

UNIVERZITET U BEOGRADU  
POLJOPRIVREDNI FAKULTET

Predrag D. Randelović

**RAZVOJ MODELA ZA VISOKOPROPUSNU  
FENOTIPIZACIJU KVANTITATIVNIH OSOBINA  
U OPLEMENJAVAČKIM KOLEKCIJAMA SOJE**

Doktorska disertacija

Beograd, 2025

UNIVERSITY OF BELGRADE  
FACULTY OF AGRICULTURE

Predrag D. Randelović

**DEVELOPMENT OF HIGH-THROUGHPUT  
PHENOTYPING MODELS FOR THE  
ESTIMATION OF QUANTITATIVE TRAITS IN  
SOYBEAN BREEDING COLLECTIONS**

Doctoral Dissertation

Belgrade, 2025

UNIVERZITET U BEOGRADU  
Poljoprivredni fakultet

**Mentori**

---

**Dr Slaven Prodanović**, redovni profesor, Poljoprivredni fakultet,  
Univerzitet u Beogradu, UNO Oplemenjivanje biljaka

---

**Dr Vuk Đorđević**, naučni savetnik, Institut za ratarstvo i povrtarstvo,  
Novi Sad, Institut od nacionalnog značaja za Republiku Srbiju,  
UNO Genetika i oplemenjivanje

**Članovi komisije**

---

**Dr Tomislav Živanović**, redovni profesor, Poljoprivredni fakultet,  
Univerzitet u Beogradu, UNO Genetika

---

**Dr Nataša Milosavljević**, vanredni profesor, Poljoprivredni fakultet,  
Univerzitet u Beogradu, UNO Matematika i informatika

---

**Dr Marina Ćeran**, viši naučni saradnik, Institut za ratarstvo i  
povrtarstvo, Novi Sad, Institut od nacionalnog značaja za  
Republiku Srbiju, UNO Genetika i oplemenjivanje

**Datum odbrane doktorske disertacije:** \_\_\_\_\_

## **RAZVOJ MODELA ZA VISOKOPROPUSNU FENOTIPIZACIJU KVANTITATIVNIH OSOBINA U OPLEMENJIVAČKIM KOLEKCIJAMA SOJE**

**Sažetak:** U okviru oplemenjivačkog procesa koji za krajnji rezultat ima stvaranje nove sorte, prikupljanje podataka o fenotipskim karakteristikama biljnog materijala predstavlja esencijalan ali i prilično naporan posao. S obzirom da oplemenjivači soje svake godine rade na materijalu koji se sastoji od stotina i hiljada genotipova roditelja i hibridnog potomstva od  $F_1$  do  $F_{6-7}$  generacije, a da je raspoložive radne snage sve manje, postaje neophodno uvoditi savremene alate i tehnike za efikasniju i precizniju determinaciju kvantitativnih osobina. Imajući u vidu potencijal daljinske detekcije i fotogrametrijske obrade snimaka u oplemenjivanju biljaka, cilj ove doktorske disertacije bio je razvoj modela za visokopropusnu fenotipizaciju kvantitativnih osobina soje. Istraživanje je realizovano u četvorogodišnjim poljskim ogledima, u dve faze, pri čemu je u prvoj kreiran model za predikciju broja biljaka/ $m^2$  dok su modeli za procenu pokrovnosti, visine, biomase i prinosa soje razvijeni tokom druge faze istraživanja na divergentnoj germplazmi koja je gajena na dva tipa zemljишta, karbonantnom černozemu i peskovitom lesu (simulacija suše). Kalibriranje modela je obavljeno na osnovu podataka izdvojenih sa digitalnih fotografija (RGB, multispektral) biljnog materijala i stvarno izmerenih vrednosti osobina za koje se modeli prave. Pored toga, analizirana je veza između podataka visokopropusne fenotipizacije i morfoloških i produktivnih svojstava soje, te mogućnost korišćenja rezultata predikcionih modela za selekciju superiornih genotipova. Kreirani modeli su pokazali visok nivo preciznosti što je potvrđeno  $R^2$  vrednostima koje su se u zavisnosti od osobine kretale od 0,76 do 0,94. Podaci dobijeni pomoću visokopropusne fenotipizacije pokazali su određen stepen povezanosti sa pojedinim morfološkim i proizvodnim karakteristikama soje ( $r = \pm 0,5$ ) što je od posebnog značaja za ranu karakterizaciju oplemenjivačkog materijala. Konačno, rezultati predikcionih modela u kombinaciji sa podacima koji su dobijeni klasičnom fenotipizacijom, omogućili su odabir najboljih genotipova u različitim uslovima gajenja koji kao takvi mogu biti iskorišćeni u budućim oplemenjivačkim programima.

**Ključne reči:** visokopropusna fenotipizacija, soja, oplemenjivanje, daljinska detekcija, fotogrametrija, broj biljaka/ $m^2$ , pokrovnost, visina, biomasa, prinos

**Naučna oblast:** Biotehničke nauke

**Uža naučna oblast:** Genetika i oplemenjivanje

**UDK:** 633.34:631.527(043.3)

## DEVELOPMENT OF HIGH-THROUGHPUT PHENOTYPING MODELS FOR THE ESTIMATION OF QUANTITATIVE TRAITS IN SOYBEAN BREEDING COLLECTIONS

**Abstract:** In the plant breeding process, which results in the development of new varieties, phenotyping represents an essential yet demanding task. Each year, soybean breeders work with material that consists of hundreds or even thousands of genotypes from F<sub>1</sub> to F<sub>6-7</sub> generations. This fact, alongside the current decrease in available manpower, demands the implementation of modern tools and techniques that will enable a more efficient and precise determination of quantitative traits. Knowing the potential of remote sensing and image photogrammetry in plant breeding, this doctoral dissertation aimed to develop models for high-throughput phenotyping of quantitative soybean traits. The research was carried out in four-year field trials in two phases. The model for the prediction of soybean plant density (plants/m<sup>2</sup>) was created in the first phase, while models for canopy coverage, height, biomass and yield were developed during the second phase of the study on divergent germplasm grown on two soil types, carbonate chernozem, and sandy loess (drought simulation). The models were calibrated based on the data extracted from digital images (RGB, multispectral) of soybean plots and actual values of the traits for which the models were created. In addition, the relationship between high-throughput phenotyping data and morphological and agronomic soybean characteristics was analyzed. Also, the results obtained with the prediction models were used to select superior genotypes. The created models showed a high level of precision, which was confirmed by R<sup>2</sup> values that ranged from 0,76 to 0,94, depending on the trait. The high-throughput phenotyping data was correlated with some morphological and productive soybean traits ( $r = \pm 0,5$ ), which is very important for the early characterization of breeding material. Based on the data obtained with the prediction models and traditional phenotyping, the genotypes with the best performance in different growing conditions were highlighted as a great source of superior traits for future breeding programs.

**Key words:** high-throughput phenotyping, soybean, breeding, remote sensing, photogrammetry, plant density, canopy coverage, height, biomass, yield

**Scientific field:** Biotechnical Science

**Scientific subfield:** Genetics and breeding

**UDK:** 633.34:631.527(043.3)

# Sadržaj

<b>1. UVOD.....</b>	1
<b>2. PREGLED LITERATURE.....</b>	3
2.1. Poreklo, širenje i oplemenjivanje soje .....	3
2.2. Kvantitativne osobine soje .....	5
2.3. Fenotipizacija, daljinska detekcija i fotogrametrija .....	7
2.3.1. Alati i tehnike daljinske detekcije i fotogrametrije.....	9
2.3.2. Primena visokopropusne fenotipizacije u oplemenjivanju biljaka .....	14
2.3.3. Visokopropusna fenotipizacija i oplemenjivanje soje .....	17
2.3.4. Primena mašinskog učenja u visokopropusnoj fenotipizaciji.....	19
<b>3. NAUČNI CILJ ISTRAŽIVANJA .....</b>	20
<b>4. OSNOVNE HIPOTEZE OD KOJIH SE POLAZI.....</b>	21
<b>5. MATERIJAL I METODE .....</b>	22
5.1. FAZA I - Razvoj modela za predikciju broja biljaka soje po jedinici površine .....	22
5.1.1. Poljski ogledi i biljni materijal korišćen u okviru Faze I.....	22
5.1.2. Bespilotna letelica i prikupljanje podataka tokom Faze I.....	22
5.1.3. Kreiranje modela za predikciju broja biljaka soje po jedinici površine.....	24
5.2. FAZA II - Razvoj modela za predikciju visine, pokrovnosti, biomase i prinosa soje .....	25
5.2.1. Poljski ogledi i biljni materijal korišćen u okviru Faze II .....	25
5.2.2. Bespilotna letelica i prikupljanje podataka u okviru Faze II .....	26
5.2.3. Kreiranje modela za predikciju pokrovnosti soje .....	27
5.2.4. Kreiranje modela za predikciju visine soje .....	28
5.2.5. Kreiranje modela za predikciju biomase soje .....	30
5.2.6. Kreiranje modela za predikciju prinosa soje.....	32
5.3. Prikupljanje podataka o morfološkim, proizvodnim i tehnološkim osobinama soje klasičnom fenotipizacijom .....	34
<b>6. REZULTATI.....</b>	35
6.1. Predikcioni model za procenu broja biljaka soje po jedinici površine .....	35
6.2. Predikcioni model za procenu pokrovnosti soje .....	39
6.3. Predikcioni model za procenu visine biljaka soje.....	42
6.4. Predikcioni model za procenu biomase soje.....	45
6.5. Morfološke, proizvodne i tehnološke osobine soje .....	51
6.5.1. Visina prve mahune .....	51
6.5.2. Broj grana po biljci.....	52
6.5.3. Broj zrna po biljci.....	53
6.5.4. Masa zrna po biljci .....	54

6.5.5. Masa hiljadu zrna .....	55
6.5.6. Prinos zrna .....	56
6.5.7. Sadržaj proteina u zrnu .....	57
6.5.8. Sadržaj ulja u zrnu .....	58
6.6. Predikcioni model prinosa soje .....	59
6.7. Karakterizacija genotipova soje na osnovu klasične i visokopropusne fenotipizacije .....	64
<b>7. DISKUSIJA .....</b>	<b>67</b>
7.1. Model za predikciju broja biljaka po jedinici površine .....	68
7.2. Model za predikciju pokrovnosti soje .....	69
7.3. Model za predikciju visine biljaka soje .....	71
7.4. Model za predikciju biomase soje .....	73
7.5. Model za predikciju prinosa soje .....	75
7.6. Tumačenje kvantitativnih i kvalitativnih osobina soje dobijenih klasičnom fenotipizacijom .....	76
7.7. Selekcija superiore germplazme soje na osnovu klasične i visokopropusne fenotipizacije .....	79
<b>8. ZAKLJUČAK .....</b>	<b>82</b>
<b>9. LITERATURA .....</b>	<b>84</b>
PRILOG 1. Lista skraćenica .....	104
PRILOG 2. Vegetacioni indeksi korišćeni prilikom kreiranja modela za visokopropusnu fenotipizaciju soje .....	106
PRILOG 3. Rana grupa genotipova soje korišćena u drugoj fazi istraživanja .....	109
PRILOG 4. Kasna grupa genotipova soje korišćena u drugoj fazi istraživanja .....	114
PRILOG 5. Mehanički sastav, % organske materije i retencija vlage u zemljištima korišćenim u okviru druge faze istraživanja. RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola) .....	118
Biografija autora .....	119
Izjava o autorstvu .....	120
Izjava o istovetnosti štampane i elektronske verzije doktorskog rada .....	121
Izjava o korišćenju .....	122

# 1. UVOD

Soja (*Glycine max* (L.) Merr.) je jednogodišnja biljna vrsta koja pripada familiji *Fabaceae*, podfamiliji *Papilionoideae*, rodu *Glycine* Willd, podrodu Soja (Moench). Ova mahunarka predstavlja jednu od najznačajnijih ratarskih kultura, pre svega zbog visokog kvaliteta zrna koje je bogato različitim hranljivim materijama, uključujući visok sadržaj proteina i ulja. Pored toga, gajenje soje ima brojne koristi i sa agroekološkog aspekta budući da kao leguminoza ima sposobnost da zajedno sa krvžičnim bakterijama (*Bradyrhizobium japonicum*) formira simbiotsku zajednicu i tako za svoj razvoj obezbedi značajne količine azota iz vazduha. Na ovaj način smanjuje se potreba za dodatnim korišćenjem mineralnih đubriva čime se pospešuje ekonomičnost proizvodnje.

Soja je fotoperiodski zavisna i pripada grupi biljaka kratkog dana što znači da za prelazak iz vegetativne u generativnu fazu zahteva dužinu dana koja je kraća od kritične i najčešće iznosi 12-14 časova (Miladinović i sar., 2008). Kao posledica fotoperiodizma, sorte soje su na osnovu dužine vegetacije podeljene u 13 grupa zrenja (000-X) (Zhang i sar., 2007). Trajanje obdanice na Zemlji zavisi od geografske širine zbog čega su različite grupe zrenja optimalne za različite paralele. U slučaju kada se određena sorta soje uzgaja na većim geografskim širinama od odgovarajuće, period do cvetanja i ukupna dužina vegetacionog perioda se produžuju dok gajenje soje na manjim geografskim širinama od optimalne dovodi do ranijeg sazrevanja (Miladinović i sar., 2018). Sorte koje pripadaju grupi 000, prilagođene su za proizvodnju na većim geografskim širinama dok genotipovi iz X grupe mogu uspešno da se gaje u blizini Ekvatora. U našim agroekološkim uslovima koji su karakteristični za 42. paralelu severne hemisfere, optimalne su sorte od 000 do III grupe zrenja, pri čemu I grupa predstavlja osnov gajenog sortimenta (Miladinović i Prodanović, 2021).

Gajenje soje se u svetu odvija na preko 130 miliona hektara uz ostvarenu proizvodnju od skoro 350 miliona tona (Faostat, 2022). Sa ekspanzijom površina težilo se i povećanju prinosa koji je u prvim godinama gajenja bio skroman u poređenju sa današnjim standardima. Prosečan prinos soje u svetu je 1961. godine bio oko 1,2 t/ha dok je u 2022. iznosio 2,61 t/ha (Faostat, 2022). Podaci pokazuju da je u navedenom periodu godišnji rast prosečnog prinosa u SAD-u iznosio oko 24,7 kg (Specht i sar., 2014) a sličan trend zabeležen je i na našim prostorima. Povećanje prosečnog prinosa za skoro dva i po puta u proteklih 60 godina rezultat je napretka koji je ostvaren u oblasti tehnologije proizvodnje i gajenja visokoprinosnih sorti koje su nastale oplemenjivanjem.

Oplemenjivanje soje, odnosno stvaranje nove sorte predstavlja proces koji podrazumeva izbor roditelja zatim njihovo plansko ukrštanje nakon čega se kroz generacije samooplodnje vrši selekcija najboljih genotipova koji na kraju višegodišnjeg procesa postaju sorte (Miladinović i sar., 2015). Selekcija superiornih genotipova zasnovana je na različitim metodama oplemenjivanja, upotrebi odgovarajućeg početnog materijala i preciznoj oceni agronomski značajnih osobina. Najvažnija svojstva su najčešće kvantitativne osobine čija fenotipska ekspresija zavisi od većeg broja faktora. U današnje vreme ocena fenotipskih karakteristika materijala u polju predstavlja usko grlo u daljem napretku selekcije zbog čega se javlja potreba za pronalaženjem novih rešenja koja će ovaj segment oplemenjivanja učiniti preciznijim i efikasnijim.

Kao jedan od načina za unapređenje procesa prikupljanja podataka o fenotipskim karakteristikama biljnog materijala nameće se upotreba visokopropusne fenotipizacije (eng. *high-throughput phenotyping*), koja omogućava praćenje stanja i razvoja velikog broja genotipova u realnom vremenu čime se pospešuje efikasnost selekcije. Pored efikasnijeg prikupljanja podataka o osobinama koje se beleže u okviru standardnih oplemenjivačkih protokola, kreiranje modela za visokopropusnu fenotipizaciju omogućilo bi dobijanje vrednosti novih parametara koje do sada nije bilo moguće prikupiti tradicionalnim metodama.

Oplemenjivanje soje u Institutu za ratarstvo i povrтарство, Institutu od nacionalnog značaja za Republiku Srbiju ima tradiciju dugu pola veka. Fokus oplemenjivačkih programa u proteklom periodu bio je usmeren na stvaranje visokoprinosnih sorti tolerantnih na različite abiotičke i biotičke faktore. Tokom godina, najveći iskorak u procesu selekcije ostvaren je primenom molekularnih markera i genotipizacije budući da su ove metode i tehnike znatno uticale na povećanje efikasnosti oplemenjivanja. Sa druge strane, savremeni protokoli koji se odnose na analizu biljaka na parceli su u velikoj meri ostali isti kao na početku. Imajući u vidu veliki potencijal visokopropusne fenotipizacije, ovaj pristup bi mogao doprineti daljem napretku selekcije superiornih sorti soje.

## 2. PREGLED LITERATURE

Kao jedna od najznačajnijih poljoprivrednih kultura, soja se gaji širom sveta, od Kanade do Japana i od severa Evrope pa sve do juga Afrike. Gotovo 90% ukupne svetske proizvodnje dolazi iz Brazila, Sjedinjenih Američkih Država (SAD), Argentine, Kine i Indije (Faostat, 2022). U Srbiji, prosečan prinos soje u periodu od 2018. do 2022. godine iznosio je približno 2,7 t/ha na oko 220.000 hektara zbog čega je soja po zastupljenosti u našoj zemlji odmah iza kukuruza, pšenice i suncokreta (Faostat, 2022). Značaj soje se ogleda u tome što ona predstavlja jedan od najkvalitetnijih izvora mikro i makro-hranljivih materija zbog čega zauzima važno mesto u ishrani ljudi i domaćih životinja (Burssens i sar., 2011). Soja kao proteinsko-uljana biljna vrsta sadrži oko 38% proteina i oko 19% ulja u zrnu (Wilson, 2004). U ljudskoj ishrani se najviše koristi kao tofu, sojino mleko ili edame. Za ishranu domaćih životinja, soja se pretežno upotrebljava u obliku sačme koja predstavlja proteinsko hranivo visoke nutritivne vrednosti a dobija se izdvajanjem ulja iz zrna. Soja je kao sirovina široko rasprostranjena i u drugim granama industrije pri proizvodnji sapuna, kozmetičkih preparata, raznih vrsta plastike, boja i maziva (Chen i sar., 2012). Takođe, sojino ulje predstavlja glavnu komponentu za proizvodnju biodizel goriva u SAD-u (Kim i Dale, 2009).

Upotreba soje kao gotovog proizvoda ili resursa za prerađivačku industriju biće u porastu i u budućnosti budući da se očekuje da do 2050. godine broj stanovnika na globalnom nivou premaši devet milijardi (Godfray i sar., 2010). Zadovoljenje narastajućih potreba čovečanstva otežaće i sve izraženiji klimatski ekstremi zbog čega će rad oplemenjivača prilikom stvaranja novih sorti pored visokog prinosa biti fokusiran i na tolerantnost na različite biotičke i abiotičke faktore.

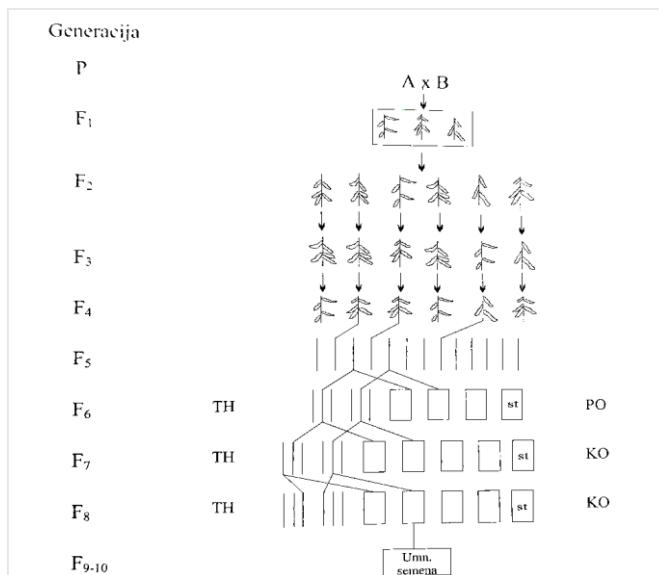
### 2.1. Poreklo, širenje i oplemenjivanje soje

Soja vodi poreklo od divljeg srodnika (*Glycine soja* Seib. et Zucc.) od kog je domestifikovana u severoistočnoj Kini pre više od 3.000 godina (Carter i sar., 2004). Vremenom, soja se počela gajiti i u ostaku ove zemlje koja predstavlja njen primarni gen centar iz kog se dalje proširila po svetu. Od 1. do 17. veka, soja je introdukovana u Japan, Mjanmar, Vijetnam, Tajland i Filipine koji se smatraju njenim sekundarnim gen centrom (Hymowitz, 2008). Hiljadama godina nakon početka gajenja u Aziji, soja je stigla na evropski i američki kontinent. U Evropu su je doneli moreplovci, nakon povratka sa istraživanja Dalekog istoka a počeci uzgoja zabeleženi su u prvoj polovini 18. veka. U to vreme, ova leguminoza se pre svega gajila za potrebe botaničkih izučavanja. Tek na osnovu dela Fridriha Haberlanda iz 1875. godine i rezultata koje je objavio, šira evropska javnost je bliže upoznata sa ovom biljnom vrstom. Iako je početak uzgoja soje vezan za zapad Evrope, značajna proizvodnja je sve do osamdesetih godina 20. veka bila uglavnom ograničena na zemlje Balkanskog poluostrva (Miladinović i sar., 2008). Nakon toga, počinje dalja ekspanzija i to prvo u Italiji i Francuskoj a zatim u Rusiji i Ukrajini koji su i danas najveći evropski proizvođači (Faostat, 2022). Na tlo Severne Amerike soja je pristigla iz Kine oko 1756. godine ali je njena šira proizvodnja počela vek kasnije, prevashodno služeći za ishranu životinja (Hymowitz, 2004). Do polovine 20. veka soja je uglavnom korišćena za silažu a tek nakon toga glavni proizvod postaje zrno zbog čega se i javlja potreba za stvaranjem prinosnijih genotipova.

Savremeno oplemenjivanje soje je otpočelo u SAD-u tokom dvadesetih godina prošlog veka na materijalu koji je vodio poreklo iz Azije. Inicijalni rad oplemenjivača bio je usmeren na selekciju genotipova sa čvrstim glavnim stablom, odgovarajućim tipom rasta i visokim nutritivnim kvalitetom semena (Anderson i sar., 2019). Nakon što su kreirane, prve sorte soje su se brzo proširile i u ostalim delovima sveta gde su u okviru oplemenjivačkih programa korišćene kao početni materijal za stvaranje novih, visokoprinosnih genotipova koji su prilagođeni različitim uslovima gajenja.

Kreiranje superiornih sorti soje odnosno uspeh oplemenjivačkih programa zavisi od brojnih faktora među kojima se izdvajaju cilj oplemenjivanja, izbor roditelja, metod selekcije, svojstvo na koje se selekcija obavlja i raspoloživi ljudski i materijalni kapaciteti. Većina oplemenjivačkih programa fokusirana je na povećanje prinosa kao agronomski najznačajnije osobine, pri čemu se pored produktivnosti, velika pažnja posvećuje i tolerantnosti prema različitim abiotičkim i biotičkim faktorima. Da bi se uticalo na poboljšanje određenog svojstva, neophodno je stvoriti divergentnu populaciju genotipova što se postiže odabirom odgovarajućih roditeljskih parova. Budući da soja predstavlja samooplodnu biljnu vrstu sa izuzetno niskim procentom stranooplodnje, ovakav način razmnožavanja uz konstantnu upotrebu malog broja elitnih linija kao početnog materijala za ukrštanje, može dovesti do značajnog suženja genskog fonda (Dong i sar., 2014; Jarquin i sar., 2016). To potvrđuje i istraživanje iz 2018. godine u kom se navodi da američka kolekcija koja se sastoji od 19.652 genotipova ima izrazito usku genetičku osnovu budući da je efektivna veličina populacije svega 106 genotipova (Xavier i sar., 2018). Kao roditelji mogu biti korišćene prethodno stvorene sorte, linije ili egzotična germplazma koja je nosilac želenog svojstva. Ipak, najčešće se za ukrštanje koriste elitne linije sa različitom genetičkom osnovom što obezbeđuje najveću verovatnoću za dobijanje superiornog potomstva (Miladinović, 1999). Odabir parova se obavlja na osnovu podataka koji su dobijeni iz ogleda, test ukrštanja ili korišćenjem drugih metoda koje su efikasne za identifikaciju najboljih kombinacija. Poslednjih decenija, upotreba molekularnih markera za ocenu početnog materijala pokazala se kao izuzetno korisna (Amiteye, 2021) zbog čega ona danas predstavlja standardnu tehniku u mnogim oplemenjivačkim programima.

Nakon odabira roditelja, naredni korak je izbor metoda oplemenjivanja koji će biti primenjen tokom procesa selekcije. Kao i kod drugih samooplodnih biljnih vrsta i kod soje se koriste metode poput gajenja u smeši, pedigree metod, metod potomstva jednog semena, metod povratnog ukrštanja i druge (Miladinović i sar., 2011). Najzastupljeniji metod je metod potomstva jednog zrna (eng. *single seed descent*, SSD) (Brim, 1966). Šema SSD metoda prikazana je na Slici 1.



