fenološku fazu zasebno, u ovom prikazu radi varijabilnosti i robusnosti predikcija prikazan je kombiniran pristup sa ploha A i B zajedno



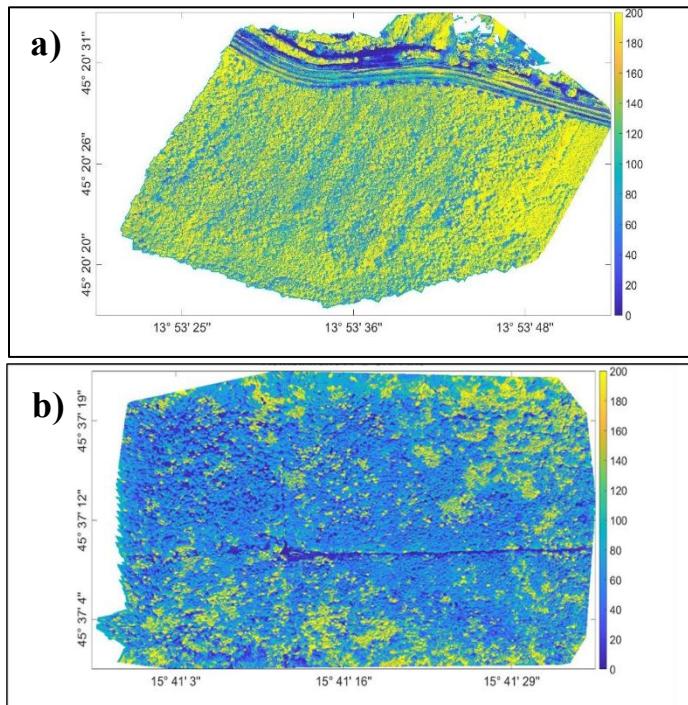
P4 - 1 Korelacijski grafikon izmjereni i predviđeni CCC vrijednosti dobivenih primjenom GPR modela na kombinirane podatke sa ploha A (zaražene) i plohe B (kontrolne) na podacima iz svibnja



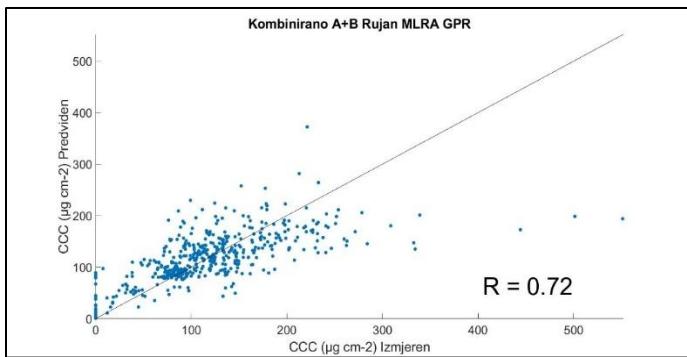
P4 - 2 Prostorna distribucija koncentracije klorofila krošnje (CCC) procijenjena Gaussian Process Regression (GPR) modelom na temelju kombiniranih podataka sa ploha A i B, za mjesec svibanj tijekom istraživanog razdoblja 2021.-2023.: (a) zaražena ploha A, (b) kontrolna ploha B.



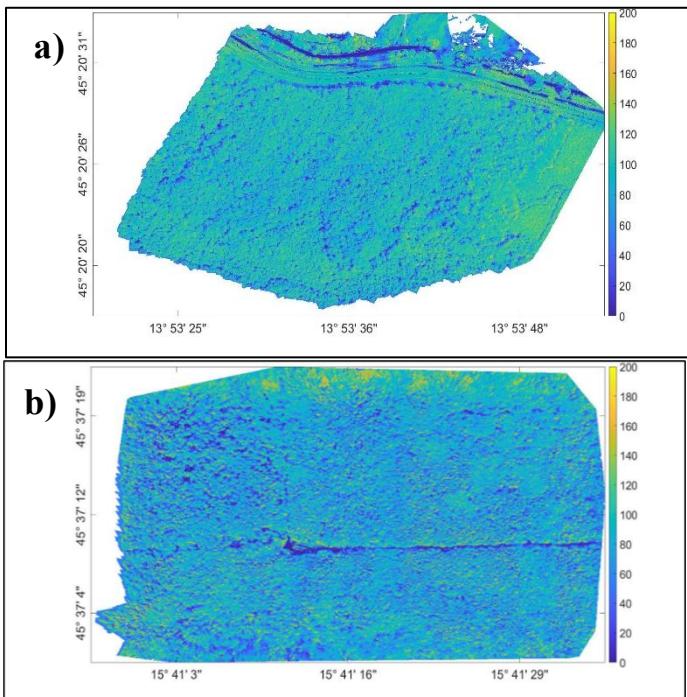
P4 - 3 Korelacijski grafikon izmјerenih i predviđenih CCC vrijednosti dobivenih primjenom GPR modela na kombinirane podatke sa ploha A (zaražene) i plohe B (kontrolne) na podacima iz srpnja