**Slika 1.** Metod potomstva jednog semena (Miladinović, 1999)

Kod SSD-a se seme svih hibridnih biljaka jedne kombinacije seje u poseban red. Nakon toga, sve do F<sub>4</sub> generacije se od svake biljke uzima po jedno zrno i seje naredne godine kako bi se održala genetička varijabilnost u populaciji. U F<sub>4</sub> se biraju pojedinačne biljke čije seme se seje u posebne redove u F<sub>5</sub> generaciji, kada se oni najbolji bez merenja prinosa koriste za dalji rad. Seme iz odabralih redova seje se u narednim godinama u prethodni (PO) a zatim i u komparativni ogled (KO) gde se na osnovu prinosa i drugih važnih osobina obavlja odabir najboljih linija za priznavanje.

## 2.2. Kvantitativne osobine soje

Agronomski bitna svojstva su najčešće kvantitativne osobine koje su određene većim brojem gena sa malim pojedinačnim efektom. Jedno od metričkih svojstava koje predstavlja važnu komponentu prinosa useva je i visina (Sun i sar., 2012). Visina glavnog stabla može biti značajan pokazatelj rasta i razvoja biljaka tokom vegetacionog perioda. Iako prethodne studije nisu pokazale direktnu povezanost između visine i prinosa soje (Diondra, i sar., 2008), produktivnost sorti može biti smanjena usled gubitka semena prouzrokovanih poleganjem koje je izraženije kod viših genotipova (Ustun i sar., 2001). Da bi umanjili negativne efekte poleganja, oplemenjivači su tokom godina bili usmereni na redukovanje visine kod novih sorti. Rezultati prethodnog istraživanja su pokazali da je kod sorti soje iz II, III i IV grupe zrenja koje su stvorene u periodu od 1923-2008. godine, selekcija bila usmerena na smanjenje visine biljaka odnosno da su noviji genotipovi bili niži u odnosu na pređašnje (Rincker i sar., 2014). Neka od prethodnih studija ukazuju da je optimalna visina pri kojoj sorte soje ostvaruju svoj pun potencijal između 70 i 90 cm (Yang, i sar., 2021). Osim značaja koji visina ima sa aspekta poleganja, ona ujedno utiče i na broj nodija i mahuna po biljci (Egli, 2013) čime se ponovo ističe njen indirekstan uticaj na prinos. Pored visine glavnog stabla, visina prve mahune takođe predstavlja važnu karakteristiku svake sorte i to pre svega sa tehničkog aspekta u procesu žetve. Ako se prve mahune nalaze suviše nisko, blizu zemlje, kombajniranje je otežano, zrna zaostaju na stabljici, što dovodi do gubitka prinosa. Pojedini autori navode da se sa povećanjem visine prve mahune od 1cm, gubici prinosa koji se javljaju prilikom kombajniranja mogu smanjiti i do 100 kg/ha (Hrustić i sar., 1998).

U novije vreme, sve veća pažnja se obraća i na nekonvencionalne pokazatelje kao što je biomasa odnosno količina nakupljene organske materije tokom vegetacionog perioda. Biomasa može biti značajan indikator rasta na osnovu kojeg je moguće oceniti i efikasnost korišćenja sunčeve svetlosti (Sinclair i Muchow, 1999). U prethodnim studijama je utvrđeno da genotipovi koji nakupljaju više organske materije postižu veći prinos, posebno u sušnim uslovima (Gajić i sar., 2018). Robusniji genotipovi sa većom lisnom površinom presreću više svetlosti čime se podstiče proces fotosinteze u celijama. Sa druge strane, genotipovi sa smanjenom akumulacijom biomase imaju nizak stepen iskorišćenosti sunčevog zračenja (eng. *radiation use efficiency*, RUE) što se nepovoljno odražava na njihovu produktivnost (Bajgain i sar., 2015). Takođe, utvrđeno je da od R1 (početak cvetanja) do R5 (početak nalivanja zrna) faze razvoja soje, stopa porasta useva (eng. *crop growth rate*, CGR) odnosno količina nakupljene suve materije po jedinici površine u jedinici vremena predstavlja jedan od ključnih elemenata u formiranju prinosa (Vogel i sar., 2021). Suštinski, porast CGR-a ukazuje na veću produkciju zrna po biljci koja je u direktnoj vezi sa prinosom (Egli, 2019). Broj zrna po biljci predstavlja svojstvo koje karakteriše niska heritabilnost, najčešće i ispod 50% (Srebrić, 2013). Ipak, zbog visoke korelacije sa prinosom zrna, ova osobina može biti uspešno iskorišćena kao selekcioni kriterijum prilikom odabira superiornih genotipova soje u okviru oplemenjivačkih programa koji su usmereni na povećanje prinosa (Jocković i sar., 1986). Budući da je broj zrna po biljci direktno zavistan od broja mahuna po biljci i broja zrna po mahuni, klimatski faktori poput temperature i vlažnosti vazduha tokom cvetanja i u periodu zametanja mahuna i zrna imaju presudnu ulogu na ispoljavanje ovog svojstva (Perić, 2015).

Sa druge strane, u prethodnim istraživanjima je utvrđeno da masa zrna po biljci i masa 1000 zrna imaju manji uticaj na prinos soje u odnosu na broj zrna po biljci (Carciochi i sar., 2019). Od ranije je poznato da sorte sa većom masom 1000 semena obrazuju manji broj zrna po jedinici površine dok je kod genotipova sa sitnjim zrnom situacija obrnuta (Vogel i sar., 2021). Međutim, ova osobina predstavlja važno kvantitativno svojstvo budući da je za postizanje punog potencijala sorte pored obrazovanja maksimalnog broja zrna po biljci važno ostvariti i maksimalnu težinu, odnosno krupnoću formiranog semena.

Pokrovnost useva koja se definiše kao ideo zemljišta prekriven vegetativnom masom (Virdi i sar., 2023) predstavlja još jednu osobinu koja može biti od velikog značaja za oplemenjivanje soje budući da je ranije utvrđeno da korišćenje ovog svojstva povećava efikasnost genomske selekcije (van Eeuwijk i sar., 2019). Ranije dostizanje pune pokrovnosti osigurava veću količinu presretnutog sunčevog zračenja u početnim fazama razvoja čime se stimuliše rast i povećava prinos (Bullock i sar., 1998). U prethodnim istraživanjima je dokazano da prosečna vrednost pokrovnosti određena u periodu od V2 (druga troliska) do R5 faze predstavlja visoko heritabilno svojstvo koje je u značajnoj meri korelisano sa prinosom zrna (Xavier, i sar., 2017). Sa druge strane, u slučaju da do početka nalivanja zrna usev soje ne dostigne punu pokrovnost, biljke smanjuju produktivnost (Bastidas i sar., 2008; Lee i sar., 2008). Pored značaja koji ima sa aspekta produktivnosti, pokrovnost je takođe važna i za očuvanje vlage u zemljištu te regulisanje brojnosti korovske zajednice. Brzo zatvaranje redova smanjuje gubitak vode evaporacijom a ujedno povećava konkurentnost gajenog useva prema korovima što predstavlja bitan faktor u njihovom suzbijanju (Bastiaans i sar., 2008).

Brzina zatvaranja redova između ostalog zavisi i od arhitekture biljaka na koju u velikoj meri utiče i setvena norma. Optimalan broj biljaka po hektaru može da varira i u zavisnosti od genotipa i uslova gajenja kreće se od 200.000 do preko 600.000 (Miladinović i sar., 2008). U uslovima smanjenog broja biljaka po jedinici površine dolazi do pojačanog grananja i stvaranja većeg broja mahuna po biljci (Rigsby i Board, 2003). Ovaj vid prilagođavanja arhitekture biljaka predstavlja uspešan način za kompenzovanje gubitka prinosa budući da je od ranije poznato da produktivnost bočnih grana u značajnoj meri doprinosi ukupnom prinosu po biljci (Norsworthy i sar., 2005). Masa suve materije bočnih grana takođe može biti dobar pokazatelj prinosa soje s obzirom da je ranije potvrđena visoka pozitivna korelacija ( $r = 0,95$ ) između navedenih osobina (Carpenter i Board, 1997). Ipak, sposobnost pojačanog grananja ne može u potpunosti nadomestiti smanjenje prinosa koji se javlja kao posledica nedovoljnog broja biljaka (Mathan i sar., 2016). Sa druge strane, gušća setva podstiče porast glavnog stabla (Rahman i Hossain, 2011) dok ujedno smanjuje osvetljenost pazušnih popoljaka što može negativno da se odrazi na razvoj bočnih grana (Yang i sar., 2018). Veći broj biljaka/ $m^2$  omogućava efikasnije korišćenje sunčeve svetlosti i raspoloživog zemljišta zbog čega je tokom godina rad oplemenjivača bio usmeren na stvaranje sorti koje su prilagođene većim gustinama setve (Xu i sar., 2021). Bolja prilagođenost većim setvenim normama pre svega je omogućena promenom arhitekture biljaka kod novih sorti soje pri čemu je osnovni cilj bio stimulisanje bočnog grananja u uslovima većeg broja biljaka po jedinici površine (Sun i sar., 2019). Tokom vegetacionog perioda može doći do odstupanja u odnosu na početnu setvenu normu budući da broj izniklih biljaka veoma često nije i finalni broj u žetvi. Primena agrotehničkih mera, nepovoljni klimatski uslovi ili napad bolesti i štetočina mogu dovesti do propadanja biljaka i smanjenja konačnog broja.

Pored prinosa i njegovih komponenti, važno svojstvo svake sorte soje predstavlja i hemijski sastava zrna. Prethodna istraživanja su pokazala velika variranja u sadržaju proteina i ulja kod različitih sorti soje. Kao primer mogu se navesti rezultati studije koja je obavljena na genotipovima iz američke kolekcije kod kojih se procentualni ideo proteina u zrnu kretao u rasponu od 35,1-56,8% a ulja između 8,3% i 27,9% (Burton i Miranda, 2013). Budući da su potrebe tržišta za proteinskim hranivima poslednjih decenija u porastu, genotipovi soje sa povišenim sadržajem proteina postaju sve traženiji. I pored toga što navedene osobine karakteriše visoka heritabilnost, selekcija usmerena na istovremeno povećanje koncentracije proteina i ulja u zrnu soje predstavlja zahtevan zadatak iz dva osnovna razloga. Prvi se odnosi na to da su navedena svojstva međusobno negativno korelisana (Bellaloui i sar., 2009) a drugi da takođe postoji izrazita negativna korelacija između sadržaja proteina i prinosu zrna (Taški Ajduković i sar., 2010). Imajući u vidu specifičan međusobni odnos između navedenih parametara tehnološkog kvaliteta semena kao i njihov efekat na prinos soje, težnja oplemenjivača prilikom stvaranja novih sorti usmerena je na selekciju genotipova koji će imati što bolji kvalitet semena uz održavanje visokog prinosu.

## 2.3. Fenotipizacija, daljinska detekcija i fotogrametrija

Naučna disciplina koja se bavi proučavanjem fenotipa nastalog usled interakcije genotipa, spoljašnje sredine i primenjene agrotehnike naziva se fenotipizacija (Lobos i sar., 2017). Fenotipizacija podrazumeva sistematičan pristup koji iziskuje prikupljanje podataka o osobinama koje se odnose na rast i razvoj biljaka uključujući prinos, morfološke karakteristike, fiziološke i druge merljive parametre (Li i sar., 2014). Odabir najboljih genotipova na osnovu njihove produktivnosti i adaptabilnosti započet je još pre oko 10.000 godina domestikacijom prvih biljnih vrsta (Ahmar i sar., 2020). Prelaskom na sedelački način života, stalan boravak ljudi na određenom području stvorio je uslove za kontinuirani uzgoj useva i selekciju najboljih biljaka čije je seme korišćeno za setvu u narednoj generaciji. Sve do pojave Mendelovih zakona nasleđivanja, odabir superiornih individua bazirao se isključivo na fenotipskim karakteristikama koje su uočene tokom gajenja (Pieruschka i Schurr, 2019). Ovakav vid selekcije bio je značajno uspešniji za visoko heritabilna svojstva odnosno za one osobine čija ekspresija manje zavisi od faktora spoljašne sredine (Hallauer i sar., 2010). Iako u današnje vreme fenotipizacija predstavlja neizostavni segment i u oplemenjivačkim programima usmerenim na kompleksnije osobine poput prinosa, ona je označena kao usko grlo daljem napretku selekcije. Glavni razlog je taj što se u većini konvencionalnih oplemenjivačkih programa fenotipizacija i dalje oslanja na tradicionalne metode (Araus i sar., 2018) koje zahtevaju mnogo vremena, novca i radne snage. Poznato je da je jedan od glavnih ciljeva oplemenjivača povećanje genetičke dobiti koja zavisi od heritabilnosti, intenziteta selekcije, fenotipske varijabilnosti kao i od dužine trajanja oplemenjivačkog ciklusa (Falconer i Mackay, 1996).

Genetička dobit od selekcije se obračunava po formuli:

$$\Delta G = \frac{h^2 \times \sigma_p \times i}{L}$$

pri čemu je:  $\Delta G$  - genetička dobit  
 $h^2$  - heritabilnost  
 $\sigma_p$  - fenotipska varijabilnost  
 $i$  - intenzitet selekcije  
 $L$  - dužina oplemenjivačkog ciklusa

Povećanje genetičke dobiti moguće je ostvariti korišćenjem početne populacije sa većom fenotipskom varijabilnosti analiziranih genotipova, pravilnom ocenom genetičke vrednosti ili skraćenjem vremena potrebnog za pojedinačni ciklus selekcije (Moose i Mumm, 2008; Xu i sar., 2017). Svaki od navedenih načina zavisi od precizno određenih fenotipskih podataka ispitivanog materijala (Cobb i sar., 2013). Nedovoljan kapacitet kao i neefikasnost aktuelnih metoda fenotipizacije u merenju agronomski važnih osobina predstavljaju ograničavajući faktor u povećanju genetičke dobiti (Zhou i sar., 2022). Kod soje, fenotipizacija podrazumeva praćenje dinamike rasta i razvoja biljaka u toku vegetacionog perioda kao i ocenu morfoloških, fizioloških, biohemijskih i produktivnih osobina. Nedostatak resursa limitira mogućnost prikupljanja svih relevantnih podataka s obzirom da oplemenjivači soje svake godine testiraju veliki broj različitih genotipova. U cilju povećanja efikasnosti procesa selekcije koji za krajnji rezultat ima stvaranje sorte soje a zbog važnosti koju fenotipizacija ima u procesu oplemenjivanja, javlja se potreba za korišćenjem novih alata koji će to i omogućiti. Jedan od načina za unapređenje procesa determinacije kvantitativnih osobina u oplemenjivačkim kolekcijama soje je upotreba modela za visokopropusnu fenotipizaciju.

U odnosu na standardne tehnike koje se zasnivaju na ručnom merenju, visokopropusna fenotipizacija predstavlja jeftiniji i efikasniji način za pribavljanje podataka o velikom broju genotipova u kratkom roku (Nyonje i sar., 2021; Gill i sar., 2022). Pored visoke propusnosti, preciznosti i neinvazivnog pristupa u oceni biljnog materijala, ovaj vid fenotipizacije takođe omogućava dobijanje podataka o osobinama koje nije moguće odrediti klasičnim metodama

(Afonnikov i sar., 2016). Sa druge strane, količina prikupljenih podataka može dovesti do problema kada su u pitanju skladištenje i obrada podataka (Kaur i sar., 2021) što uz biološku interpretaciju rezultata predstavlja jedan od glavnih izazova u primeni visokopropusne fenotipizacije. Pored toga, određeni nedostaci visokopropusne fenotipizacije pri radu u poljskim uslovima odnose se na alate za daljinsku detekciju i fotogrametriju odnosno njihova ograničenja po pitanju autonomije leta i eksploatacije u nepovoljnim vremenskim uslovima (Zhou, 2023).

Daljinska detekcija predstavlja disciplinu u okviru koje se podaci o analiziranim objektima ili površinama beleže na osnovu refleksije svetlosti bez direktnog kontakta (Hamugapriya i sar., 2019). Kao jedna od tehnologija precizne poljoprivrede, daljinska detekcija pruža različite mogućnosti u sagledavanju stanja useva i zemljišta tokom vegetacionog perioda (Khanal i sar., 2020). Počeci upotrebe daljinske detekcije u oblasti poljoprivrede vezani su za satelit *Landsat Multispectral Scanner System* (LANDSAT) koji je 1972. godine poslat u Zemljinu orbitu. Godinu dana kasnije, podaci koji su dobijeni pomoću ovog satelita korišćeni su za klasifikaciju poljoprivrednih useva u državi Illinois, SAD (Bauer i Cipra, 1973). Ovakav način prikupljanja podataka iako ograničen u pogledu preciznosti, ukazao je na veliki potencijal primene digitalnih tehnologija za potrebe poljoprivrede. Pojavom globalnog pozicionog sistema (eng. *global positioning system*, GPS) i razvojem naprednih hardverskih i softverskih rešenja, povećana je rezolucija odnosno preciznost fotografija koje su korišćene za ekstrakciju podataka (Khanal i sar., 2020). Na ovaj način omogućeno je praćenje promena analiziranih objekata u prostoru i vremenu na brz i efikasan način. Iako istraživanja u ovoj oblasti traju više od pola veka, pravu ekspanziju u poljoprivredi doživljavaju u poslednjoj deceniji. O tome svedoči i porast broja naučnih radova sa ovom tematikom i to posebno od 2013. godine (Weiss i sar., 2020). Brojni su razlozi zbog kojih je daljinska detekcija doživela veliki zamah za poslednjih deset godina. Naime, da bi se sagledale mogućnosti i iskoristile prednosti upotrebe ovakvih tehnologija bilo je važno prikupiti dovoljno informacija, analizirati rezultate dotadašnjih istraživanja i steći odgovarajuća znanja. Sa druge strane, visoka cena koštanja uređaja koji su potrebni za prikupljanje podataka ograničavala je njihovu pristupačnost široj zajednici. Razvoj digitalne industrije doveo je do pojeftinjenja alata daljinske detekcije što je omogućilo njenu veću zastupljenost prvo kod istraživača a danas sve više i kod poljoprivrednih proizvođača.

Pored podataka koji se odnose na refleksiju posmatrane površine, veoma važno mesto u okviru precizne poljoprivrede zauzima i fotogrametrija, specifična tehnika pomoću koje je moguće obaviti merenja posmatranih objekata analizom fotografija (Walter i sar., 2018). Pored toga, ona može da se koristi i za karakterizaciju terena i površina zbog čega je našla primenu u različitim oblastima kao što su arheologija, hidrologija, geologija, šumarstvo i poljoprivreda (Delgado-Vera i sar., 2017). Fotogrametrija se upotrebljava preko 150 godina pri čemu su u početku korišćene proste analogne metode zasnovane na optičkim uređajima i mehaničkom merenju dok se u novije vreme za obradu digitalnih fotografija koriste savremeni računari i napredni matematički algoritmi (Aber, 2010). Pored podele po načinu obrade, fotogrametrija se klasificuje i na osnovu udaljenosti sa koje se prikupljaju snimci određenog objekta pa tako postoje: svemirska fotogrametrija (sateliti), zemaljska fotogrametrija (uređaji koji se nalaze na tlu) i vazdušna fotogrametrija (letelice) (Quirós Rosado, 2018). Danas se za potrebe fotogrametrijske obrade u okviru precizne poljoprivrede najviše koriste bespilotne letelice opremljene različitim senzorima koji omogućavaju dobijanje preciznih podataka uz visoku propusnost.

### 2.3.1. Alati i tehnike daljinske detekcije i fotogrametrije

U eri digitalnih tehnologija, sateliti, različiti modeli uređaja koji se nalaze na zemlji i bespilotne letelice čine tri osnovne platforme za prikupljanje fotografija na osnovu kojih se obavlja daljinska detekcija i fotogrametrijska analiza. Kod satelita, jedna od ključnih razlika odnosi se na tip senzora za prikupljanje podataka pa tako postoje one sa multispektralnim i hiperspektralnim senzorima i sateliti bazirani na mikrotalasima (Kumar i Bhagat, 2018). Mnogi od njih, poput LANDSAT-a ili MODIS-a pružaju besplatne fotografije rezolucije do 20 m/piksel dok postoje i komercijalne varijante koje obezbeđuju preciznost i do 0,3 m/piksel. Ovi uređaji prikupljaju podatke sa iste lokacije u rasponu od jednog dana do nekoliko nedelja. Među glavnim prednostima upotrebe satelita navodi se njihova visoka propusnost odnosno mogućnost prikupljanja velike količine podataka za kratko vreme čime se omogućava analiza celokupne površine Zemlje ili nekog specifičnog predela (Guo i sar., 2016). Iako predstavljaju odličan način za monitoring poljoprivrednih površina, glavni nedostatak ovih uređaja je relativno niska rezolucija koja je posebno važna za kreiranje preciznih modela za visokopropusnu fenotipizaciju. Ovo je veoma bitno u oplemenjivanju biljaka budući da se selekcija odvija na velikom broju parcela koje su uglavnom malih dimenzija ( $8\text{-}10\text{ m}^2$ ) dok se u određenim slučajevima analize svode i na pojedinačne biljke. U takvim uslovima kvalitet podataka prikupljenih pomoću satelita može biti narušen usled šumova koji su prouzrokovani pikselima biljaka sa susednih parcela ili zemljišta (Pinto i sar., 2023).

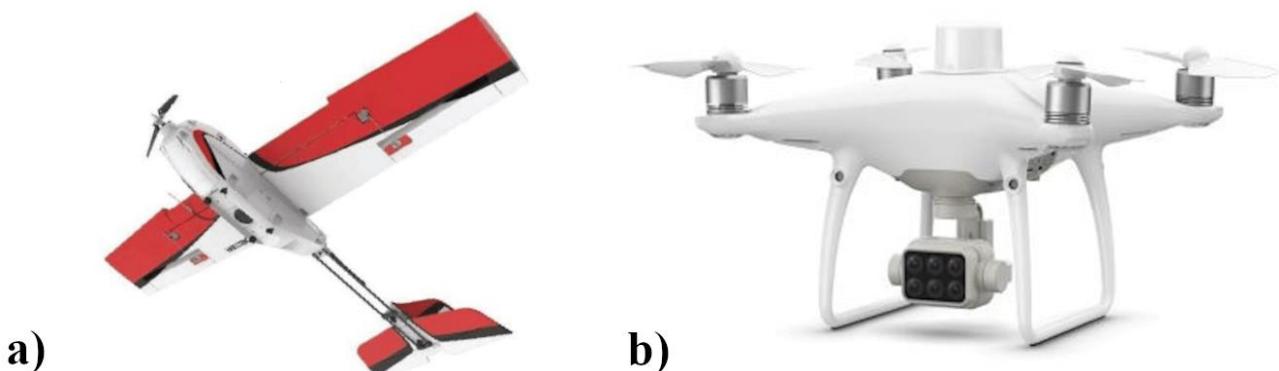
Nasuprot satelitima, postoje i sistemi za prikupljanje podataka čiji uređaji se nalaze na zemlji, neposredno iznad biljaka. U ovu grupu alata za visokopropusnu fenotipizaciju spadaju stacionarni tornjevi (Slika 2a), platforme za skeniranje useva (Slika 2b) i različiti autonomni sistemi za snimanje biljaka (Slika 2c).



**Slika 2.** Sistemi za visokopropusnu fenotipizaciju na tlu. a) stacionarni toranj (Shafiekhani i sar., 2017), b) platforma za skeniranje useva (Virlet i sar., 2017), c) autonomni sistem za prikupljanje podataka (Young, i sar., 2019)

Pojava modernih sistema značajno je unapredila ocenu fenotipskih karakteristika analiziranog materijala u oplemenjivačkim programima pre svega zbog preciznosti koja je obezbeđena fotografijama visoke rezolucije. Pored toga, upotreboom pojedinih uređaja kao što su platforme za skeniranje useva izbegava se sabijanje zemljišta koje je čest slučaj posebno kod sukcesivnih odnosno ponovljenih snimanja iste površine (Bronick i Lal, 2005). Sa druge strane, nedostatak ovih sistema ogleda se u visokoj ceni ali i neodvoljnoj propusnosti odnosno sposobnosti da obezbede kontinuirano praćenje razvoja velikog broja biljaka na brz i efikasan način (Sangjan i sar., 2021). Kao i kod drugih alata koji se koriste za visokopropusnu fenotipizaciju i kod ove grupe se javljaju određene poteškoće kako sa aspekta prikupljanja snimaka (promena osvetljenja tokom rada) tako i one vezane za kompleksnu obradu i interpretaciju dobijenih podataka (Virlet i sar., 2017).

U treću grupu uređaja koji se primenjuju u okviru precizne poljoprivrede spadaju bespilotne letelice. Koristeći digitalne kamere visoke rezolucije, kreću se na visinama od jednog do nekoliko stotina metara. Na ovaj način one kombinuju prednosti prethodna dva sistema, odnosno visoku propusnost satelita i preciznost uređaja na zemlji. Korišćenje bespilotnih letelica je jednostavnije i manje zavisno od vremenskih prilika u odnosu na satelite (Zhang i Kovacs, 2012). Sa druge strane, njihova upotreba omogućava analizu šireg područja i većeg broja lokacija za razliku od sistema na zemlji koji su u tom pogledu značajno ograničeni (Deery i sar., 2014). Zbog sve pristupačnije cene, niskih troškova eksploatacije uz visoku prostornu i vremensku rezoluciju prikupljenih podataka, ovi uređaji postaju sve zastupljeniji u preciznoj poljoprivredi (Matese i sar., 2015; Yang i sar., 2017). Međutim, primena ovih sistema ograničena je određenim faktorima kao što su limitiran kapacitet baterija (Frankelius i sar., 2019), specifične veštine neophodne za pravilnu obradu podataka (Sagan i sar., 2022) i nedovoljna dostupnost senzora koji pokrivaju kompletan spektar refleksije svetlosti. Bespilotne letelice se najčešće dele na one sa fiksnim krilima (Slika 3a) i na koptere sa rotirajućim elisama (Slika 3b).



**Slika 3.** Tipovi bespilotnih letelica koje se koriste za potrebe precizne poljoprivrede. a) letelica sa fiksnim krilima (Jeziorska, 2018), b) kopter sa rotirajućim elisama (Lu i sar., 2020)

Varijante uređaja sa fiksnim krilima podsećaju na maketu aviona kojima se upravlja pomoću autopilota uz mogućnost kontrole visine i navođenja (Ma i sar., 2022). Zbog veće brzine kretanja i većeg kapaciteta baterije, ovaj tip letelice ima mogućnost pokrivanja šireg područja u odnosu na koptere (Puri i sar., 2017). Sa druge strane, kopteri su kontrolisani pomoću brojnih softvera i aplikacija što osigurava jednostavnije upravljanje i bolju kontrolu nad letelicom (Sassu i sar., 2021). Takođe, usled kompjuterski kontrolisanog leta, njihovo kretanje je ujednačenije što omogućava dobijanje podataka koji su precizniji i detaljniji (Boon i sar., 2017). Trenutno postoje različiti modeli ovog tipa bespilotnih letelica a u praksi se najčešće koriste kopteri sa četiri, šest ili osam elisa.

Iako letelice predstavljaju važan segment visokopropusne fenotipizacije, ključnu ulogu u prikupljanju podataka o bilnjom materijalu imaju senzori. Oni beleže reflektovano ili emitovano elektromagnetno zračenje posmatranog objekta pa u skladu sa tim postoje aktivni i pasivni sistemi za daljinsku detekciju. Kao aktivni sistemi označavaju se oni koji emituju zračenje i beleže vrednosti na osnovu povratnog signala, dok pasivni tip senzora isključivo detektuje refleksiju svetlosti

(Latchininsky i Sivanpillai, 2010). Jedan od najzastupljenijih aktivnih senzora je LiDAR (eng. *light-detection and ranging system*) (Slika 4).



**Slika 4.** Aktivni senzor za visokopropusnu fenotipizaciju, LiDAR (eng. *light-detection and ranging system*) (Bongomin i sar., 2024)

Ovaj tip senzora se pokazao kao veoma uspešan za fotogrametrijska merenja zbog čega je našao široku primenu u različitim oblastima poput šumarstva i poljoprivrede. Podaci prikupljeni pomoću LiDAR-a najviše se koriste za potrebe determinacije visine biljaka (Kane i sar., 2010; Suab i Avtar, 2020). Pored toga, ovaj senzora ima mogućnost dubljeg prodiranja kroz vegetativnu masu što može biti korisno za sagledavanje strukturnih karakteristika useva (Shi i sar., 2016). Iako LiDAR obezbeđuje precizne i pouzdane podatke, njegova upotreba ograničena je visokom cenom koštanja i složenošću u prikupljanju podataka čija obrada zahteva posedovanje posebnih znanja i veština (Deery i sar., 2014).

Pasivni senzori predstavljaju digitalne kamere koje beleže reflektovano sunčevu zračenje. Kamere mogu biti integrisane u određeni sistem ili predstavljaju zasebne uređaje koji se naknadno povezuju sa odgovarajućom platformom. U zavisnosti od senzora koji poseduju (Slika 5), imaju mogućnost prikupljanja različitih podataka pri čemu se najčešće koriste:

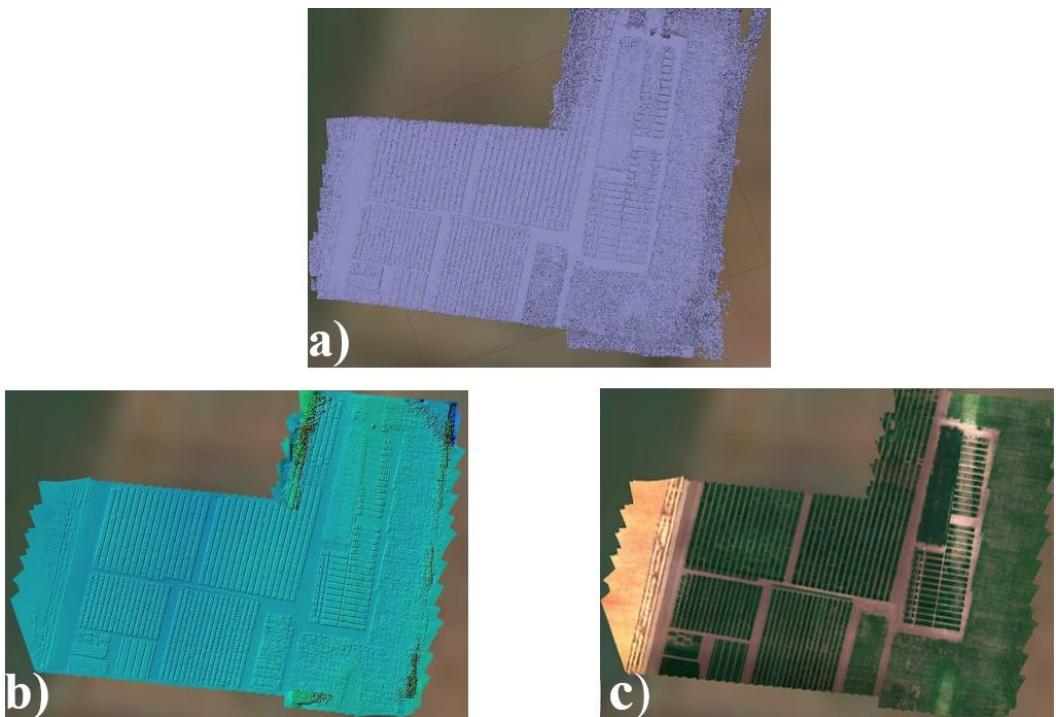
- RGB kamere-poseduju jedan optički senzor koji obezbeđuje podatke iz crvenog (620-700 nm, R), zelenog (480-560 nm, G) i plavog (430-480 nm, B) dela spektra (Slika 5a).
- Multispektralne kamere-karakteriše ih više pojedinačnih, monohromatskih senzora koji pored R, G i B kanala najčešće još pokrivaju RE (eng. *red edge*, 700-780 nm) i NIR (eng. *near-infrared*, 700-1327 nm) (Slika 5b).
- Hiperspektralne kamere-imaju mogućnost prikupljanja podataka o velikom broju talasnih dužina spektra i to na svakih nekoliko nanometara (400 nm-1000 nm) (Slika 5c).
- Termalne kamere-opremljene su senzorom pomoću kojeg je moguće odrediti temperaturu snimanih objekata (Slika 5d).



**Slika 5.** Pasivni senzori za visokopropusnu fenotipizaciju (Bongomin i sar., 2024). a) RGB, b) multispektralni senzor, c) hiperspektralni senzor, d) termalna kamera

Svaka od navedenih kamera ima svoje prednosti ali i određene nedostatke sa aspekta precizne poljoprivrede. Najrasprostranjenije RGB kamere, pružaju mogućnost prikupljanja fotografija koje su visoke rezolucije ali su ograničene na samo tri spektralna kanala. Sa druge strane, multispektralni senzori pružaju bolji uvid u stanje analiziranog materijala zbog toga što obezbeđuju podatke i izvan vidljivog dela spektra (Maes i Steppe, 2019). Kod ovog tipa kamere svaki kanal predstavlja zaseban senzor pa zbog toga najčešće imaju manju rezoluciju a veću cenu u odnosu na RGB. Pokrivajući desetine pa i stotine talasnih dužina spektra, hiperspektralne kamere imaju najveći potencijal za korišćenje u daljinskoj detekciji biljaka (Banerjee i sar., 2020). Dugo je njihova upotreba bila ograničena na uređaje koji imaju relativno nisku preciznost (sateliti) i nedovoljnu propusnost (uređaji na zemlji). Međutim, poslednjih godina ovaj tip senzora u kombinaciji sa bespilotnim letelicama se sve češće koristi za potrebe analize biljaka (Tu i sar., 2018; Shu i sar., 2021). Međutim, još uvek visoka cena ovih uređaja predstavlja glavni limitirajući faktor za njihovu širu rasprostranjenost kako u komercijalne tako i u naučno-istraživačke svrhe. Poslednju grupu čine termalne kamere koje se u poljoprivredi najčešće koriste za praćenje temperature useva ili zemljišta. One predstavljaju odličan alat za toplotni monitoring terena pri čemu su pokazale veliki potencijal za detektovanje stresa koji je prouzrokovao nedostatak vode kod biljaka (Masina i sar., 2020). Budući da je njihova upotreba ograničena na procenu jednog specifičnog parametra, ovaj tip senzora manje je zastupljen u poljoprivrednim istraživanjima koji su bazirani na daljinskoj detekciji (Tsouros i sar., 2019).

Prikupljanje podataka o analiziranom biljnem materijalu pomoću odabranog senzora predstavlja početni korak nakon kog sledi najvažniji i najkompleksniji segment visokopropusne fenotipizacije koji se odnosi na obradu velike količine podataka. U zavisnosti od veličine snimane površine, bespilotna letelica može prikupiti i nekoliko hiljada fotografija na kojima su zabeležene geografske koordinate, elevacija i podaci o spektralnoj refleksiji. Pojedinačne fotografije se pomoću odgovarajućih softvera kao što je Agisoft (Agisoft LLC v. 1.7.2, 2021) koriste za kreiranje jedinstvenog projekta po specifičnom protokolu. Inicijalni korak podrazumeva učitavanje pojedinačnih fotografija u softver nakon čega sledi njihovo poravnavanje u prostoru (eng. *alignment*). Naredni korak se odnosi na kreiranje strukture poznate kao "oblak tačaka" (eng. *dense point cloud*, DPC) pomoću specifične SfM (eng. *structure from motion*) metode koja podrazumeva stvaranje trodimenzionalnog modela na osnovu fotografija koje su snimljene iz različitih uglova (Johnson i sar., 2014). Konačno, DPC omogućava kreiranje digitalnog elevacionog modela (DEM) (Mlambo i sar., 2017) i ortomozaika (Jeziorska, 2018) koji se koriste za dalju obradu. Primeri DPC-a, DEM-a i ortomozaika prikazani su na Slici 6.



**Slika 6.** Prodotti dobijeni nakon sklapanja pojedinačnih fotografija u Agisoft softveru. a) “oblak tačaka” (eng. *dense point cloud*, DPC), b) digitalni elevacioni model (DEM), c) ortomozaik

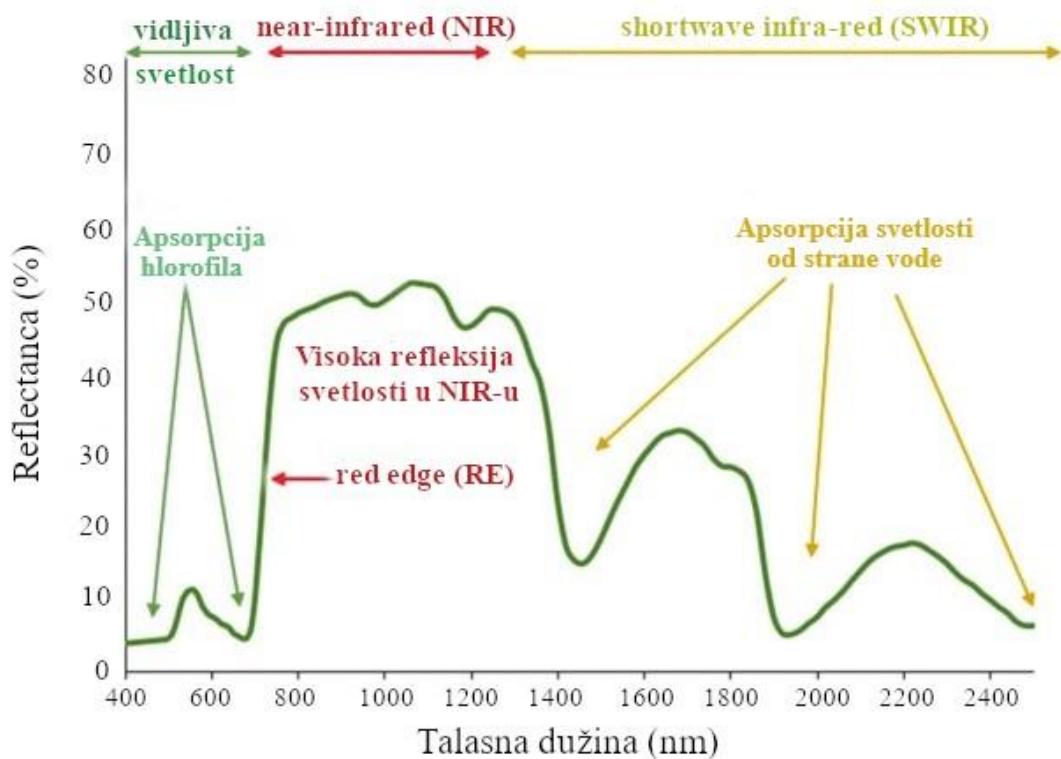
Pored DEM-a, postoje i drugi derivati SfM-a kao što su digitalni model površine (DMP) i digitalni model terena (DMT) (Westoby i sar., 2012; Mesas-Carrascosa i sar., 2015) pri čemu se DMT odnosi na elevaciju tla a DMP na usev koji se na njemu nalazi. Kao glavni ograničavajući faktor pri kreiranju ovih modela navodi se preciznost GPS prijemnika u bespilotnim letelicama (Bendig i sar., 2013; Ruiz i sar., 2013). Integrisani pozicioni sistemi uređaja ne obezbeđuju dovoljnu tačnost kada su u pitanju podaci vezani za geografske koordinate i nadmorskú visinu (Chang i sar., 2017). Zbog toga se za prevazilaženje ovih nedostataka koristite dodatni alati i tehnike. Kao jedan od najpopularnijih načina za georeferisanje (prostornu korekciju) fotografija navodi se upotreba RTK (eng. *real time kinematics*) sistema. Ovaj uređaj poseduje sopstveni predajnik pomoću kog prima GPS podatke iz orbite, koriguje ih na zemlji i šalje letelici koja snima određeni teren. Na ovaj način, RTK omogućava centimetarsku preciznost snimanih objekata (Deliry i Avdan, 2021). Uz RTK-a, korišćenje kontrolnih tačaka (eng. *ground control point*, GCP) predstavlja izuzetno važan faktor kojim se utiče na povećanje apsolutne i relativne preciznosti snimaka. Pored toga, upotreba GCP-a prilikom kreiranja ortomozaika osigurava tačnost i veći stepen automatizacije samog procesa prikupljanja fenotipskih parametara (Turner i sar., 2012). Ovo je veoma važno posebno kada se snimanje istog prostora obavlja više puta tokom vegetacionog perioda što je neophodno za kontinuirano praćenje dinamike rasta biljaka. Iako se kao GCP mogu koristiti bilo koji stacionarni objekti na fotografiji određenog terena koji se snima, najčešće su to drvene ploče (1m x 1m) podeljene na dva crna i dva bela polja radi lakšeg uočavanja. Prilikom postavljanja GCP-a mora se voditi računa o njihovom rasporedu kao i o brojnosti, budući da to može imati veliki uticaj na njihovu efikasnost (Pourali i sar., 2014). Ukupan broj tačaka koji se koristi najčešće zavisi od veličine terena, pri čemu veći broj GCP-a obezbeđuje i veću preciznost rezultata prilikom obrade fotografija, posebno kod određivanja visine (Xie i sar., 2021). Kada je u pitanju pozicioniranje kontrolnih tačaka, važno je da one u okviru snimane parcele budu smešteni na mesta na kojima će biti vidljivi tokom svakog pojedinačnog snimanja. Tačne koordinate (geografska dužina, širina i nadmorska visina) svakog GCP-a, dobijene pomoću RTK-a sistema se kasnije tokom procesa sklapanja pojedinačnih fotografija koriste za georeferisanje ortomozaika i korigovanje apsolutne i relativne preciznosti snimaka.

### **2.3.2. Primena visokopropusne fenotipizacije u oplemenjivanju biljaka**

Tradicionalan način ocene agronomski značajnih osobina u polju se zasniva na zahtevnim i često neefikasnim protokolima zbog čega se u dosadašnjim istraživanjima evaluacija fenotipskih karakteristika oplemenjivačkog materijala svodi na najosnovnije parametre poput boje cveta i dlačica, datuma zrenja, visine, poleganja glavnog stabla i prinosa. Da bi se osigurao dalji napredak u procesu stvaranja vrhunskih sorti soje, neophodno je povećati efikasnost aktuelnih programa. Jedan od načina je preciznija ocena dosadašnjih osobina i uvođenje novih parametara rasta i razvoja biljaka pomoću modela za visokopropusnu fenotipizaciju. Intenzivna istraživanja u oblasti daljinske detekcije dovela su do značajnih rezultata u determinaciji različitih svojstava i boljem razumevanju procesa koji se odvijaju tokom vegetacionog perioda. Trenutno, visokopropusna fenotipizacija se u procesu oplemenjivanja najviše koristi za predikciju važnih osobina koje mogu doprineti boljoj selekciji superiornih genotipova.

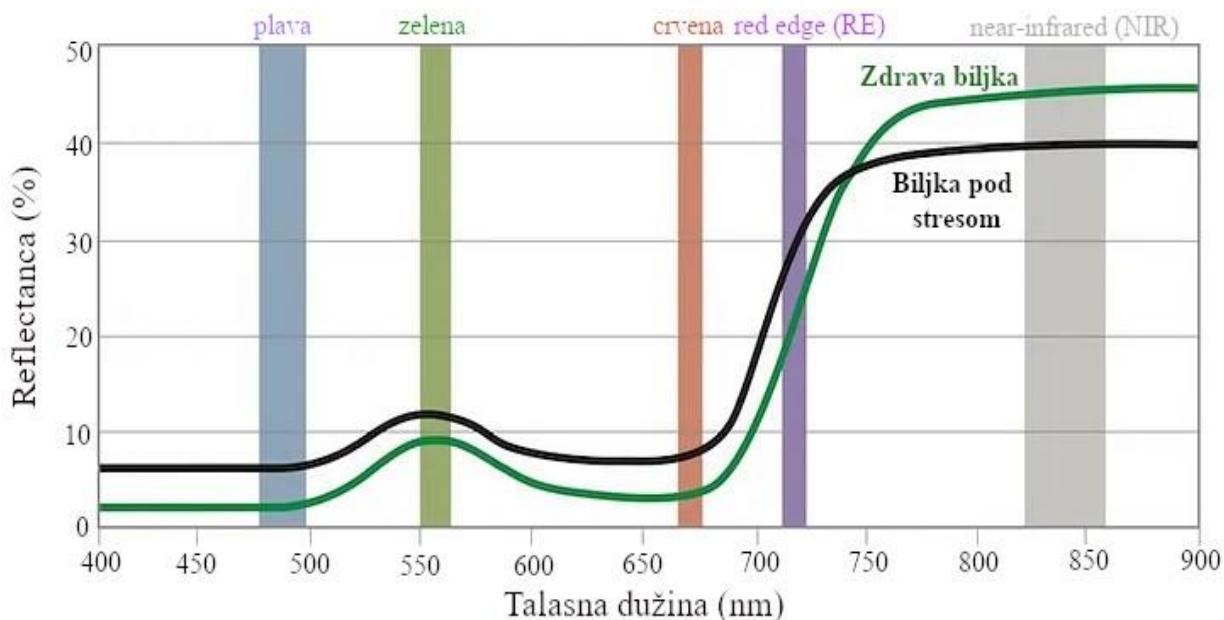
Određivanje visine na osnovu analize elevacionih modela predstavlja jedan od najčešćih primera upotrebe visokopropusne fenotipizacije u oblasti precizne poljoprivrede. Na osnovu razlike između DMP-a i DMT-a omogućeno je dobijanje podataka o visini brojnih biljnih vrsta kao što su pšenica (Holman i sar., 2016; Hassan i sar., 2019), sirak (Hu i sar., 2018) ili kukuruz (Haemmerle i Hoefle, 2016; Che i sar., 2020). Sa druge strane, daljinska detekcija se takođe upotrebljava i za procenu broja biljaka po jedinici površine, pri čemu se u tu svrhu najčešće koriste softverskih algoritmi za uočavanje pojedinačnih biljaka o čemu svedoče prethodni primjeri na pšenici (Guo i sar., 2013), uljanoj repici (Zhao i sar., 2018) i kukuruzu (Kitano i sar., 2019). Obradom fotografija koje su prikupljene pomoću bespilotne letelice moguće je obaviti procenu pokrovnosti useva na brz i nedestruktivan način što predstavlja odličnu alternativu u odnosu na tradicionalne, nedovoljno efikasne metode (Kipp i sar., 2014).

Pri kreiranju preciznih modela za visokopropusnu fenotipizaciju posebna pažnja je posvećena podacima koji se odnose na refleksiju svetlosti. Refleksija sunčevog zračenja od strane biljaka zavisi od više faktora među kojima su hemijske i fiziološke karakteristike listova, njihova ćelijska struktura i položaj (Zhou, 2023). Tipično zdravo biljno tkivo upija više vidljive svetlosti (400-700 nm) a reflektuje značajnu količinu NIR zračenja (Grafik 1). U vidljivom delu spektra najviše se reflektuje zelena svetlost pri čemu se maksimum refleksije dostiže pri oko 540 nm (Moroni i sar., 2019). Dve depresije oko zelenog pika posledica su većeg upijanja plave i crvene svetlosti od strane hlorofila a i b u navedenim regionima (Ollinger, 2010). Oblast označen kao RE, predstavlja nagli skok između crvenog i NIR dela spektra u kom se javlja plato sa visokom refleksijom svetlosti koja se održava od 765 do 1300 nm a posledica je specifične strukture mezofilnih ćelija lista (Xu i Ye, 2023). Nakon NIR dela spektra, u regionu kratkotalasnog infracrvenog zračenja (eng. *shortwave infrared*, SWIR), refleksija sunčeve svetlosti je niža, pre svega zbog visoke apsorbkcije zračenja od strane molekula vode koja je posebno izražena na određenim talasnim dužinama (Ustin i Gamon, 2010).



**Grafik 1.** Spektralna refleksija zdravog biljnog tkiva (modifikovano iz Roman i Ursu, 2016)

Stres ili degradacija linsnog tkiva usled abiotičkih i/ili biotičkih faktora može kod biljaka izazvati promene u refleksiji sunčevog zračenja. Glavna karakteristika ovakvog stanja je da usled razgradnje hlorofila i narušavanja unutrašnje strukture lista dolazi do pojačane refleksije svetlosti u vidljivom delu spektra dok se u NIR-u ona smanjuje (Chang i sar, 2013) (Grafik 2).



**Grafik 2.** Spektralna refleksija zdravih biljaka, biljaka pod stresom i zemljišta (modifikovano iz Roman i Ursu, 2016)

Parametri o refleksiji useva najčešće se koriste za obračun vegetacionih indeksa na osnovu matematičke transformacije podataka iz različitih delova spektra (Viña i sar., 2011). Do sada je kreiran veliki broj različitih vegetacionih indeksa za potrebe daljinske detekcije. U prethodnim istraživanjima, indeksi ExG (eng. *excess green*), ExGR (eng. *excess green red*) i CIVE (eng. *color index of vegetation extraction*) uspešno su iskorišćeni za isticanje biljnih piksela na kontrastnim fotografijama (Romeo i sar., 2013). Pored segmentacije, veliki broj vegetacionih indeksa kreiran na osnovu podataka iz vidljivog dela spektra pokazao se veoma korisnim pri oceni mnogih agronomski važnih osobina. Rezultati prethodnih studija su pokazali dobre rezultate pri korišćenju RGB vegetacionih indeksa za procenu prinosa i poleganja soje (Yuan i sar., 2019) kao i indeksa lisne površine (eng. *leaf area index*, LAI) i biomase strnih žita (Casadesús i Villegas, 2014). Iako podaci o refleksiji biljaka iz R, G i B dela spektra mogu biti uspešno upotrebljeni za procenu važnih osobina, dodatno uključivanje RE i NIR kanala omogućava izračunavanje još većeg broja indeksa koji pružaju bolji uvid u razvojne procese biljaka i precizniju determinaciju različitih parametara. Najpoznatiji vegetacioni indeks koji se dobija kombinacijom NIR i R kanala je NDVI (eng. *normalized difference vegetation index*). Ovaj indeks je našao široku primenu u okviru precizne poljoprivrede gde se pokazao kao veoma koristan alat za analizu zdravstvenog stanja useva (Bokhorst i sar., 2012; Beisel i sar., 2018), procenu efikasnosti iskorišćenja azota (Naser i sar., 2020) ili predikciju prinosa (Ma i sar., 2001). Pored NDVI-ja i drugi indeksi koji su bazirani na svetlosti izvan vidljivog dela spektra kao što su SAVI (eng. *soil adjusted vegetative index*), EVI (eng. *enhanced vegetative index*) ili RDVI (eng. *renormalized difference vegetation index*) imaju veliki potencijal za analizu rasta biljaka što je potvrđeno i u okviru studije na pšenici (Tao i sar., 2020). Rezultati navedenog istraživanja takođe ukazuju da veza između indeksa i određenog svojstva može varirati zavisno od faze u kojoj se usev nalazi. Kao tipičan primer navodi se zasićenje NDVI-ja koje se javlja u kasnijim razvojnim fazama i u uslovima većeg broja biljaka po jedinici površine (Wang i sar., 2016b). U tom slučaju bolje je koristiti NDRE (eng. *normalize difference red edge*) indeks za čije se izračunavanje umesto podataka iz R dela spektra kao kod NDVI-ja, koristi RE koji prodire dublje kroz lisnu masu useva (Clarke i sar., 2001). Primenom NDRE-a obezbeđuje se efikasna procena različitih osobina poput sadržaja azota (Yang i sar., 2011; Ballester i sar., 2017) ili prinosa (Fu i sar., 2020) i u kasnijim fenološkim fazama.