P4 - 4 Prostorna distribucija koncentracije klorofila krošnje (CCC) procijenjena Gaussian Process Regression (GPR) modelom na temelju kombiniranih podataka sa ploha A i B, za mjesec srpanj tijekom istraživanog razdoblja 2021.-2023.: (a) zaražena ploha A, (b) kontrolna ploha B



P4 - 5 Korelacijski grafikon izmjerene i predviđene CCC vrijednosti dobivenih primjenom GPR modela na kombinirane podatke sa ploha A (zaražene) i plohe B (kontrolne) na podacima za rujan



P4 - 6 Prostorna distribucija koncentracije klorofila krošnje (CCC) procijenjena Gaussian Process Regression (GPR) modelom na temelju kombiniranih podataka sa ploha A i B, za mjesec rujan tijekom istraživanog razdoblja 2021.-2023.: (a) zaražena ploha A, (b) kontrolna ploha B

9. ŽIVOTOPIS

Nikola Zorić rođen je 5. travnja 1990. godine u Jastrebarskom, gdje je završio osnovnu školu. Srednjoškolsko obrazovanje stekao je u Šumarskoj i drvodjeljskoj školi u Karlovcu, nakon čega upisuje Fakultet šumarstva idrvne tehnologije Sveučilišta u Zagrebu. Na istom fakultetu završava diplomski studij te je trenutno doktorand na doktorskom studiju Šumarstva idrvne tehnologije.

Profesionalni put započinje 2016. godine na Hrvatskom šumarskom institutu u Jastrebarskom, najprije kao stručni suradnik, a od 2020. godine kao asistent na Zavodu za zaštitu šuma i lovno gospodarenje. U svom radu posvećen je zaštiti šuma, monitoringu stranih invazivnih vrsta te provedbi europskih programa nadzora karantenskih štetnika.

Posebnu pažnju posvećuje primjeni naprednih tehnologija u šumarstvu, s naglaskom na korištenje bespilotnih letjelica opremljene različitim senzorima te napredne programske alate za obradu prikupljenih podataka za potrebe zaštite šuma i praćenja invazivnih kukaca. Na ovu temu održao je predavanje Europskoj komisiji u Bruxellesu 2020. godine, a od 2024. godine predavač je na radionicama Europske komisije u okviru programa BTSF (Better Training for Safer Food) na temu nadzora štetnika i primjene daljinskih istraživanja u biljnom zdravstvu.

Sudjelovao je na brojnim domaćim i međunarodnim stručnim i znanstvenim skupovima te je autor i koautor više znanstvenih radova objavljenih u relevantnim časopisima. Tijekom izrade doktorske disertacije proveo je mjesec dana u Laboratoriju za obradu slika Sveučilišta u Valenciji, pod mentorstvom dr. sc. Jochema Verrelsta.

Aktivno se koristi engleskim i njemačkim jezikom te je član Hrvatskog lovačkog saveza.

Popis radova:

Zorić, Nikola; Franjević, Milivoj; Matošević, Dinka Further Spread of *Corythucha arcuata* (Hemiptera; Tingidae) in Croatia // South-east European forestry, 14 (2023), 1; 111-115

Hoch, Gernot; Stemmelen, Alex; Eötvös, Csaba Béla; Hinterstoisser, Werner; Lanščak, Miran; Stojnić, Srđan; Tóth, Máté; Westergren, Marjana; Zidar, Simon; Zlatković, Milica; **Zoric, Nikola;** de Groot, Maarten. Infestation intensity by the invasive oak lace bug, *Corythucha arcuata* (Say) in mixed and pure oak stands // Journal of applied entomology, 148 (2023), 1; 26-33. doi: 10.1111/jen.13205

Zorić, N., Lanščak, M., Vujnović, Z. i Jukić, A. (2024). Adaptirana metoda uzorkovanja krošnji stabala uporabom arborističke pračke opremljene okidačem. *Radovi*, 49 (1), 1-5. Preuzeto s <https://hrcak.srce.hr/322907>

Zorić, N., Krcivoj, T. i Jukić, A. (2024). Posebni nadzor karantenskih štetnih organizama u šumama Republike Hrvatske. *Radovi*, 49 (1), 1-8. Preuzeto s <https://hrcak.srce.hr/322904>

Medak, J., Perić, S., **Zorić, N.** i Sirovica, I. (2021). First Results of Monitoring the New Invasive Species *Prunus serotina* Ehrh. Population inside the Regeneration Area of Common Oak-Hornbeam Forest in Western Croatia. *South-east European forestry*, 12 (2), 135-142. <https://doi.org/10.15177/seefor.21-17>

Jukić A, Cvetković F, Krcivoj T, Medak J, **Zorić N**, Ćelepirović N, Matošević D, 2025. First Record of *Cnestus mutilatus* (Coleoptera, Curculionidae) in Croatia. *South-east Eur for* 16(1): 9-14. <https://doi.org/10.15177/seefor.25-10>.