Visokopropusna fenotipizacija može doprineti povećanju efikasnosti drugih tehnika koje se koriste u oplemenjivanju biljaka kao što su genomska selekcija ili *speed breeding*. Genomska selekcija omogućava procenu oplemenjivačke vrednosti genotipova za različite kvantitativne osobine na osnovu molekularnih podataka dobijenih analizom kompletognog genoma (Heslot i sar., 2011). Procena oplemenjivačke vrednosti novih genotipova obavlja se pomoću predikcionih modela koji se kalibrišu na osnovu fenotipskih i genotipskih podataka (Đorđević i sar., 2019). Nedovoljna preciznost i propusnost tradicionalnih metoda za ocenu fenotipskih osobina ispitivanih biljaka ograničava korišćenje punog potencijala genomske selekcije (Mir i sar., 2019). Navedeni nedostaci mogu biti prevaziđeni korišćenjem alata i tehnika daljinske detekcije i fotogrametrije. Njihova upotreba osigurava preciznu karakterizaciju fenotipskih osobina brojnih genotipova u različitim razvojnim fazama što je od velikog značaja za uspešno treniranje genomske predikcione modela (Persa i sar., 2021). U prilog tome govore mnoga istraživanja poput studije na pšenici u okviru koje su vrednosti tri vegetaciona indeksa korišćene kao fiksni efekti prilikom kreiranja modela za predikciju prinosa (Lozada i sar., 2020). Rezultati su pokazali da korišćenje podataka o spektralnoj refleksiji značajno povećava preciznost genomske selekcije i doprinosi boljem odabiru superiornih genotipova. Ranije, do sličnog zaključak došli su Sun i sar. (2017) koji su pored podataka koji se odnose na refleksiju useva (NDVI) koristili i temperaturu biljaka iz više vremenskih tačaka tokom vegetacionog perioda. U studiji je naznačeno da upotreba navedenih sekundarnih osobina može povećati preciznost genomskih modela pri selekciji visokoprinosnih genotipova i do 70%.

Glavna odlika *speed breeding*-a je skraćenje oplemenjivačkog ciklusa kroz razvoj većeg broja generacija tokom jedne vegetacione sezone (Ghosh i sar., 2018). Budući da ovaj metod podrazumeva gajenje biljaka u objektima sa kontrolisanim uslovima kao što su staklare ili komore, prikupljanje podataka o fenotipskoj ekspresiji nije ograničeno spoljašnjim faktorima. Kombinovanjem *speed breeding*-a i visokopropusne fenotipizacije smanjuje se potreba za prevelikom količinom poljskih ogleda a sa tim i radne snage, čime se povećava efikasnost oplemenjivanja (Pasala i sar., 2024). Integracijom navedenih tehnologija u proces selekcije superiornih genotipova moguće je uticati na poboljšanje brojnih osobina kao što su prinos ili tolerantnost na abiotički ili biotički stres (Vala i sar., 2023). Istraživanje na pšenici je pokazalo da korišćenje snimaka korena biljaka koje su gajene u providnim saksijama može biti korisno za odabir genotipova sa poboljšanom arhitekturom podzemnog dela biljke (Richard i sar., 2015). U navedenoj studiji je naglašeno da dobijeni rezultati u kombinaciji sa *speed breeding* tehnologijom mogu biti iskorišćeni za brzu selekciju superiornih linija. Pored toga, uzgojem većeg broja generacija tokom jedne sezone podaci dobijeni visokopropusnom fenotipizacijom mogu biti upotrebljeni za kvantifikovanje stresa (Al-Tamimi i sar., 2016) ili poboljšanje osobina koje doprinose većoj tolerantnosti na sušu (Christopher i sar., 2015).

### 2.3.3. Visokopropusna fenotipizacija i oplemenjivanje soje

Imajući u vidu teškoće koja se javljaju tokom procesa oplemenjivanja soje a koje se pre svega odnose na ograničenja u pogledu resursa i količine prikupljenih podataka, visokopropusna fenotipizacija se sve više nameće kao mogućnost za rešenje navedenih problema. Primenom alata i tehnika daljinske detekcije, oplemenjivačima se pruža mogućnost za testiranje većeg broja genotipova i analizu njihovih performansi na osnovu precizno određenih osobina čime se doprinosi povećanju efikasnosti selekcije (Araus et al., 2018).

U dosadašnjim istraživanjima na soji, visokopropusna fenotipizacija je za potrebe ocene materijala korišćena na brojne načine. Budući da su fiziološki procesi korelisani sa bojom biljaka, mnoge prethodne studije su pokazale da snimci dobijeni pomoću različitih uređaja kao što su bespilotne letelice ili platforme za visokopropusnu fenotipizaciju mogu biti uspešno iskorišćene za prikupljanje važnih podataka o razvoju soje. Koristeći podatke o spektralnoj refleksiji, omogućena je procena osobina kao što su biomasa (Maimaitijiang i sar., 2019) i pokrovnost (Casagrande i sar., 2022) dok se tehnika fotogrametrije koristi pri određivanju drugih pokazatelja kao što je visina (Luo i sar., 2021; Bai i sar., 2022). Imajući u vidu da se tokom procesa selekcije analiza genotipova u polju zasniva na relativno malom broju fenotipskih parametara, svaki dodatni podatak poput prethodno navedenih osobina omogućava bolju ocenu oplemenjivačkog materijala. Iako su pojedinačne vrednosti parametara značajne za opis trenutnog stanja, još veća vrednost visokopropusne fenotipizacije ogleda se u mogućnosti praćenja dinamike rasta biljaka tokom vegetacionog perioda na osnovu podataka koji su prikupljeni više puta tokom sezone (Zhang i Kovacs, 2012). Analizom RGB snimaka koji su prikupljeni u 14 vremenskih tačaka, Borra-Serrano i sar., (2020) su podatke o visini i pokrovnosti upotrebili za kreiranje krivi rasta za preko 350 različitih genotipova soje. U navedenoj studiji, krive rasta kreirane pomoću podataka visokopropusne fenotipizacije i specifičnih matematičkih funkcija, iskorišćene su za dobijanje izvedenih parametara (maksimalna visina, brzina zatvaranja redova, itd.) na osnovu kojih je obavljena selekcija najboljih genotipova. U drugom istraživanju, podaci o pokrovnosti koji su prikupljeni pomoću bespilotne letelice i digitalne kamere u više navrata tokom generativnog perioda, omogućili su utvrđivanje razlika u brzini zatvaranja redova između 200 analiziranih genotipova (Yu i sar., 2024). Rezultati ovog istraživanja su pokazali da genotipovi sa ovalnim oblikom listova brže ispunjavaju vegetacioni prostor i dostižu veće krajnje vrednosti pokrovnosti u odnosu na one sa kopljastim listovima.

Prilikom stvaranja novih sorti soje, velika pažnja se posvećuje i tolerantnosti na stres prouzrokovani različitim abiotičkim i biotičkim faktorima. Među onima koji dovode do najvećeg smanjenja prinosa posebno se izdvaja suša, zbog čega je rad oplemenjivača sve češće usmeren na stvaranje genotipova koji bolje podnose kontinuirani nedostatak vlage. Dosadašnja praksa odabira genotipova tolerantnih na sušu bila je često neefikasna i subjektivna, budući da se u većini slučajeva zasniva na zapažanjima oplemenjivača i prinosu ostvarenom u uslovima slabe obezbeđenosti vodom (Chen i sar., 2014). Imajući u vidu da stres kod biljaka dovodi do morfoloških i fizioloških promena (Basal i Szabo, 2020), podaci visokopropusne fenotipizacije mogu biti iskorišćeni za bolju ocenu genotipova tolerantnih na sušu. U prethodnim istraživanjima, informacije dobijene analizom termalnih snimaka upotrebljene su za selekciju genotipova soje sa sporim uvenućem odnosno gubitkom turgora u listovima pri nedostatku vode, osobinom koja je visokokorelisana sa prinosom zrna (Bai i Purcell, 2018; Zhou i sar., 2020). Sa druge strane, Liang i sar. (2024) su za potrebe ocene performansi analiziranih genotipova soje gajenih u suši koristili parametre poput vegetacionih indeksa, pokrovnosti i visine iz različitih vremenskih tačaka. U navedenoj studiji, podaci dobijeni pomoću visokopropusne fenotipizacije su pokazali da stresni uslovi negativno utiču na osobine rasta i razvoja soje i da se na osnovu njih može obaviti indirektna selekcija superiorne germplazme.

I pored velikog značaja sekundarnih parametara, povećanje prinosu predstavlja glavni cilj oplemenjivačkih programa na soji. Pravilna evaluacija testiranih linija predstavlja jedan od ključnih elemenata od koga zavisi uspeh selekcije (Zhang i sar., 2019b). Koristeći podatke dobijene daljinskom detekcijom i fotogrametrijom moguće je obaviti ranu predikciju prinosu analiziranih genotipova čime se doprinosi povećanju efikasnosti i preciznosti oplemenjivanja. Bai i sar. (2016) su pomoću specijalizovane platforme i pet senzora (ultrasonični, NDVI, termalni, spektometar i RGB senzor) obavili karakterizaciju 15 genotipova soje koji su gajeni u različitim uslovima. Analizom prikupljenih snimaka u više vremenskih tačaka tokom vegetacionog perioda procenjena je visina, temperatura, tri varijante NDVI indeksa i ideo zelenih piksela svake eksperimentalne parcele kako bi se utvrdila njihova veza sa prinosom zrna. Dobijene vrednosti Pirsonovog koeficijenta korelacije koje su se kretale i do 0,7 ukazuju da navedeni parametri (posebno iz početnih i krajnjih vremenskih tačaka) mogu biti uspešno iskorišćeni za nedestruktivnu procenu prinosu soje. Do sličnih zaključaka došli su Yu i sar. (2016) koji su za predviđanje prinosu pored parametara o pokrovnosti i refleksiji, koristili i podatke o dužini redova dobijenih na osnovu odnosa broja zelenih piksela biljaka i ukupnog broja piksela na fotografijama. Rezultati navedene studije su pokazali da uključivanje podataka o dužini redova dovodi do smanjenja standardne greške i veće preciznosti modela za procenu prinosu linija soje iz različitih faza oplemenjivačkog procesa. Dalji napredak u selekciji superiornih genotipova potpomognut visokopropusnom fenotipizacijom odnosi se na implementaciju hiperspektralnih kamera koje imaju mogućnost prikupljanja podataka kontinuirano duž spektra (Zhang i sar., 2019b). Koristeći ovaj tip senzora, Berbeglieri i sar. (2024) su tokom R5 faze razvoja soje prikupili podatke o refleksiji biljaka sa 25 talasnih dužina koje su bile u rasponu od 500 do 900 nm. Koristeći podatke o refleksiji i fotogrametriji uspešno su obavili procenu prinosu analiziranih genotipova soje ( $r = 0,91$ ).

## 2.3.4. Primena mašinskog učenja u visokopropusnoj fenotipizaciji

Predikcija osobina od interesa može biti zasnovana na prostoj regresionoj zavisnosti između određenog biljnog svojstva i specifičnog parametra koji je određen daljinskom detekcijom ili fotogrametrijom. Ovakav pristup je relativno jednostavan ali vrlo često nedovoljno precizan, posebno pri determinaciji složenijih osobina poput prinosa ili biomase. U tom slučaju, neophodno je kreirati kompleksnije modele za visokopropusnu fenotipizaciju u okviru kojih je moguće koristiti više prediktora istovremeno. Ovo se postiže upotreboru nekih od algoritama mašinskog učenja koji omogućavaju korišćenje velikih setova podataka, pronađenje šablonu i posmatranje različitih varijabli istovremeno kako bi se dobili što tačniji podaci o agronomski važnim svojstvima (Singh i sar., 2016.). Veliki broj istraživanja (Guo i sar., 2015; Ali i sar., 2015; Yuzugullu i sar., 2017) govori o uspešnosti primene mašinskog učenja za potrebe kreiranja modela za predikciju različitih osobina gajenih biljaka. U tu svrhu koriste se brojni modeli kao što su regresija vektora podrške (eng. *support vector regression*, SVR), k-najbliži susedi (eng. *k-nearest neighbors*, KNN), veštačka neuronska mreža (eng. *artificial neural network*, ANN), regresija delimičnih najmanjih kvadrata (eng. *partial least square regression*, PLSR), nasumična suma (eng. *random forest*, RF) ili konvolucionala neuronska mreža (eng. *convolutional neural networks*, CNN). Algoritmi poput ANN-a, SVR-a ili CNN-a bazirani su na posebnoj metodi takozvanog dubokog učenja (eng. *deep learning*) i pogodniji su za rešavanje zadatka koji uključuju determinaciju, prepoznavanje i brojanje objekata na fotografijama (Abebe i sar., 2023). Sa druge strane, RF model je zasnovan na binarnom drveću i može biti korišćen za potrebe klasifikacije i regresije (Jeong i sar., 2016). Na osnovu stabala, RF grupiše inicijalne podatke i nakon toga obavlja finalnu predikciju koristeći parametre sa svih drveća (Cutler i sar., 2007). Kao jedan od najčešće primenjivanih modela mašinskog učenja pokazao je visoku preciznost kada je u pitanju predikcija lisne površine kukuruza (Zhou i sar., 2019a), prinosa soje (Parmley i sar., 2019) ili sadržaja hlorofila u pšenici (Shah i sar., 2019). Rezultati prethodnih studija su pokazali da je za procenu pojedinih kvantitativnih osobina poput biomase, bolje koristiti RF i slične modele nego ANN ili SVR algoritme (Wang i sar., 2016a). Još jedan od veoma korisnih algoritama za kreiranje modela za visokopropusnu fenotipizaciju je i PLSR kod kog se veza između zavisne (osobina od interesa) i nezavisnih varijabli (podaci dobijeni obradom fotografija-prediktori) određuje pomoću glavnih komponenti (eng. *principal components*). U prethodnim istraživanjima, PLSR je uspešno iskorišćen za predikciju prinosa pšenice (Zhaopeng i sar., 2020) i prinosa i biomase krompira (Li i sar., 2020). Nezavisno od izbora algoritma, prilikom kalibracije predikcionog modela neophodno je posedovanje seta podataka koji će služiti za učenje (trening set) i seta za proveru preciznosti odnosno evaluaciju modela (test set). Modela na trening i test set se obavlja pomoću neke od poznatih tehnika među kojima je najzastupljenija unakrsna validacija (eng. *cross-validation*) (Hastie i Friedman, 2008). Ova tehnika se koristi u cilju smanjenja takozvanog “prevelikog podudaranja” (eng. *over-fitting*) koje se javlja kod modela koji imaju nisku preciznost kada se testiraju na nezavisnim podacima (Ying, 2019). Postoji veliki broj različitih varijanti unakrsne validacije među kojima su i k-fold, LOOCV (eng. *leave-one-out cross-validation*) i LGOCV (eng. *leave-group-out cross-validation*).

### **3. NAUČNI CILJ ISTRAŽIVANJA**

Naučni cilj ovog istraživanja je razvoj modela za visokopropusnu fenotipizaciju soje na osnovu analize fotografija koje su prikupljene pomoću bespilotne letelice i integrisane kamere. Istraživanja u ovoj disertaciji predstavljaju pomak ka primeni digitalnih tehnologija u karakterizaciji oplemenjivačkog materijala koje je ostvareno na osnovu sledećih ciljeva:

- Razvoj modela za predikciju broja biljaka po jedinici površine, pokrovnosti, visine, biomase i prinosa soje koristeći podatke daljinske detekcije i fotogrametrije.
- Praćenje toka vegetacionog perioda divergentne germplazme soje na osnovu dinamičke promene pokrovnosti, visine i biomase čije će vrednosti biti određene u više vremenskih tačaka pomoću prethodno kreiranih prediktivnih modela.
- Analiza germplazme soje na osnovu morfoloških, tehnoloških i produktivnih osobina te utvrđivanje veze između dobijenih podataka i podataka visokopropusne fenotipizacije.
- Odabir superiornih genotipova soje na osnovu vrednosti osobina koje su prikupljene klasičnom fenotipizacijom i osobina procenjenih pomoću modela za visokopropusnu fenotipizaciju.

## **4. OSNOVNE HIPOTEZE OD KOJIH SE POLAZI**

U okviru ovog istraživanja postavljene su sledeće hipoteze:

- U istraživanju se polazi od pretpostavke da se na osnovu podataka dobijenih daljinskom detekcijom i fotogrametrijskom analizom digitalnih fotografija genotipova soje, prikupljenih tokom vegetacionog perioda, mogu kreirati pouzdani modeli za predikciju broja biljaka po jedinici površine, pokrovnosti, visine, biomase i prinosa.
- Modeli za visokopropusnu fenotipizaciju soje kreirani i ocenjeni na osnovu analize odabralih genotipova omogućiće uspešnu procenu parametara rasta i svih ostalih genotipova u okviru postavljenih ogleda.
- Kreiranje modela na osnovu podataka koji su prikupljeni tokom višegodišnjih ogleda u nezavisnim okruženjima osiguraće dovoljnu robustnost za njihovo korišćenje u različitim uslovima.
- Rezultati dobijeni pomoću kreiranih modela za visokopropusnu fenotipizaciju mogu se povezati, kroz dalja istraživanja, sa vrednostima morfoloških, tehnoloških i produktivnih osobina.
- Vrednosti kvantitativnih osobina koje su dobijene pomoću modela za visokopropusnu fenotipizaciju i klasičnim metodama fenotipizacije omogućiće pronalaženje razlika između analiziranih genotipova soje i detektovanje superiorne germplazme koja bi kao takva mogla biti uključena u buduće oplemenjivačke programe.

## 5. MATERIJAL I METODE

### 5.1. FAZA I - Razvoj modela za predikciju broja biljaka soje po jedinici površine

#### 5.1.1. Poljski ogledi i biljni materijal korišćen u okviru Faze I

U okviru prve faze istraživanja razvijen je model za predikciju broja biljaka po jedinici površine na osnovu podataka dobijenih analizom fotografija eksperimentalnih parcela soje koje su snimane pomoću digitalne kamere i bespilotne letelice. Za potrebe kalibriranja modela u 2018. godini korišćeno je 66 genotipova soje koji su bili posejani na oglednim parcelama veličine 8 m<sup>2</sup> dok je validacija obavljena naredne godine na 200 novih genotipova ovaj put posejanim na parcelama od 10 m<sup>2</sup>. Kompletan set od 266 genotipova koji je upotrebljen u ovom delu istraživanja činile su eksperimentalne oplemenjivačke linije različitih grupa zrenja sa divergentnom arhitekturom biljaka. Setva ogleda je u obe godine obavljena na zemljištu tipa černozem, kojeg karakterišu visoka plodnost i optimalan vodno-vazdušni režim. Karakteristike ogleda, alati i tehnike daljinske detekcije koji su korišćeni za potrebe kreiranja modela za predikciju broja biljaka po jedinci površine dati su u Tabeli 1.

**Tabela 1.** Materijal i metode korišćene u okviru prve faze istraživanja prilikom kreiranja modela za predikciju broja biljaka soje po jedinici površine

Period (godina)	2018-2019
Broj kalibracionih/evaluacionih parcela	266 (66/200)
Veličina osnovne parcele	8-10 m <sup>2</sup>
Bespilotna letelica	Phantom 4 (DJI)
Tip senzora	RGB
Visina leta	100 m
Broj snimaka po godini	2
Korišćena tehnika za kreiranje modela	Mašinsko učenje- nasumična šuma (eng. <i>random forest</i> , RF)
Prediktori	RGB vegetacioni indeksi

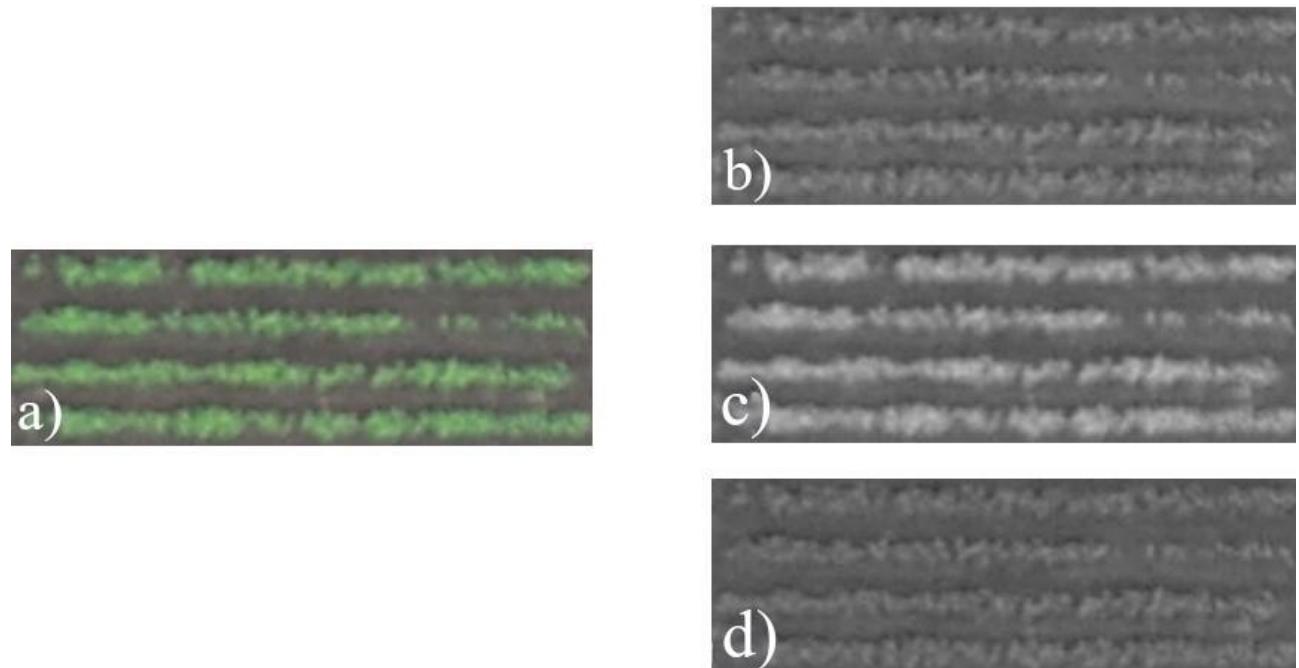
#### 5.1.2. Bespilotna letelica i prikupljanje podataka tokom Faze I

Za fotografisanje ogleda je korišćena letelica Phantom 4 (DJI, Šenžen, Kina) koju pokreću četiri propeleri i kojom se upravlja pomoću daljinskog upravljača radne frekvencije 2,4 GHz. Navedena letelica je opremljena integrisanim kamerom sa optičkim CMOS (eng. *complementary metal oxide semiconductor*) senzorom veličine 1/2,3" i rezolucijom od 12,4 megapiksela. Ova kamera pokriva vidljivi deo spektra i na taj način obezbeđuje podatke o refleksiji R, G i B svetlosti. Fotografisanje parcela soje je u obe godine obavljeno dva puta tokom vegetacionog perioda u periodu od 10:00h do 14:00h pri sunčanom danu. Prvo snimanje je realizovano u fazi četiri troliske (V4) a drugo u fazi početka formiranja mahuna soje (R3) (Slika 7).



**Slika 7.** Kalibracione parcele soje u 2018. godini snimljene bespilotnom letelicom. (a) faza četiri troliske (V4), (b) faza početka formiranja mahuna (R3)

Posle svakog snimanja, pojedinačne fotografije povezane su u jedinstveni ortomozaik pomoću softvera WebODM (OpenDroneMap). Nakon toga pristupilo se analizi pojedinačnih parcela na RGB ortomozaiku pomoću FIJI (Schindelin i sar., 2012), softvera za obradu fotografija. Prvo su u FIJI-ju na RGB fotografiji kreirani regioni od interesa (eng. *region of interest*, ROI) u obe faze za svaku od 66 parcela iz 2018. godine i isto tako za preostalih 200 iz 2019. godine. Nakon kreiranja individualnih ROI-ja, zbirni RGB ortomozaik je pomoću FIJI funkcije *stack to images* razdvojen na pojedinačne R, G i B kanale (Slika 8).

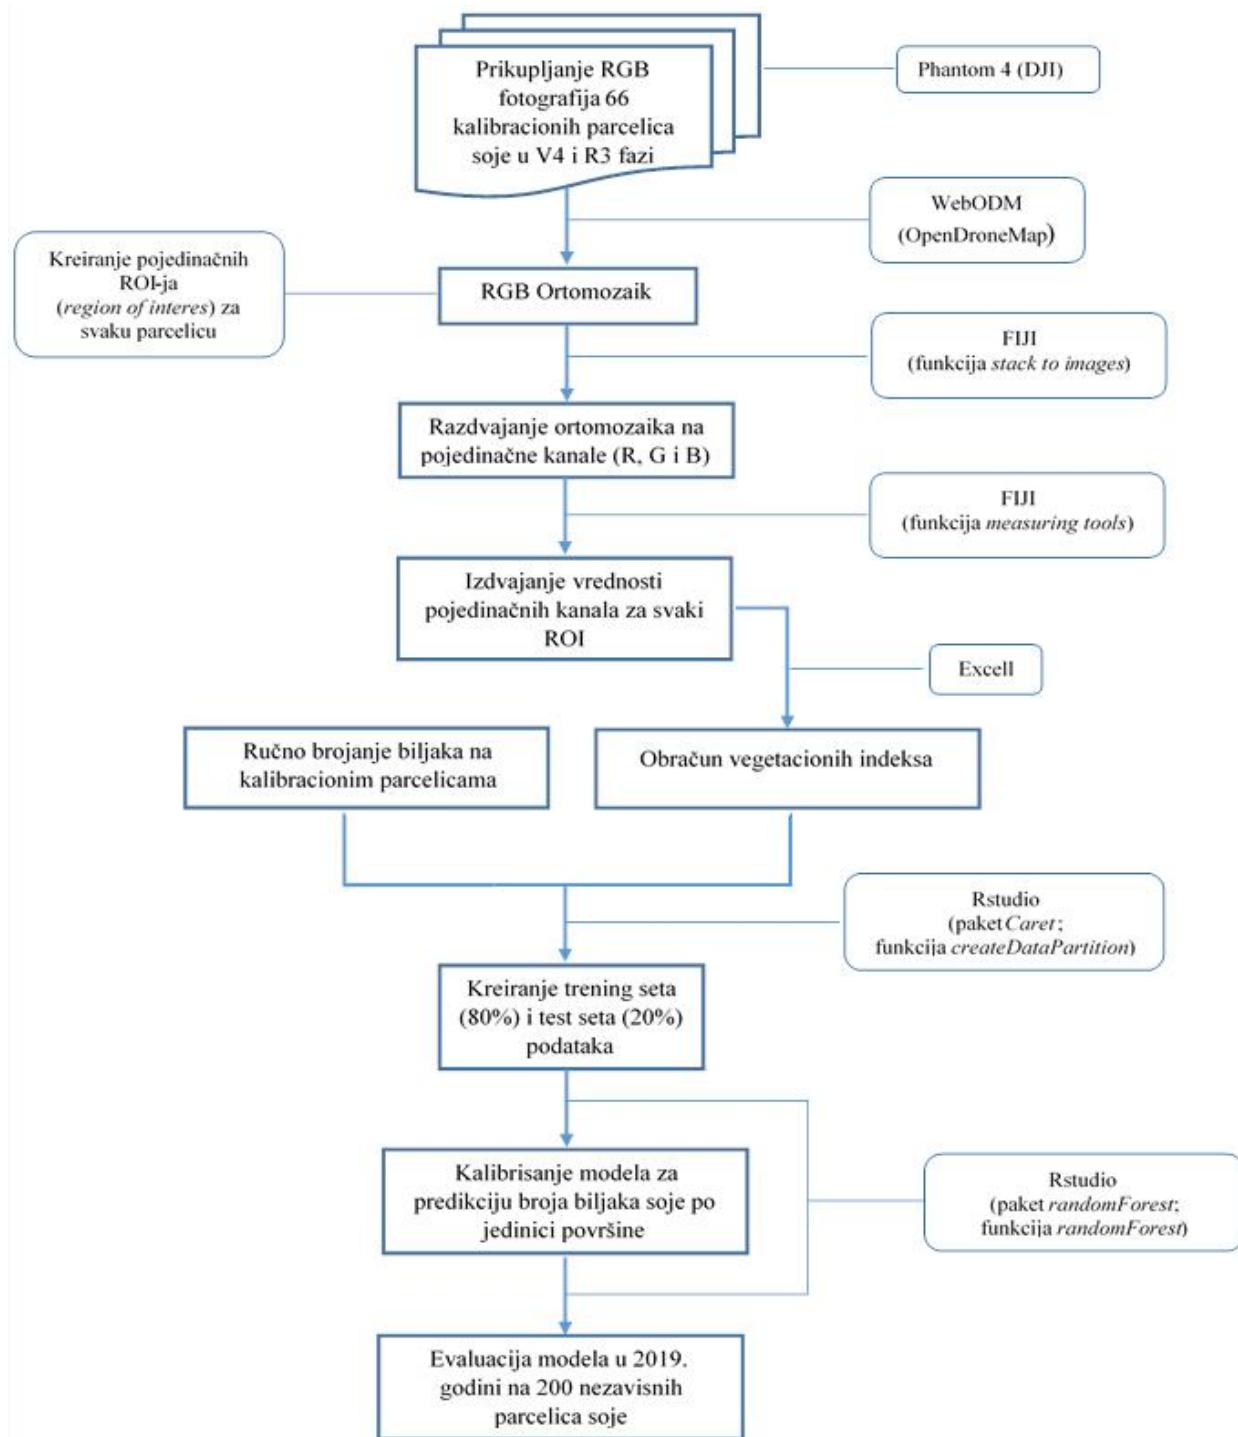


**Slika 8.** Primer kalibracione parcele soje iz 2018. godine. (a) RGB fotografija, (b) crveni kanal (R), (c) zeleni kanal (G), (d) plavi kanal (B)

Nakon izdvajanja pojedinačnih kanala, pomoću funkcije *measuring tools* (FIJI) pristupilo se ekstrakciji srednjih vrednosti kanala za svaki ROI (eksperimentalnu parcelu) u obe godine. Na osnovu dobijenih podataka, izračunato je osam vegetacionih indeksa (PRILOG 2; indeksi označeni sa \*) koji su korišćeni kao prediktori u okviru RF algoritma.

### 5.1.3. Kreiranje modela za predikciju broja biljaka soje po jedinici površine

Model za predikciju broja biljaka soje po jedinici površine kreiran je u okviru statističkog softvera R (RStudio Team, 2018) uz pomoć *randomForest* (Liaw i Wiener, 2018) funkcije iz istoimenog paketa. Kalibracija je obavljena na osnovu ručno izbrojanog broja biljaka/m<sup>2</sup> i vegetacionih indeksa izračunatih na 66 parcela u 2018. godini. Od ukupnog seta podataka, 80% je korišćeno za treniranje modela a ostalih 20% za evaluaciju. Za podelu podataka korišćen je *caret* paket (Kuhn, 2008) i funkcija *createDataPartition*. Šema razvoja modela prikazana je na Slici 9.



Slika 9. Šema razvoja modela za predikciju broja biljaka soje po jedinici površine

Rezultati dobijeni pomoću predikcionog modela upoređeni su sa ručno izbrojanim brojem biljaka radi ocene preciznosti. Naredne godine obavljena je dodatna evaluacija na nezavisnom setu podataka koji je prikupljen na 200 parcela soje. Performanse predikcionog modela su i u ovom slučaju proverene poređenjem sa ručno izbrojanim vrednostima i ocenjene na osnovu koeficijenta korelacije (eng. *correlation coefficient*, r), koeficijenta determinacije (eng. *coefficient of determination*, R<sup>2</sup>), srednje apsolutne greške (eng. *mean of the absolute error*, MAE) i korena srednje kvadratne greške (eng. *root mean square error*, RMSE). Značaj prediktora koji su korišćeni za potrebe kreiranja modela, prikazan je pomoću vrednosti IncNodePurity (eng. *Increase in Node Purity*) koja se takođe dobija kao rezultat RF algoritma. Ovaj pokazatelj predstavlja meru ujednačenosti uzorka nakon podele podataka na osnovu određene varijable (prediktora) (Echeverry-Galvis i sar., 2014). Kreirani model korišćen je za predikciju broja biljaka po jedinici površine i na eksperimentalnim parcelama soje posejanim u 2020. i 2021. godini.

## **5.2. FAZA II - Razvoj modela za predikciju visine, pokrovnosti, biomase i prinosa soje**

### **5.2.1. Poljski ogledi i biljni materijal korišćen u okviru Faze II**

Kreiranje modela za visokopropusnu fenotipizaciju pokrovnosti, visine, biomase i prinosa u ovom delu istraživanja obavljeno je na divergentnoj germplazmi soje koja je analizirana u ogledima postavljeni po proširenom p-rep (eng. *partially replicated*) dizajnu (Williams i sar., 2011). Kompletan biljni materijal koji je korišćen u okviru druge faze istraživanja činila je oplemenjivačka kolekcija od 206 genotipova soje od kojih je njih 117 označeno kao rana (PRILOG 3) a 89 kao kasna germplazma (PRILOG 4). Svaki genotip je posejan u četiri reda pri čemu su samo neki od njih bili zastupljeni u više ponavljanja kao kontrola. Odabrani genotipovi su u identičnim ogledima posejani na dva tipa zemljišta koji su se razlikovali u pogledu kvaliteta i mehaničkog sastava. Kako bi se simulirali uslovi suše, jedan set genotipova bio je posejan na zemljištu niske plodnosti sa slabom retencijom vode (peskoviti les), a drugi kao kontrola na černozemu sa optimalnim proizvodnim karakteristikama (PRILOG 5). U ogledima koji su obeleženi kao RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola) svake godine je bilo zastupljeno ukupno 560 eksperimentalnih parcela soje veličine 8 m<sup>2</sup>. Modeli za predikciju pokrovnosti i prinosa soje kreirani su analizom svih eksperimentalnih parcela dok je za model za procenu visine korišćeno 20 parcela iz RK ogleda. U ovoj fazi su pored navedenih, posejane i dodatne parcele za potrebe razvoja modela za predikciju biomase soje. Budući da je kalibriranje ovog modela podrazumevalo primenu destruktivnih metoda, dodatnih 50 parcela posejano je u prvoj a 40 u drugoj godini ovog dela istraživanja. Opšti prikaz ogleda, odabranih alata i tehnika korišćenih prilikom razvoja modela za predikciju visine, pokrovnosti, biomase i prinosa soje dat je u Tabeli 2.

**Tabela 2.** Materijal i metode korišćene u okviru druge faze istraživanja prilikom kreiranja modela za predikciju pokrovnosti, visine, biomase i prinosa soje

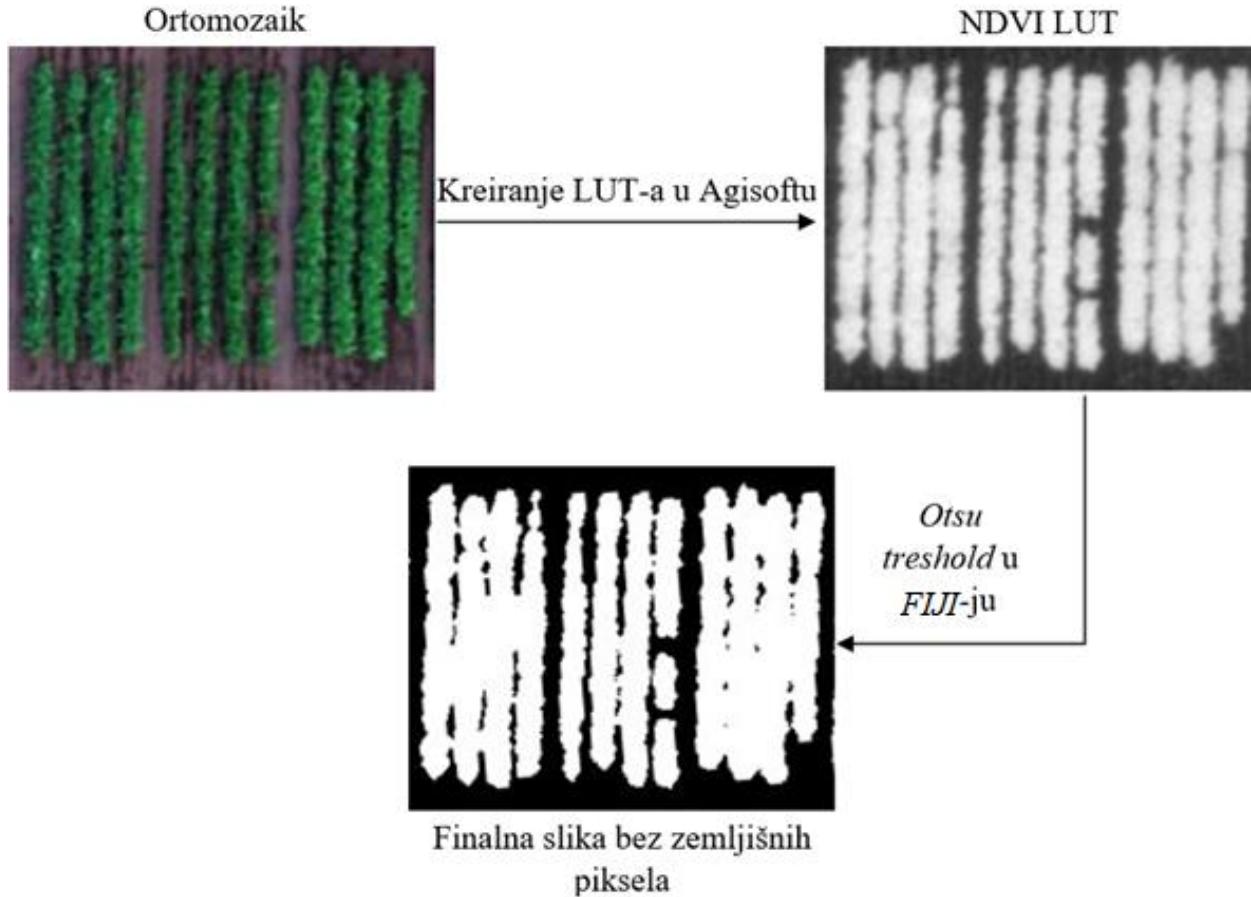
Period	2020-2021			
<b>Osobina soje za koju se kreira predikcioni model</b>	Pokrovnost	Visina	Biomasa	Prinos
<b>Broj kalibracionih/evaluacionih parcela</b>	1120	40	90	1120 (1113)
<b>Veličina eksperimentalne parcele soje</b>	$8 \text{ m}^2$			
<b>Bespilotna letelica</b>	P4M (DJI)			
<b>Tip senzora</b>	RGB i Multispektralni (R, G, B, RE i NIR kanali)			
<b>Visina leta</b>	60 m			
<b>Broj vremenskih tačaka po godini</b>	12	8	4-5	12
<b>Korišćena tehnika/algoritam za kreiranje modela</b>	Segmentacija	Fotogrametrija	RF, PLSR	RF, PLSR
<b>Prediktori</b>	/	/	Pokrovnost, visina, RGB/MS vegetacioni indeksi	Biomasa, pokrovnost, visina, RGB/MS vegetacioni indeksi

### 5.2.2. Bespilotna letelica i prikupljanje podataka u okviru Faze II

Bespilotna letelica koja je korišćena za potrebe snimanja u okviru druge faze istraživanja bila je P4M (DJI, Šenžen, Kina). Ova letelica je opremljena sa multispektralnom kamerom koju čine šest 1/2,9" CMOS senzora od kojih je pet monohromatskih R, G, B, RE i NIR i jedan RGB sa rezolucijom od 2,08 megapiksela i fokalnom dužinom od 5,74 mm. Tokom svakog leta, bespilotna letelica je bila povezana sa RTK sistemom za dodatno povećanje preciznosti prikupljenih snimaka. Pojedinačna fotografisanja eksperimentalnih parcela soje obavljena su pri sunčanom danu uz brzinu vетра koja nije prelazila 10 m/s i na visini od 60 m čime je obezbeđena rezolucija fotografija od 3,17 cm/piksela. Fotografisanje RK, KK, RS i KS ogleda tokom 2020. i 2021. godine obavljeno je u različitim vremenskim tačkama koje su predstavljene u vidu suma aktivnih temperatura ( $t > 10^\circ\text{C}$ ) nakon nicanja (eng. *growing degree days*, GDD). Snimanja su u obe godine obavljena pri oko 103, 167, 230, 274, 390, 474, 642, 706, 828, 917, 1001 i 1130 GDD. Za procenu pokrovnosti korišćene su sve vremenske tačke dok su prilikom kreiranja modela za predikciju visine izuzete vremenske tačke 103, 167, 474 i 828 GDD. Parcele soje koje su dodatno posejane za predikciju biomase su tokom 2020. i 2021. godine fotografisane pet, odnosno četiri puta. U prvoj godini snimanje je obavljeno pri 274, 413, 650, 745 i 1016 GDD a u drugoj pri 215, 492, 747 i 1130 GDD.

### 5.2.3. Kreiranje modela za predikciju pokrovnosti soje

Razvoj modela za predikciju pokrovnosti soje zasnovan je na tehnici segmentacije koja služi za eliminisanje zemljišnih piksela na fotografijama prikupljenih pomoću bespilotne letelice. Tehnika je bazirana na NDVI indeksu koji je izračunat u Agisoft softveru i pomoću kog je kreiran LUT (eng. *look up table*) kako bi se istakle biljke soje. Za razdvajanje zemljišnih od biljnih piksela korišćen je *Otsu* metod (Otsu, 1979) koji je u okviru *threshold* funkcije iz FIJI softvera primenjen na dobijenom NDVI LUT-u (Slika 10).

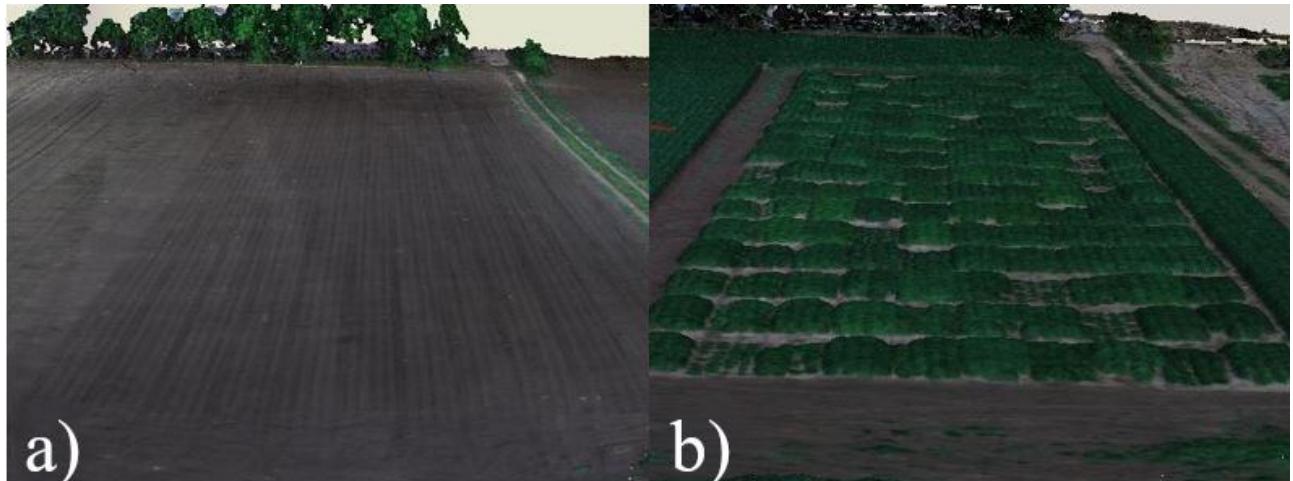


Slika 10. Maskiranje zemljišta prilikom određivanja pokrovnosti genotipova soje

Po dobijanju binarne slike, pristupilo se kreiranju ROI-ja za svaku parcelu radi određivanja procentualnog udela zemljišta koji je prekriven bilnjom masom. Pomoću kreiranog modela a na osnovu procenta biljnih piksela koji se nalaze u svakom ROI-ju, pokrovnost je prediktovana za svaku eksperimentalnu parcelu soje. Nakon prikupljanja podataka o pokrovnosti analiziranih genotipova tokom vegetacionog perioda, obavljen je obračun dužine trajanja maksimalne pokrovnosti (ukupan broj dana sa pokrovnošću iznad 90%). Navedeni parametar predstavlja važno fenotipsko svojstvo budući da je od ranije poznato da se proces fotosinteze najintenzivnije odvija pri maksimalnoj pokrivenosti zemljišta lisnom masom (Wells, 1991; Lee, 2006). Na osnovu dobijenih podataka izdvojeni su genotipovi kojima je za dostizanje 50% pokrovnosti trebalo najmanje vremena kao i oni sa najdužim trajanjem maksimalne pokrovnosti. Šema modela za predikciju pokrovnosti prikazana je na Slici 12a.

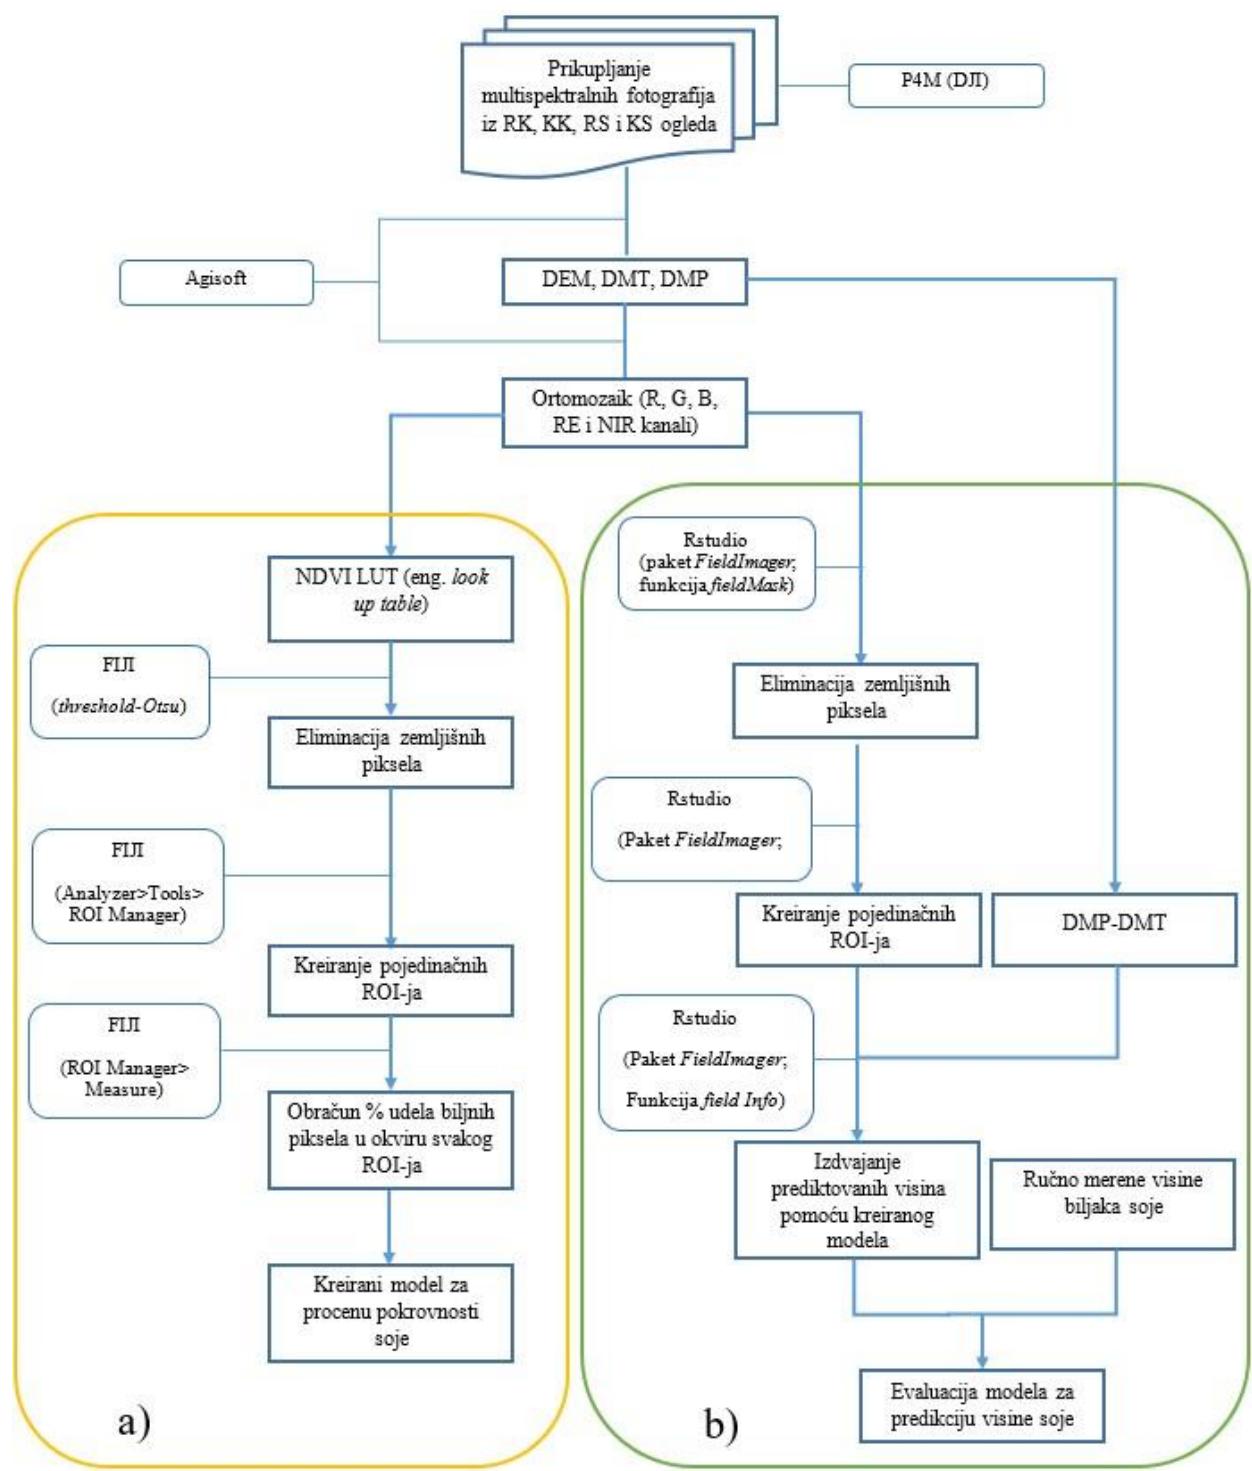
#### 5.2.4. Kreiranje modela za predikciju visine soje

Nakon svakog snimanja u okviru druge faze istraživanja, na osnovu prikupljenih fotografija kreirani su elevacioni modeli (DEM, DMT, DMP) i ortomozaici pomoću Agisoft softvera. Model za predikciju visine zasnovan je na razlici u elevaciji koja je dobijena između DMT-a i DMP-a na 40 eksperimentalnih parcela soje u osam vremenskih tačaka (Slika 11).



Slika 11. Primer (a) digitalnog modela terena (DMT) i (b) digitalnog modela površine (DMP)

Za određivanje visine korišćen je R softver i u okviru njega *FIELDimageR* paket (Matias i sar., 2020). Obrada elevacionih modela i ortomozaika u svakoj vremenskoj tački odvijala se u nekoliko faza. Inicijalni korak je podrazumevao odstranjivanje zemljišta kreiranjem maske pomoću *fieldMask* funkcije i SCI (eng. *Soil Color Index*) (Mathieu i sar., 1998) vegetacionog indeksa. Nakon maskiranja zemljišta, upotrebljena je funkcija *fieldPolygon* kako bi se kreirali ROI-ji kalibracionih parcela na ortomozaiku. Konačno, oduzimanjem DMT-a od DMP-a pomoću *fieldInfo* funkcije izdvojene su vrednosti visine svake eksperimentalne parcele. Prediktovane visine biljaka na kalibracionim parcelama soje upoređene su sa ručno izmerenim vrednostima radi utvrđivanja preciznosti modela. Ručno merenje obavljeno je neposredno pre svakog snimanja i to pomoću lenjira sa centimetarskom skalom. Merenja su obavljena na pet mesta u okviru svake odabrane parcele nakon čega su obračunate prosečne vrednosti korišćene za evaluaciju predikcionog modela na osnovu  $R^2$ , MAE i RMSE vrednosti. Uz pomoć kreiranog modela, obavljena je predikcija visina svih eksperimentalnih parcela u drugoj fazi istraživanja nakon čega su izdvojeni genotipovi soje kod kojih maksimalna dostignuta visina bila između 100 i 110 cm. Šema modela za predikciju visine prikazana je na Slici 12b.

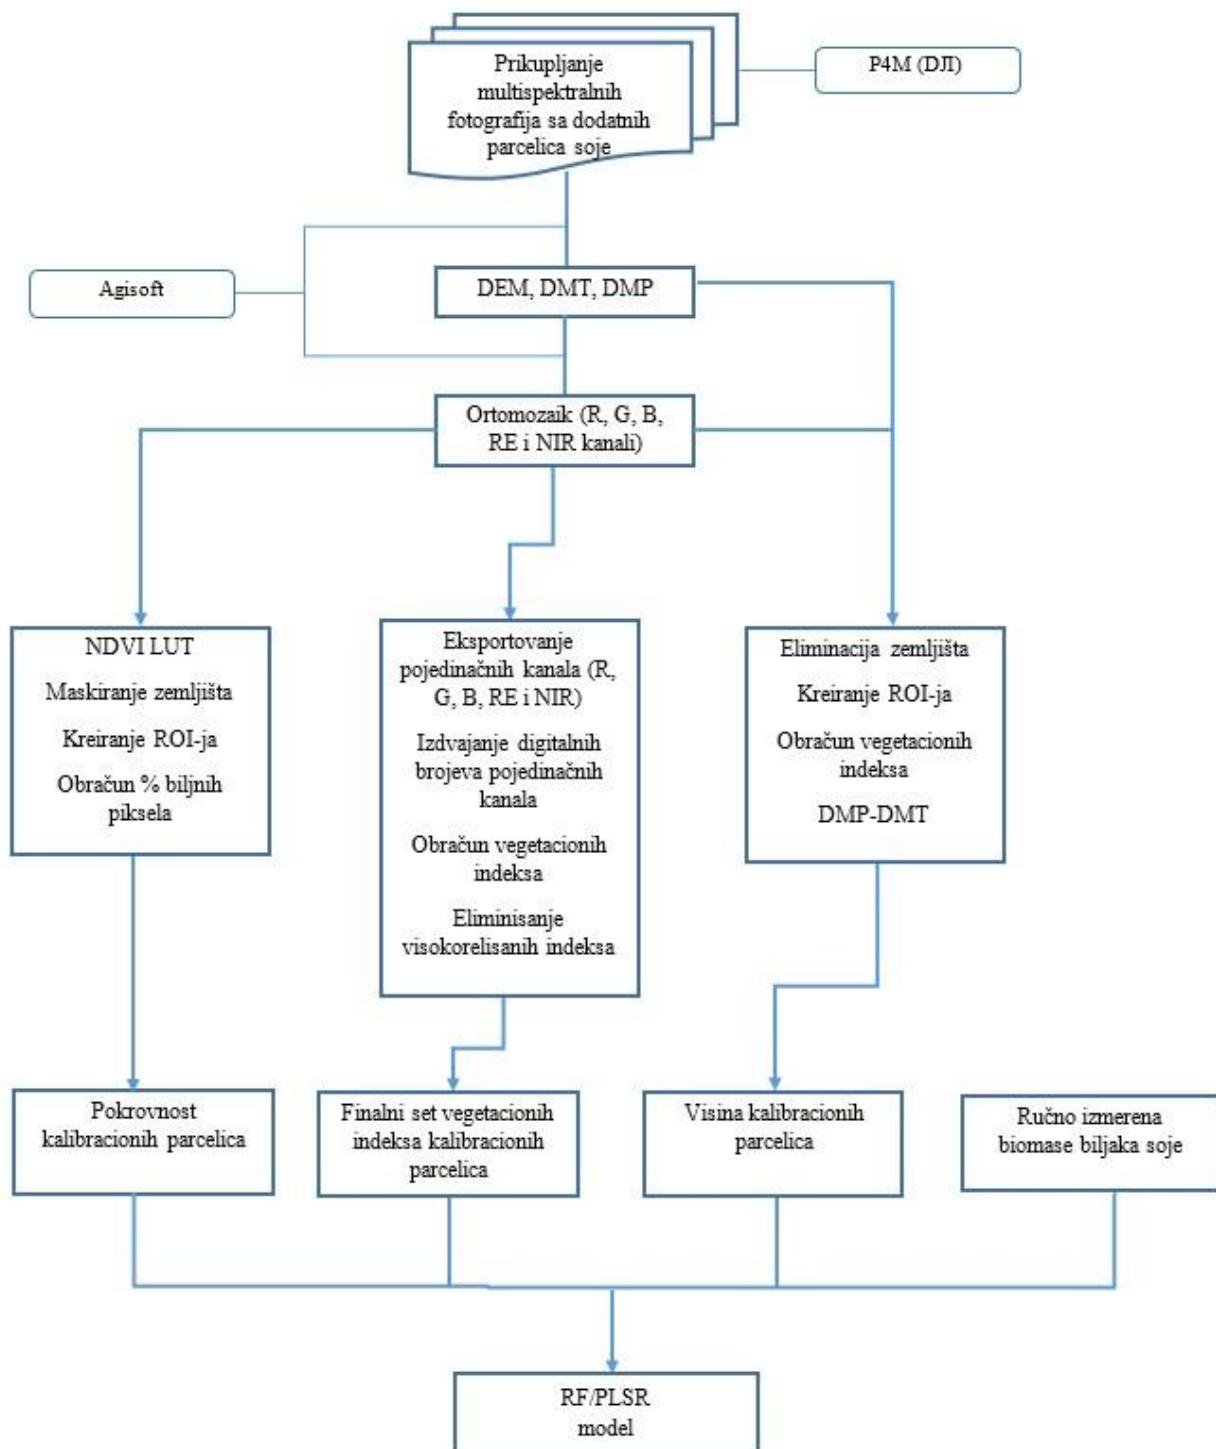


Slika 12. Šematski prikaz kreiranja modela za predikciju a) pokrovnosti i b) visine biljaka soje

### 5.2.5. Kreiranje modela za predikciju biomase soje

Model za predikciju biomase soje zasnovan je na vrednostima pokošene biomase, odgovarajućim prediktorma i algoritmima mašinskog učenja. Kao prediktori upotrebljeni su podaci o pokrovnosti, visini biljaka i vegetacionim indeksima koji su obračunati sa fotografija prikupljenih u devet vremenskih tačaka pri čemu je u svakoj analizirano po 10 parcela soje. Posle pojedinačnih snimanja, nadzemna masa kalibracionih parcela je pokošena i nakon toga izmerena. U svim vremenskim tačkama pokrovnost i visina su određeni pomoću prethodno kreiranih modela za predikciju ovih osobina. Obradom pojedinačnih kanala multispektralne fotografije u FIJI softveru, eksportovani su digitalni brojevi R, G, B, RE i NIR kanala svake kalibracione parcele. Na osnovu podataka o refleksiji izračunat je 31 vegetacioni indeks (PRILOG 2; indeksi označeni sa °). Veza između upotrebljenih vegetacionih indeksa prikazana je u vidu koeficijenata korelacije na korelacionom matriksu kreiranom u R softveru pomoću *ggcorrmat* funkcije iz *ggstatsplot* paketa (Schloerke i sar., 2018). Za filtriranje visokokorelisanih indeksa korišćen je *caret* paket i u okviru njega *findCorrelation* funkcija sa graničnom vrednosti korelacionog koeficijenta od ±0,8. Ova funkcija poredi vrednosti prosečne absolutne korelacije (eng. *mean absolute correlation*, MAC) između dva indeksa i odstranjuje indeks sa najvećim MAC-om.

Prilikom kreiranja modela upotrebljeni su algoritmi mašinskog učenja RF i PLSR. Kod RF modela, korišćena je *train* funkcija iz *Caret* paketa pri čemu su optimalni parametri *ntree* = 500 i *mtry* = 3 odabrani na osnovu najmanje RMSE vrednosti. Pomoću LGOCV metode unakrsne validacije, podaci 70% nasumično odabranih eksperimentalnih parcela iz obe godine korišćene su kao trening set a ostalih 30% kao test set. Podela podataka obavljena je u 10 ponavljanja pri čemu su svaki put dobijeni novi trening/test setovi. Kao krajnji rezultat predikcije uzeta je prosečna vrednost svih ponavljanja. Procena biomase soje na osnovu PLSR algoritma takođe je obavljena pomoću *train* funkcije uz primenu identične LGOCV procedure. Kod ovog modela, optimalan broj latentnih varijabli odabran je na osnovu najniže RMSE vrednosti dobijene pri predikciji zavisne varijable (biomasa soje). Evaluacija oba modela obavljena je na osnovu  $R^2$ , MAE i RMSE pokazatelja koji su dobijeni poređenjem prediktovanih i pokošenih vrednosti biomase. Značaj prediktora koji su korišćeni za potrebe kreiranja bolje ocenjenog modela, prikazan je pomoću vrednosti IncNodePurity dobijenih pomoću predloženog algoritma mašinskog učenja. Bolje ocenjeni model upotrebljen je za izračunavanje biomase na svim parcelama u okviru RK, KK, RS i KS ogleda pri oko 230, 274, 390, 642, 706, 917, 1001 i 1130 GDD. Na osnovu prikupljenih podataka izdvojeni su genotipovi soje sa najvećom ostvarenom biomasom. Šema kreiranja modela za predikciju biomase prikazana je na Slici 13.

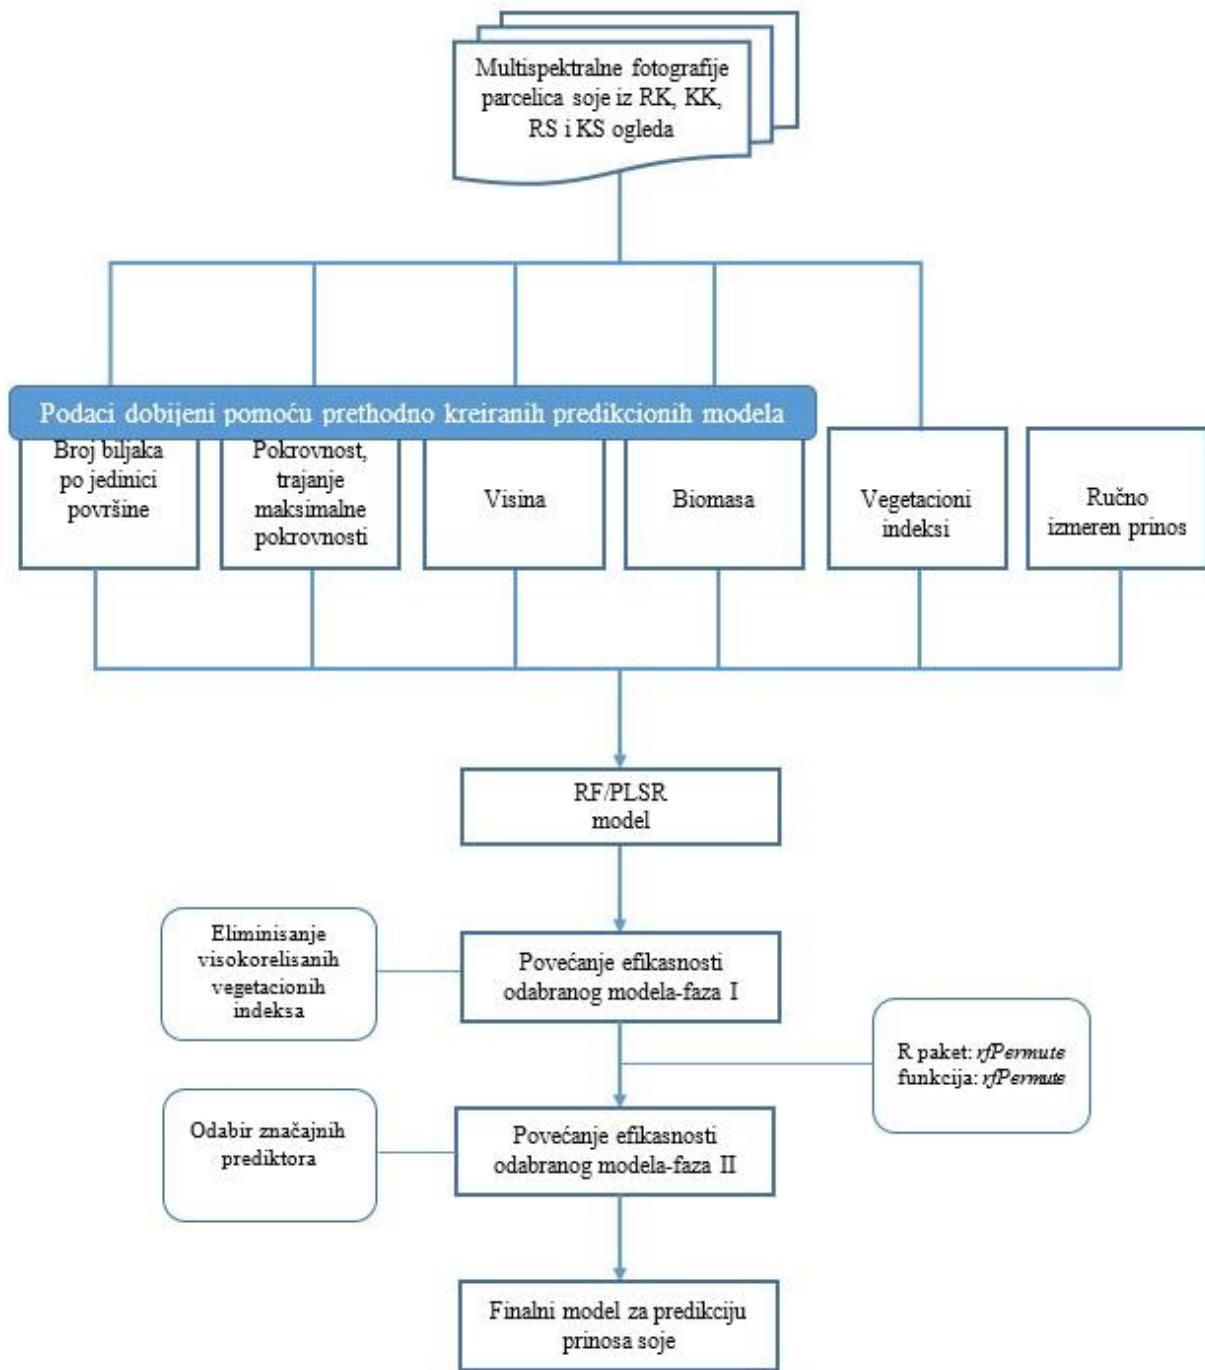


**Slika 13.** Šematski prikaz kreiranja modela za predikciju biomase soje

### **5.2.6. Kreiranje modela za predikciju prinosa soje**

Tokom druge faze istraživanja kreirani su i predikcioni modeli za potrebe ranog predviđanja prinosa genotipova soje koji su gajeni u okviru RK, KK, RS i KS ogleda na 1120 eksperimentalnih parcela (po 560 u svakoj godini). U 2020. i 2021. godini na sedam eksperimentalnih parcela je neposredno pre žetve došlo do propadanja biljaka usled abiotičkih i biotičkih faktora pa su modeli za predikciju prinosa kreirani na osnovu podataka koji su prikupljeni na preostalih 1113. Modeli su bazirani na RF i PLSR algoritmima mašinskog učenja i podacima o broju biljaka po jedinici površine, pokrovnosti, dužini trajanja maksimalne pokrovnosti, visini i biomasi dobijenim primenom prethodno razvijenih modela za visokopropusnu fenotipizaciju. Takođe, za predviđanje prinosa analiziranih genotipova korišćena su i 33 vegetaciona indeksa (PRILOG 2; indeksi označeni sa □). Početni set varijabli korišćen u RF i PLSR modelima činilo je 426 prediktora (broj biljaka po jedinici površine; pokrovnost i 33 vegetaciona indeksa koji su određeni u 12 vremenskih tačaka; dužina trajanja maksimalne pokrovnosti; visine i biomase iz 8 vremenskih tačaka).

Inicijalna predikcija prinosa pomoću RF i PLSR modela obavljena je u R softveru (*train* funkcija iz *Caret* paketa) uz eliminaciju visokokorelisanih indeksa na osnovu MAC vrednosti i kreiranja trening/test seta podataka u odnosu 70/30 pomoću LGOCV metode unakrsne validacije. Podela podataka obavljena je 10 puta a za finalni rezultat predikcije uzeta je prosečna vrednost svih ponavljanja. Evaluacija modela obavljena je poređenjem prediktovanih vrednosti prinosa sa prinosom dobijenim nakon žetve preračunatim na 14% vlage. Precizniji model odabran je za dalji rad. Kod RF algoritma pored *caret* paketa korišćen je i *rfPermute* (Archer, 2022) sa istoimenom funkcijom, koja pored predikcije prinosa omogućava dobijanje informacija o uticaju korišćenih varijabli (prediktora). Značajnost svakog prediktora obračunata je na nivou od  $p < 0,01$ . Finalni set prediktora iskorišćen je za bližu analizu prinosa u odnosu na promene vrednosti odabranih varijabli. U tu svrhu korišćeni su PDP (eng. *partial dependence plot*) i PDP+ICE (eng. *individual conditional expectation*) grafici koji se koriste za prikazivanje efekta varijable na krajnji rezultat predikcije osobine od interesa (Friedman, 2001). Prvi, PDP plot prikazuje generalni trend osobine koja se predviđa u zavisnosti od promene vrednosti prediktora. U ovom slučaju, glavna ideja upotrebe PDP-a bila je da se proveri da li postoje određene vrednosti prediktora koje ukazuju na veći prinos analiziranih genotipova soje. Za analizu dinamike promene prediktovane osobine na nivou genotipova je iskorišćen ICE grafik koji predstavlja pandan PDP-u na pojedinačnom nivou (Goldstein i sar., 2015). Kreiranje oba grafika obavljeno je u R softveru pomoću *iml* paketa (Molnar i sar., 2018). Šema modela za predikciju prinosa soje prikazana je na Slici 14.



Slika 14. Šematski prikaz kreiranja modela za predikciju prinosa soje

### **5.3. Prikupljanje podataka o morfološkim, proizvodnim i tehnološkim osobinama soje klasičnom fenotipizacijom**

U okviru RS, KS, RK i KK ogleda su praćena sledeća morfološka svojstva:

- visina prve mahune (cm)
- broj zrna po biljci
- broj grana
- masa zrna po biljci (g)
- masa hiljadu zrna (g)

Morfološke analize su obavljene na po pet biljaka koje su uzimane u punoj zrelosti, neposredno pre žetve sa svake parcele. Žetva parcela obavljena je u fazi pune zrelosti (R8) pomoću kombajna. Nakon žetve je izmeren prinos i preračunat na 14% vlage. U laboratorijskim uslovima analiziran je hemijski sastav zrna, u pogledu sadržaja proteina i ulja. Ocena tehnološkog kvaliteta ispitivanih genotipova soje obavljena je pomoću Antaris II FT-NIR spektrofotometra (Termo Electron Co., USA) čiji se rad zasniva na blisko-infracrvenoj spektroskopiji sa Furijeovom transformacijom (eng. *near-infrared reflectance spectroscopy*, NIRS).

Obrada morfoloških podataka, tehnološkog kvaliteta, komponenti prinosa i prinosa prikupljenih u ogledima postavljenim tokom druge faze istraživanja obavljena je u statističkom softveru R. Na osnovu p-rep dizajna po kom su RS, KS, RK i KK ogledi bili postavljeni, prikupljeni podaci upotrebljeni su za izračunavanje BLUP-ova (eng. *best linear unbiased predictor*) koji su dalje korišćeni za analizu ispitivanih genotipova soje. U tu svrhu korišćen je mešoviti linearni model (Jiang i Nguyen, 2007) i SpATS (*spatial analysis offield trials with splines*) paket (Rodríguez-Álvarez i sar., 2018), koji predstavlja R paket za prostornu analizu poljskih ogleda. Mešoviti linearni model zasniva se na postojanju fiksnih i slučajnih faktora, pri čemu su kao fiksni faktori korišćeni blokovi u okviru ogleda a kao slučajni faktori genotipovi. Na osnovu kreiranog modela izračunate su BLUP vrednosti za sve genotipove prema formuli:

$$y = X\beta + Z\mu + e$$

pri čemu je:  $y$  - osobina čija se vrednost predviđa

$X$  - matrica dizajna

$\beta$  - vektor fiksnog efekta

$Z$  - matrica slučajnih efekata

$\mu$  - vektor slučajnih efekata

$e$  - vektor slučajnih grešaka

Značajnost razlika srednjih vrednosti odabranih morfoloških, proizvodnih i tehnoloških osobina između grupa zrenja (rane i kasne sorte) i uslova gajenja (suša i kontrola) utvrđena je pomoću t-testa. Podaci o navedenim svojstvima iskorišćeni su za izdvajanje najboljih genotipova soje koji su analizirani tokom druge faze istraživanja. Dodatno, vrednosti osobina koje su dobijene klasičnom fenotipizacijom upoređene su sa podacima dobijenim pomoću kreiranih modela za visokopropusnu fenotipizaciju. Poređenje je obavljeno na osnovu vrednosti Pirsonovog koeficijenta korelacije i koreACIONOG matriksa koji je kreiran u okviru R softvera pomoću *ggcorr* funkcije i *GGally* paketa.

## 6. REZULTATI

### 6.1. Predikcioni model za procenu broja biljaka soje po jedinici površine

Analizom RGB fotografija 66 kalibracionih parcela u 2018. godini dobijene su vrednosti osam vegetacionih indeksa koje su omogućile razvoj modela za predikciju broja biljaka soje po jedinici površine. Pri kreiranju modela vegetacioni indeksi su iskorišćeni kao prediktori u RF algoritmu mašinskog učenja čije performanse su date u Tabeli 3. Dobijeni rezultati su pokazali visoku korelaciju i nisku MAE i RMSE vrednost između izbrojanog i prediktovanog broja biljaka/m<sup>2</sup>.

**Tabela 3.** Ocena performansi modela za predikciju broja biljaka soje po jedinici površine kalibriranog u 2018. godini

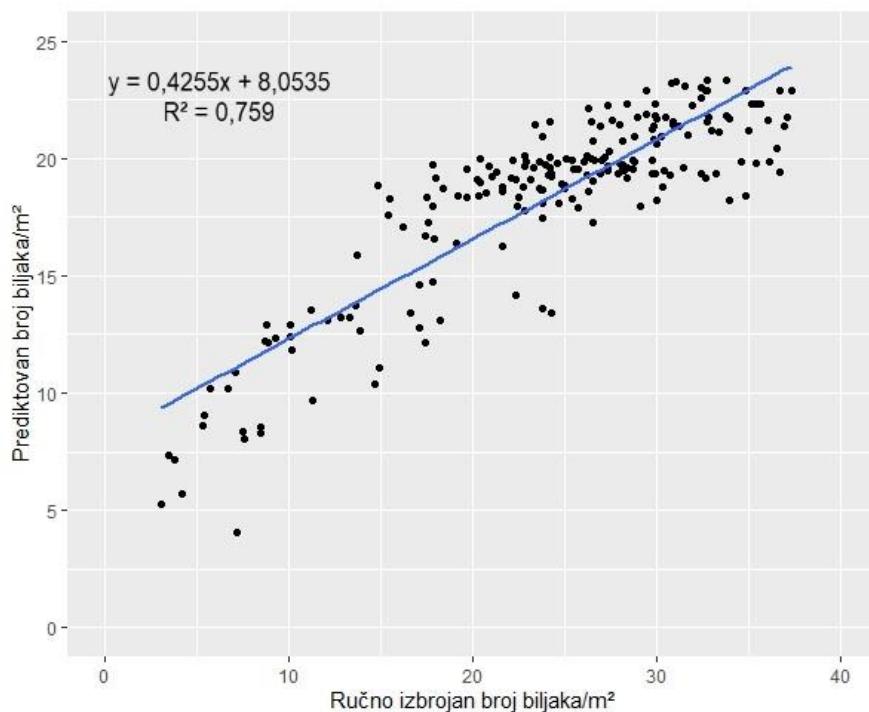
	r	R <sup>2</sup>	MAE	RMSE
<b>Kalibracija modela u 2018</b>	0,90	0,80	3,07	3,91

Da bi model bio prihvaćen kao novi alat za visokopropusnu fenotipizaciju, neophodno je da pokaže odgovarajuću preciznost prilikom upotrebe u različitim uslovima. Zbog toga je u 2019. godini obavljena evaluacija modela na nezavisnom setu od 200 genotipova soje a dobijeni rezultati prikazani su u Tabeli 4.

**Tabela 4.** Ocena performansi modela za predikciju broja biljaka soje po jedinici površine pri validaciji u 2019. godini

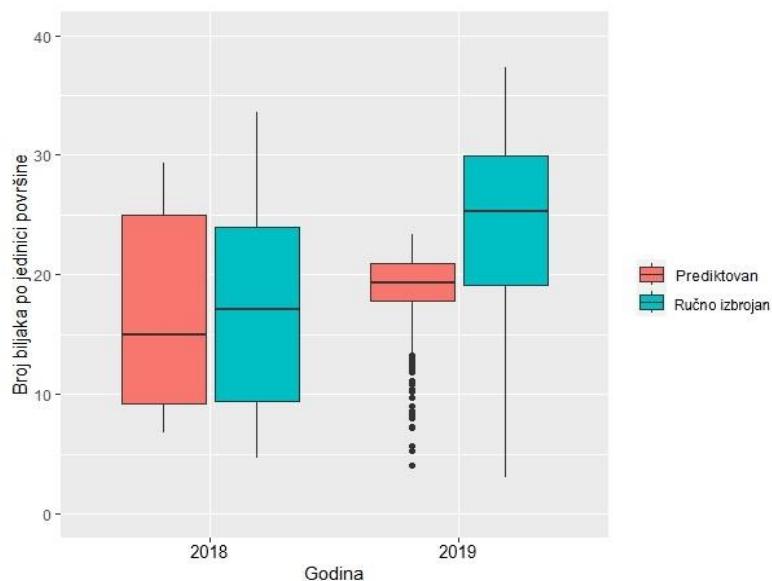
	r	R <sup>2</sup>	MAE	RMSE
<b>Evaluacija modela u 2019</b>	0,87	0,76	6,24	7,47

Dodatno testiranje potvrdilo je robustnost modela koji je zadržao dobre performanse pri testiranju na novoj germplazmi i u novom okruženju što visoke vrednosti r i R<sup>2</sup> dobijene pri poređenju prediktovanog i ručno izbrojanog broja biljaka na evaluacionim parcelama i pokazuju (Grafik 3).



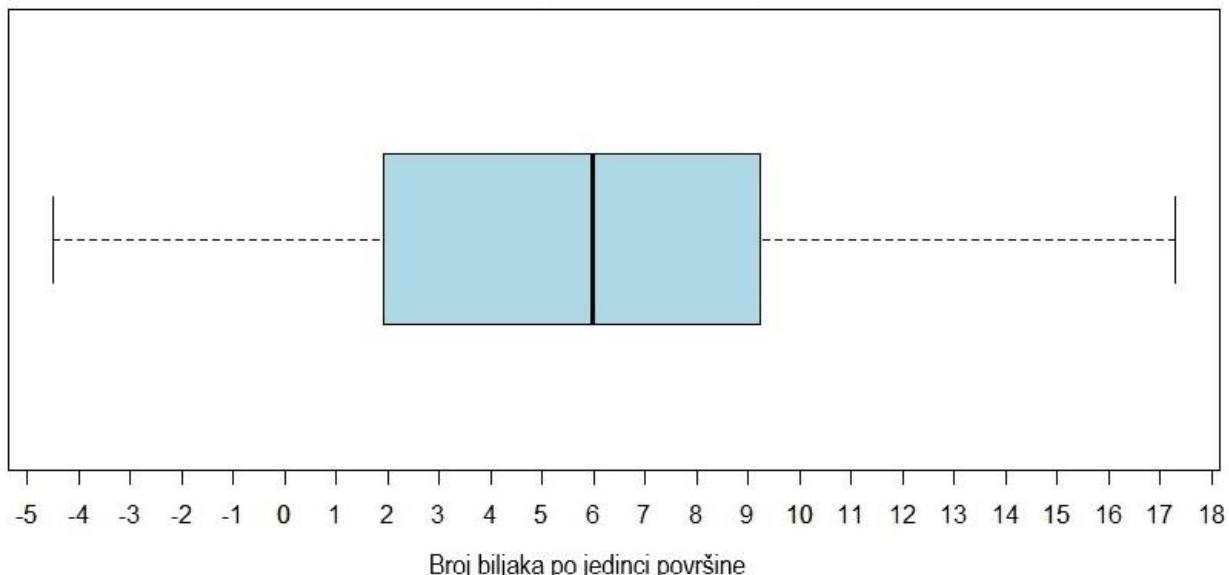
**Grafik 3.** Korelacija između prediktovanog i ručno izbrojanog broja biljaka soje po jedinici površine u 2019. godini

Prilikom evaluacije modela dobijen je nešto niži  $R^2$  dok su vrednosti MAE i RMSE porasli u odnosu na predikciju iz 2018. godine. Ovakve vrednosti statističkih parametara pri oceni efikasnosti modela bile su očekivane i predstavljaju rezultat efekta nekontrolisanih faktora. Nakon obavljene predikcije broja biljaka/m<sup>2</sup> za 200 eksperimentalnih parcela soje u 2019. godini, vrednosti dobijene pomoću modela i ručno izbrojan broj biljaka po jedinici površine iz obe godine prikazan je na Grafik 4.



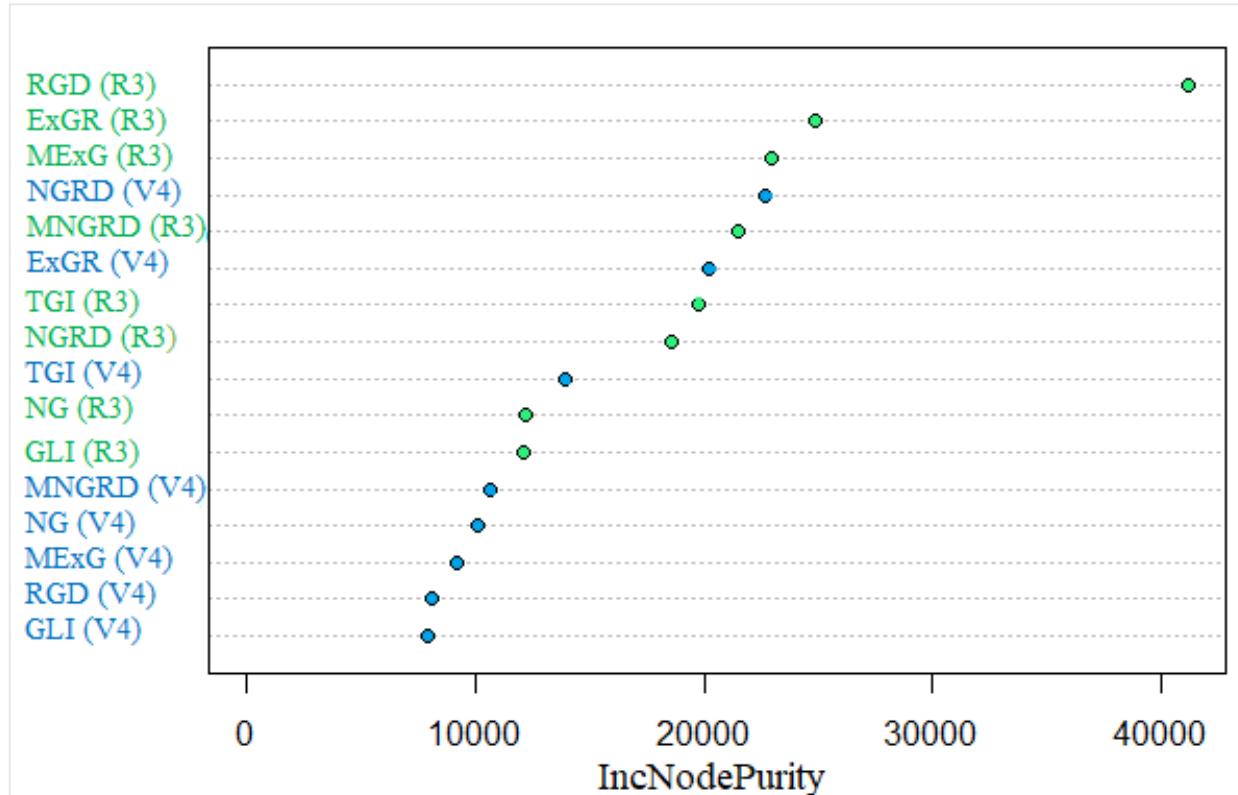
**Grafik 4.** Ručno izbrojane i prediktovane vrednosti broja biljaka soje po jedinci površine u 2018. i 2019. godini

Dobijeni rezultati pokazuju da je veća varijabilnost u broju biljaka po jedinici površine pojedinačnih parcela soje zabeležena pri ručnom brojanju u odnosu na broj biljaka dobijen pomoću kreiranog predikcionog modela. U prilog ovome govori veća vrednost standardne devijacije što je uslovilo i veću standardnu grešku kod podataka dobijenih ručnim brojanjem u odnosu na prediktovane vrednosti na svakoj eksperimentalnoj parceli u 2019. godini. Uži raspon između minimalnog i maksimalnog broja biljaka/m<sup>2</sup> koji je zabeležen kod rezultata dobijenih pomoću modela pre svega je posledica nižih maksimalnih vrednosti koje su dobijene predikcijom. Odstupanje u broju biljaka/m<sup>2</sup> koji je ručno izbrojan na 200 kalibracionih parcela i broja biljaka dobijenog obradom fotografija se kretao od -5 do 18 (Grafik 5).



**Grafik 5.** Odstupanja između ručno izbrojanog i prediktovanog broja biljaka/m<sup>2</sup> za 200 eksperimentalnih parcela soje u 2019 godini. Linije greške prikazuju interval poverenja od 95% a horizontalna linija u okviru *box plot*-a predstavlja medijanu

Na parcelama na kojima je uočeno pozitivno odstupanje između ručno izbrojanog i prediktovanog broja biljaka, model je potcenio stvarnu brojnost. Sa druge strane, negativna razlika ukazuje na to da su prediktovane vrednosti na pojedinim parcelama bile veće nego što one zapravo jesu. Vegetacioni indeksi dobijeni obradom fotografija iz dve razvojne faze soje (V4 i R3) imali su različit uticaj na efikasnost i preciznost modela. Efekat individualnih prediktora prikazan je pomoću vrednosti IncNodePurity (Grafik 6). Dobijeni rezultati ukazuju da su varijable koje su prikupljene u kasnijoj fazi imale veći značaj pri kreiranju modela za predikciju broja biljaka po jedinici površine. Od pet najznačajnijih prediktora, njih četiri (RGD, ExGR, MExG i MNGRD) bilo je iz R3 a samo jedan (NGRD) iz V4 faze. Važno je istaći da su vrednosti ExGR vegetacionog indeksa iz obe faze bile visoko rangirane po pitanju značaja za predikciju broja biljaka soje po jedinici površine.



**Grafik 6.** Značaj vegetacionih indeksa iz V4 i R3 razvojne faze soje u kreiranom modelu za predikciju broja biljaka/m<sup>2</sup>

Kreirani predikcioni model iskorišćen je za procenu broja biljaka po jedinici površine na svim parcelama u okviru druge faze istraživanja u 2020. i 2021. godini. Dobijeni podaci su pokazali da je broj biljaka u ogledima postavljenim na zemljištu sa nepovoljnim vodno vazdušnim svojstvima (RS i KS) bio manji u odnosu na kontrolu (RK i KK) (Tabela 5).

**Tabela 5.** Prosečan broj biljaka/m<sup>2</sup> u ogledima postavljenim tokom 2020. i 2021. godine dobijen pomoću predikcionog modela

Ogled	Godina	
	2020	2021
<b>RK</b>	27,52	33,09
<b>RS</b>	21,49	26,89
<b>KK</b>	24,37	31,22
<b>KS</b>	18,25	23,33

Uporedni pregled rezultata o brojnosti biljaka u okviru svakog ogleda ukazuje da je broj biljaka/m<sup>2</sup> u proseku bio veći 2021. godine. Na parcelama soje gajenim u nepovoljnim uslovima sredine (RS i KS), broj biljaka po jedinici površine u proseku je bio manji za 6,03-7,89 u odnosu na kontrolu. Kada je u pitanju dužina vegetacionog perioda, u obe godine istraživanja zabeležen je veći broj biljaka/m<sup>2</sup> kod ranih u odnosu na kasnije sorte. Ovakav trend zabeležen je i u suši i u kontroli.

## 6.2. Predikcioni model za procenu pokrovnosti soje

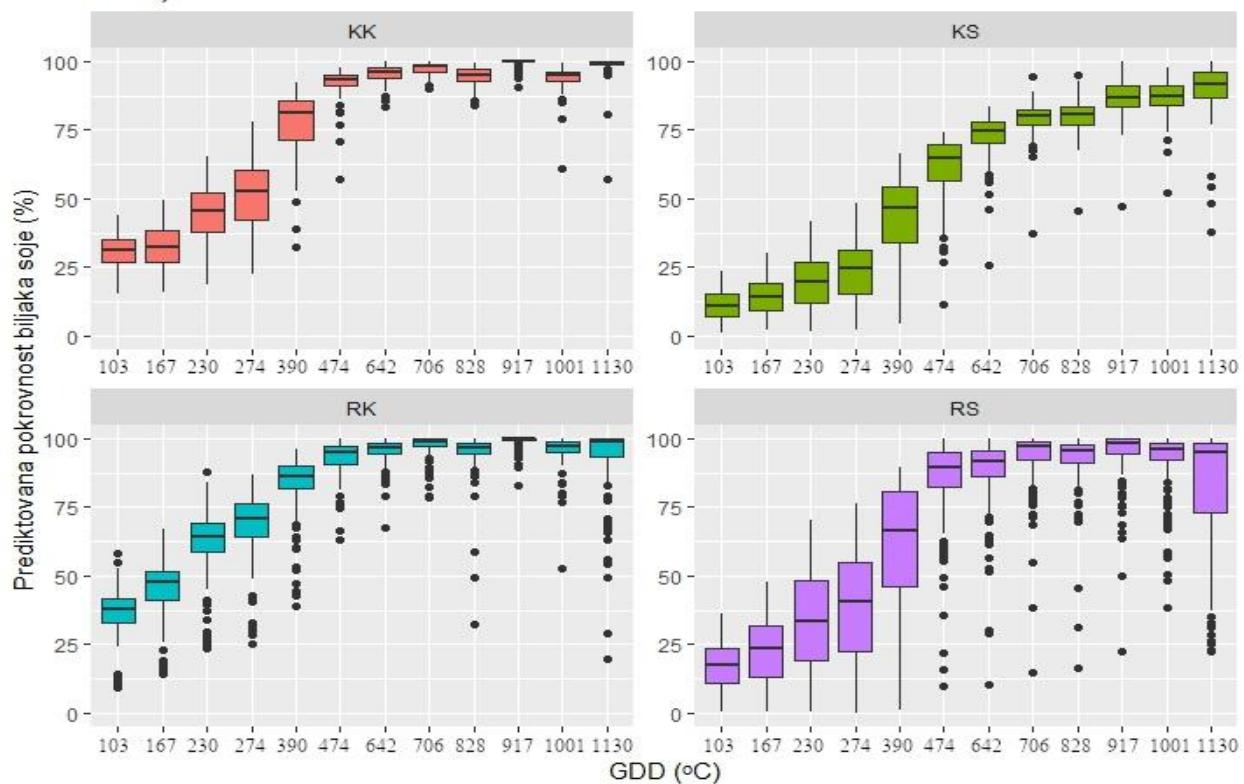
Predikcija pokrovnosti soje bazirana je na obračunu procenta biljnih piksela koji ispunjavaju ROI svake eksperimentalne parcele. Rezultati obrade prikupljenih snimaka su pokazali da je upotreba NDVI osigurala jasno izdvajanje biljne mase u odnosu na piksele zemljišta nakon čega su oni potpuno uklonjeni kreiranjem binarne slike pomoću *Otsu threshold* metode. Na ovaj način predloženi model omogućio je uspešnu procenu pokrovnosti analiziranih genotipova od samog početka sezone kada su biljke pokrivale mali deo zemljišta pa sve do momenta u kom je projektovana lisna površina potpuno prekrila unutrašnjost ROI-ja (Slika 15).



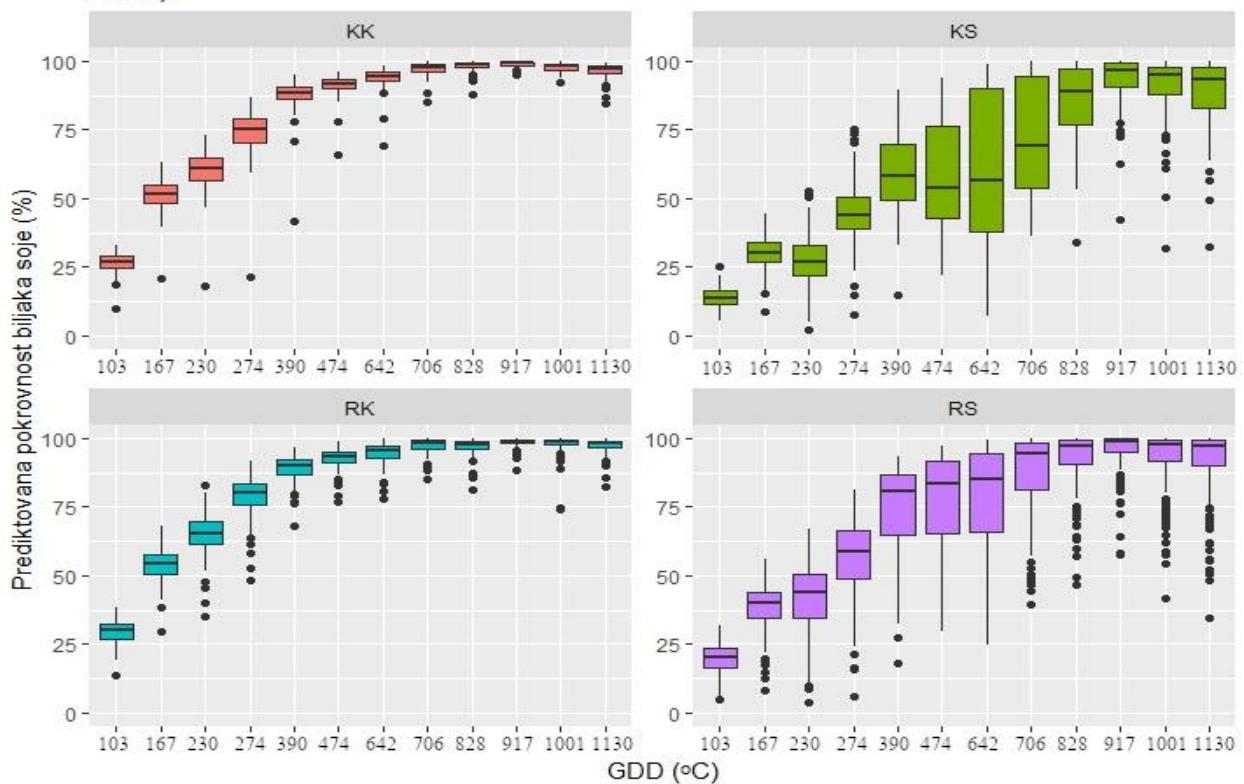
Slika 15. Eksperimentalne parcele soje u tri različite faze razvoja sa primerom ROI-ja (žuti pravougaonici). RGB snimak (gore) i binarna slika biljaka i zemljišta (dole) dobijena pomoću predloženog modela za predikciju pokrovnosti

Iako je tokom sezone dolazilo do promena u boji zemljišta i biljaka koje su bile posledica padavina, različitog mehaničkog sastava zemljišta ili rasta useva, to nije uticalo na sprovođenje protokola za predikciju pokrovnosti soje. Primenom kreiranog modela, procenjena je pokrovnost svih eksperimentalnih parcella na kojima su gajeni genotipovi soje u okviru RK, KK, RS i KS ogleda u 2020. i 2021. godini (Grafik 7).

2020)



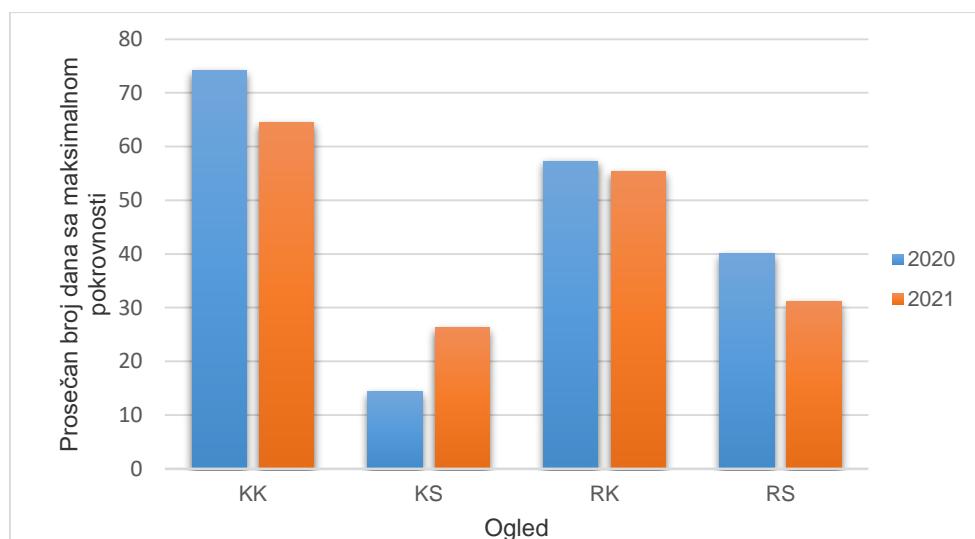
2021)



**Grafik 7.** Prediktovana pokrovnost biljaka soje u 2020. i 2021. godini. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola), GDD (eng. *growing degree days*)

Na osnovu dobijenih rezultata uočeno je da su i rani i kasni genotipovi soje koji su gajeni u sušnim uslovima imali niže vrednosti pokrovnosti u odnosu na kontrolu u obe godine istraživanja. Pored toga, nepovoljni uslovi sredine uticali su i na brzinu zatvaranja redova s obzirom da su genotipovi u okviru RS i KS ogleda kasnije dostizali veće vrednosti pokrovnosti u poređenju sa istim materijalom u RK i KK ogledima. Već pri 390 GDD, prosečna ispunjenost vegetacionog prostora na eksperimentalnim parcelama u kontrolnim ogledima bila je preko 80% u obe godine istraživanja. Sa druge strane u istoj vremenskoj tački prosečna pokrovnost genotipova soje u sušnim uslovima se kretala od 43% do 74% zavisno od ogleda i godine. Takođe, prikupljeni podaci ukazuju da rane sorte imaju brži porast u odnosu na one sa dužim vegetacionim periodom kod kojih kasnije dolazi do zatvaranja redova. Ova pojava dodatno dolazi do izražaja u sušnim uslovima kada se u početnim fazama razvoja uočava jasna razlika u pokrovnosti između genotipova sa kraćim i dužim vegetacionim periodom.

Pored negativnog efekta koje je imalo na brzinu zatvaranja redova, gajenje u sušnim uslovima nepovoljno se odrazilo i na dužinu trajanja maksimalne pokrovnosti i kod ranih i kod kasnih genotipova soje (Grafik 8).

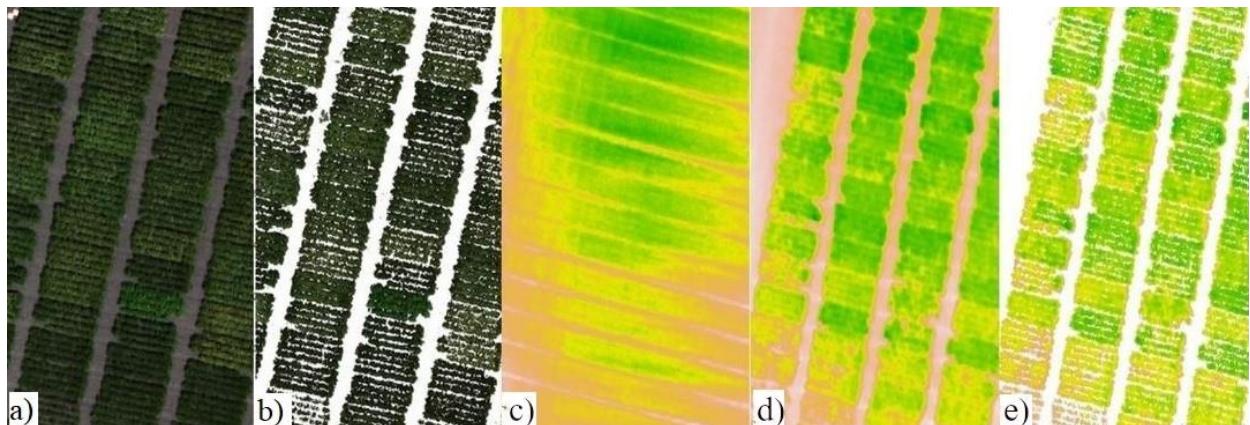


**Grafik 8.** Prosečno trajanje maksimalne pokrovnosti (broj dana sa pokrovnošću iznad 90%) analiziranih genotipova soje po ogledima u 2020. i 2021. godini

U 2020. godini, prosečno trajanje maksimalne pokrovnosti u okviru RS ogleda iznosilo je 40,09 a u RK 57,27 dana dok su te vrednosti naredne godine bile 31,13 odnosno 55,28 dana. Kod sorti iz kasnijih grupa zrenja razlike su još izraženije budući da je u 2020. godini prosečan broj dana sa maksimalnom pokrovnošću u KK ogledu bio 74,16 a u KS svega 14,33 dana odnosno 26,25 dana u 2021. godini. Navedeni rezultati svedoče da su nepovoljni uslovi sredine redukovali vrednost ovog parametra kod ranih genotipova za 30-44% a kod kasnih čak 59%-80%. Na osnovu dvogodišnjih podataka o prediktovanoj pokrovnosti izdvojeno je po pet genotipova u kontroli i pet u suši koji najbrže dostižu 50% pokrovnosti. U kontroli su to bili Soja 809, Soja 832, Record North, Mandin Kajon i Gatersleben 45 a u suši Danica HR, Josefine, Pando, Selecta 201 i Xonia. Pored toga je obavljen odabir genotipova sa najdužim trajanjem maksimalne pokrovnosti pri čemu su se u kontroli istakle sorte Vera, NS-L-510016, Venera, Srebina i Dumbar dok su u suši to bile Kato, NS Kraljica, Buenos, Dumbar i Antonia.

### 6.3. Predikcioni model za procenu visine biljaka soje

Analizom fotografija kalibracionih parcela soje prikupljenih pomoću bespilotne letelice i multispektralne kamere, omogućeno je kreiranje modela za predikciju visine. Softverskom obradom snimaka najpre je obavljeno maskiranje zemljišta pomoću SCI indeksa nakon čega je dobijena maska iskorišćena za izdvajanje visine kalibracionih parcela na osnovu razlike u vrednostima elevacionih modela, DMT-a i DMP-a (Slika 16).



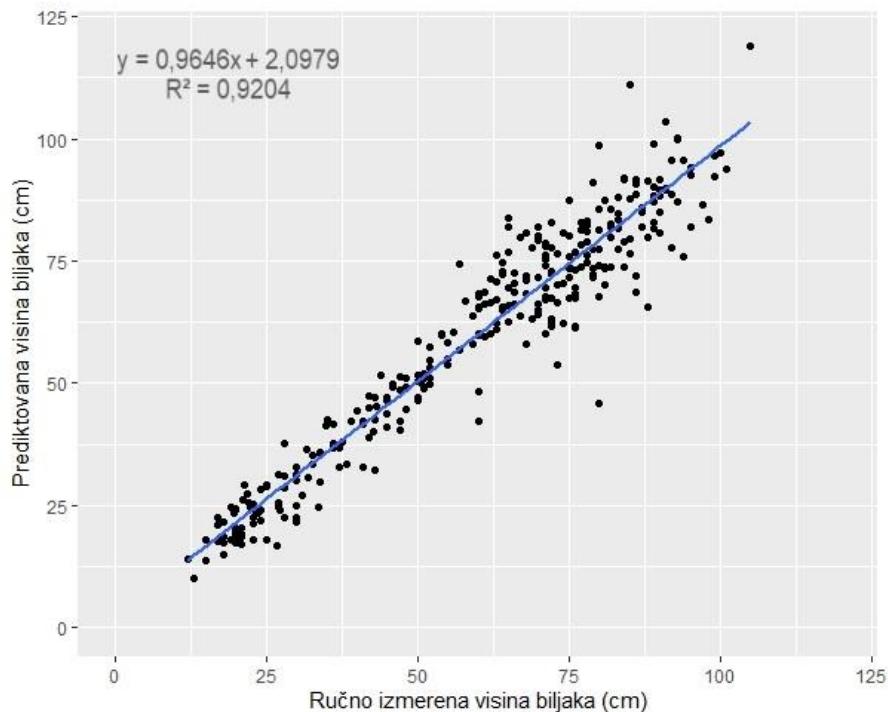
**Slika 16.** Protokol na kom je zasnovan model za predikciju visine biljaka soje. a) RGB ortomozaik, b) maskiranje zemljišta, c) digitalni model terena (DMT), d) digitalni model površine (DMP), e) visina eksperimentalnih parcela dobijena na osnovu razlike DMP-a i DMT-a

Vrednosti dobijene pomoću modela za predikciju visine bile su visoko korelisane sa visinama koje su ručno izmerene na kalibracionim parcelama o čemu svedoče statistički pokazatelji prikazani u Tabeli 6.

**Tabela 6.** Ocena preciznosti kreiranog modela za predikciju visine biljaka soje na osnovu poređenja sa ručno izmerenim vrednostima

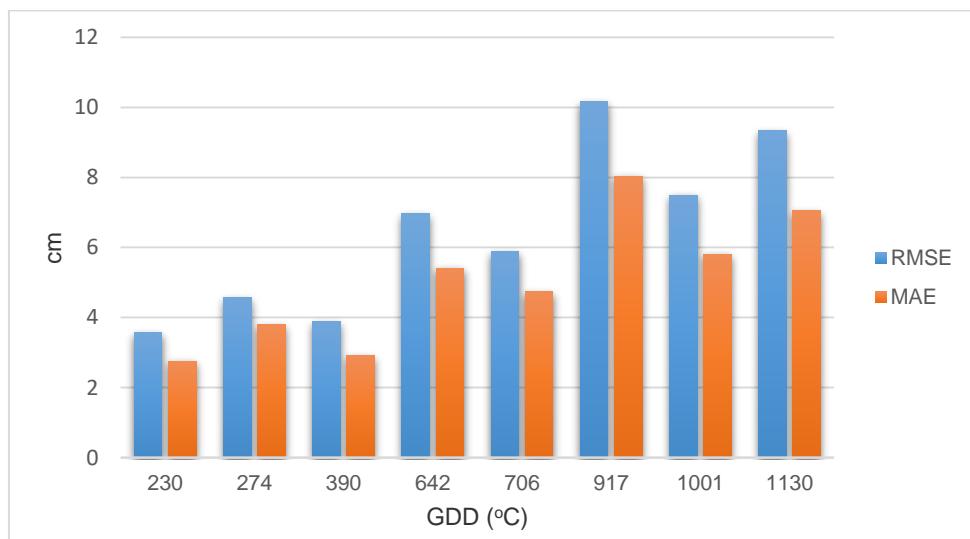
r	R <sup>2</sup>	MAE (cm)	RMSE (cm)
0,96	0,92	3,93	6,88

Ručna merenja koja su obavljena na parcelama korišćenim za kalibriranje modela su pokazala da se visina biljaka soje tokom 2020. i 2021. godine kretala u širokom rasponu od 12 do 105 cm. Računajući dve godine, osam vremenskih tačaka i 20 parcela, dobijeno je ukupno 320 pojedinačnih vrednosti visina na osnovu kojih je proverena preciznost modela za predikciju navedenog svojstva. Kreiranjem regresione krive prikazan je odnos između prediktovanih i ručno izmerenih vrednosti visina kalibracionih parcela analiziranih genotipova soje (Grafik 9).



**Grafik 9.** Korelacija između ručno izmerenih i prediktovanih visina biljaka soje

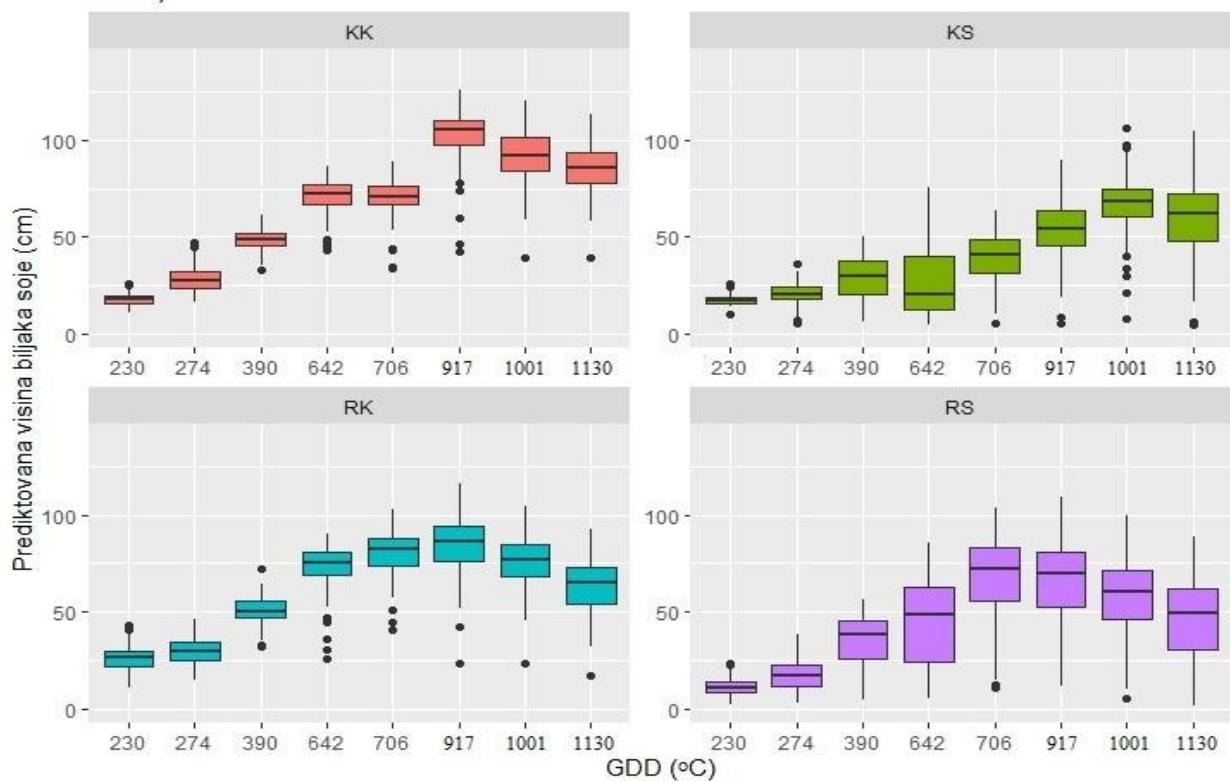
Preciznost kreiranog modela za predikciju visine biljaka soje prikazana pomoću odabranih statističkih parametara na kompletnom setu podataka, dodatno je proverena i u svakoj pojedinačnoj vremenskoj tački. Vrednosti grešaka (RMSE i MAE) koje su dobijene pri poređenju ručno izmerenih i prediktovanih visina date su na Grafiku 10.



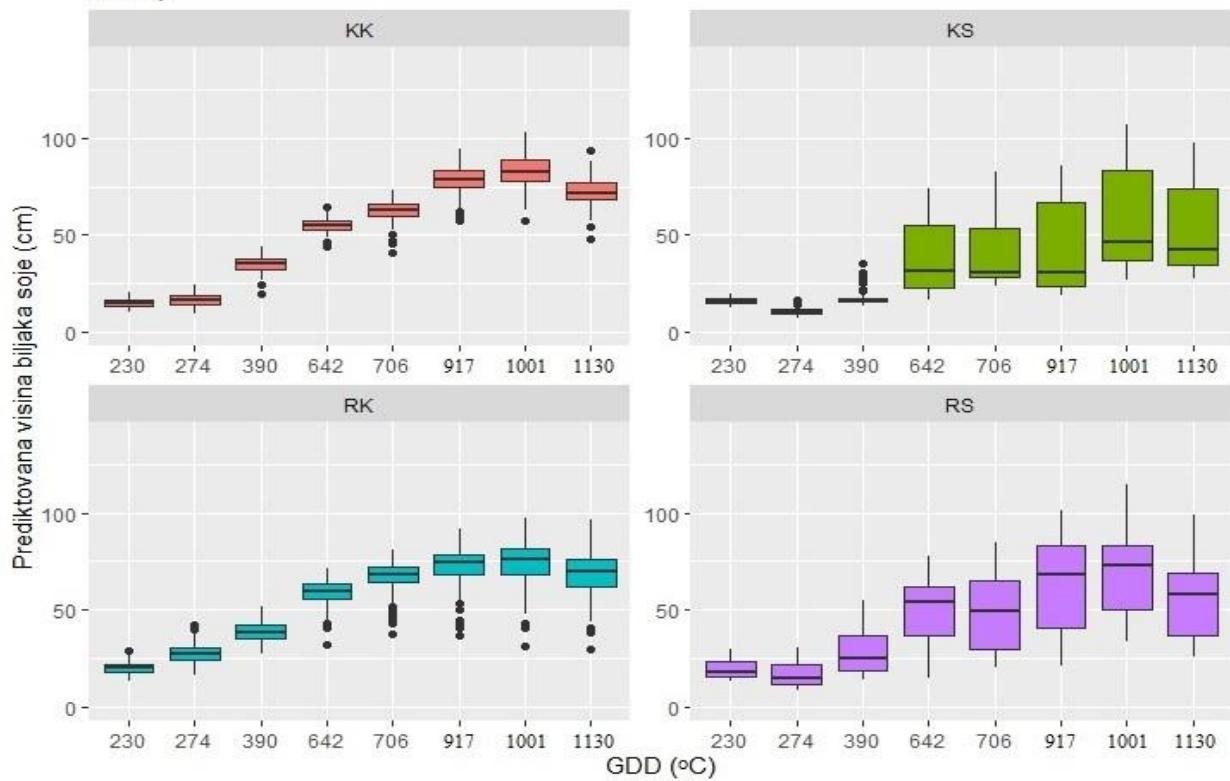
**Grafik 10.** Greška između ručno izmerene i prediktovane visine biljaka soje u različitim fazama razvoja

Prosečna vrednost RMSE pri predikciji visine na kalibracionim parcelama se kretala između 3,56 cm i 10,17 cm dok je MAE iznosila od 2,74 cm do 8,04 cm. Ovako mala odstupanja između ručno izmerenih i prediktovanih podataka govore da je model pokazao visoku preciznost tokom čitavog vegetacionog perioda soje. U 2020. i 2021. godini, kreirani model iskorišćen je za predikciju visine svih genotipova iz RK, KK, RS i KS ogleda u osam vremenskih tačaka (Grafik 11).

2020)



2021)



**Grafik 11.** Predikovana visina biljaka soje u 2020. i 2021. godini. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola), GDD (eng. *growing degree days*)

U 2020. godini maksimalna prosečna visina biljaka soje u KK i RK ogledima zabeležena je pri 917 GDD i iznosila je 102,28 cm odnosno 83,86 cm. Kasne sorte iz kontrolnih ogleda bile su više u odnosu na rane i u 2021. godini sa tom razlikom što su maksimumi postignuti pri 1001 GDD, sa vrednostima od 82,55 cm i 74,03 cm. Kod ogleda u sušnim uslovima dobijeni rezultati razlikovali su se u odnosu na kontrolu. U 2020. godini maksimalna prosečna visina u KS ogledu iznosila je 67,22 cm i zabeležena je pri 1001 GDD dok su biljke iz RS ogleda u proseku bile najviše (68,13 cm) pri 706 GDD. Naredne godine najveća prosečna visina kod kasnih genotipova u sušnim uslovima nije prelazila 58,3 cm dok su se rane sorte održale na vrednosti od oko 68 cm. U oba slučaja maksimumi su postignuti pri 1001 GDD. Dobijeni rezultati o prediktovanoj visini analizirane germplazme soje govore da su nepovoljni uslovi sredine bili ograničavajući faktor rasta. U obe godine istraživanja u gotovo svakoj vremenskoj tački visina biljaka soje gajene u sušnim uslovima bila je niža u odnosu na kontrolu a razlike su se kretale od 1,15% do čak 60,86%. Jedini izuzetak zabeležen je u 2021. godini pri 230 GDD kada je kod ranih sorti u RS ogledu zabeležena veća prosečna visina od 5,42% u odnosu na iste genotipove posejane u kontrolnim uslovima. Na osnovu podataka o prediktovanoj visini iz 2020. i 2021. godine u kontroli i suši su izdvojeni genotipovi čija je maksimalna visina bila između 100 i 110 cm. Zadate granične vrednosti visine glavnog stabla osiguravaju dobar potencijal za formiranje značajnog broja mahuna dok u isto vreme ne predstavljaju preveliki rizik za poleganje. Ujedno, odabrani opseg u saglasnosti je sa navodima prethodne studije (Perić, 2015) u kojoj se ističe da je optimalni raspon visina komercijalnih sorti soje između 80 i 120 cm. Sorte koje su odabране iz kontrolnih uslova bile su Krajina, Eugen, NS Virtus, NS Kaća, Steara, NS-L-404266, Trijumf, Rubin, Bećejka, Belka, NS Atlas, NS Sirius, ZPL 1, ES Mediator, Regnum, Dumbar, NS Maximus, Vigo, Vojvođanka, NS Milan i NS Vasa a u suši Tena, Vojvođanka, Fabiana F, NS Princeza, Buenos, Neoplanta, ZPL 1, Alisa, ES Inventor, Proteinka, Zita, Daciana, Miruna TD, Spartakus i Steara.

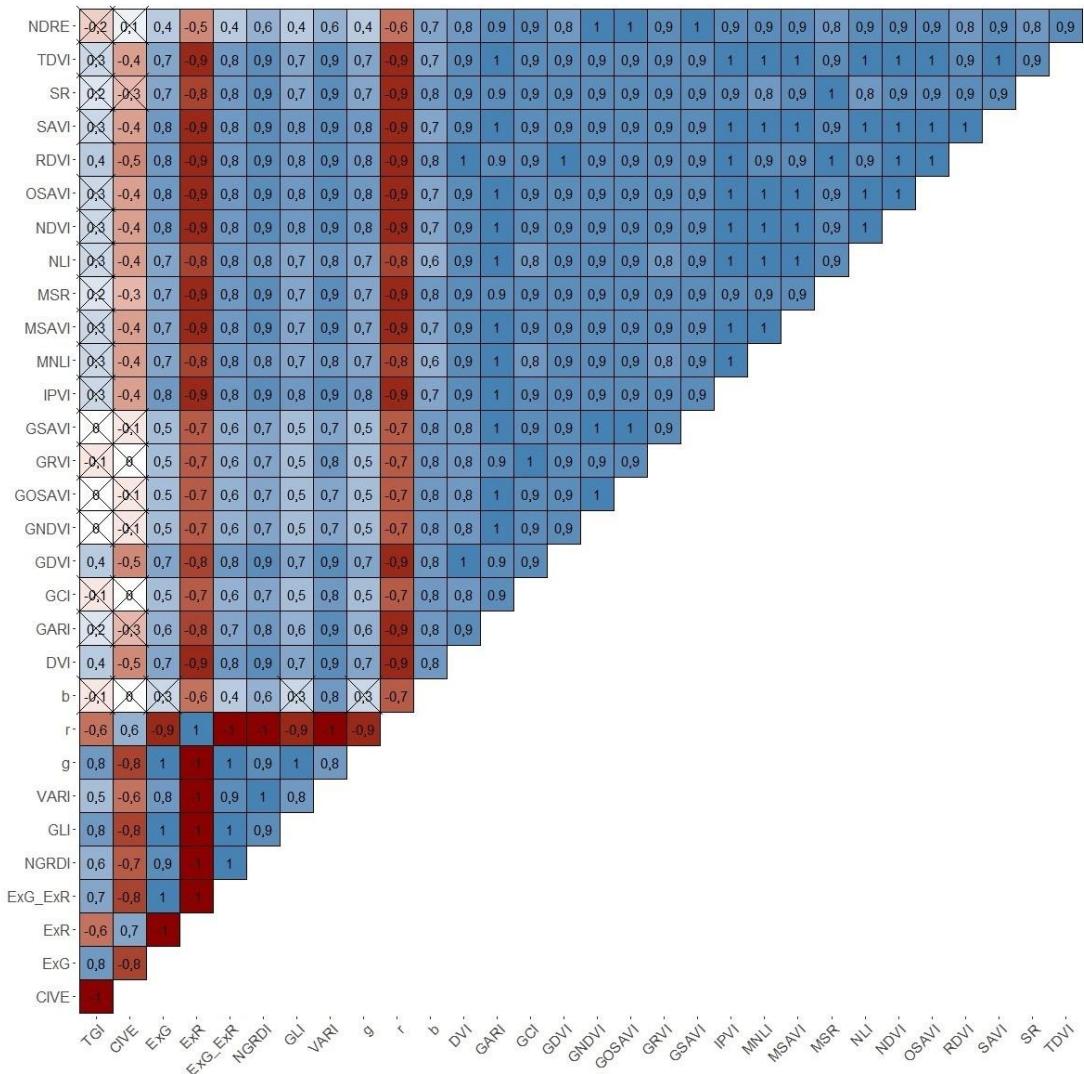
#### **6.4. Predikcioni model za procenu biomase soje**

Tokom druge faze istraživanja, na kalibracionim parcelama soje korišćenim za kreiranje modela za predikciju biomase, sa rastom GDD-a rasle su i vrednosti pokrovnosti, visine i sveže biomase (Tabela 7). Biljke soje bile su više u 2020. godini dok je gotovo maksimalna pokrovnost (100%) postignuta u obe godine. Podaci su pokazali da je nakupljanje biomase u početnim fazama bilo brže u drugoj a u kasnjim fazama u prvoj godini ovog dela istraživanja.

**Tabela 7.** Prosečne vrednosti pokrovnosti, visine i sveže biomase izmerene na kalibracionim parcelama soje u 2020. i 2021. godini

2020				2021			
GDD (°C)	Pokrovnost (%)	Visina biljaka (cm)	Sveža biomasa (kg/m <sup>2</sup> )	GDD (°C)	Pokrovnost (%)	Visina biljaka (cm)	Sveža biomasa (kg/m <sup>2</sup> )
<b>274</b>	45,08	15	0,18	<b>215</b>	53,26	10	0,21
<b>413</b>	74,33	25	0,54	<b>492</b>	84,50	28	0,89
<b>650</b>	82,75	59	1,61	-	-	-	-
<b>745</b>	98,82	96	2,28	<b>747</b>	95,70	53	1,74
<b>1016</b>	87,87	99	3,03	<b>1130</b>	98,63	75	2,75

U cilju povećanja preciznosti i efikasnosti predikcionog modela, analizirana je veza između vegetacionih indeksa koji su odabrani za predikciju biomase soje. Budući da su navedeni indeksi kreirani kombinovanjem vrednosti digitalni brojeva pet spektralnih kanala bilo je očekivano da se javi visoka multikolinearnost. Korelacije kod kojih nije utvrđena statistička značajnost ( $p < 0,05$ ) su precrtane (Slika 17).



**Slika 17.** Korelacioni matriks sa vrednostima Pirsonovog koeficijenta korelacije između vegetacionih indeksa korišćenih za kreiranje modela za predikciju biomase soje. Precrtana polja govore da vrednosti korelacionog koeficijenta nisu statistički značajne ( $p < 0,05$ )

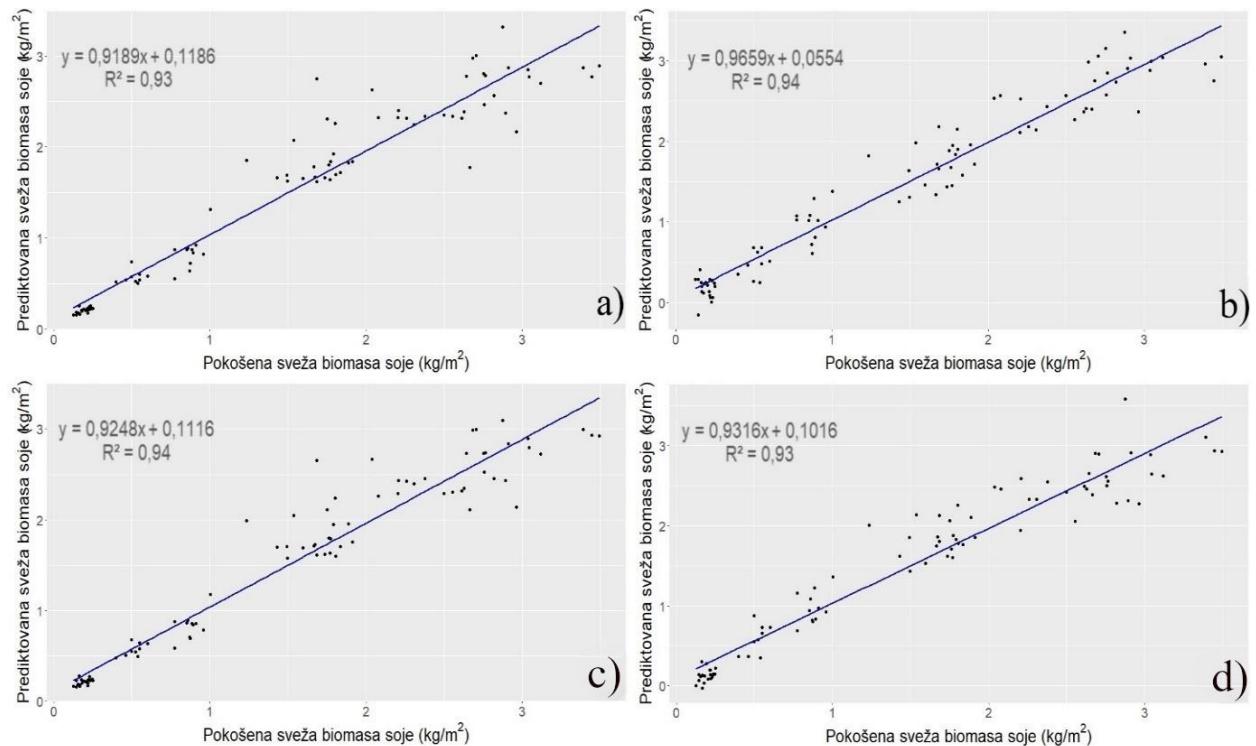
Preko 62% svih korelacija bile su veće od prethodno definisane vrednosti za odbacivanje visokokoreliranih indeksa ( $\pm 0,8$ ). Na osnovu redukcije, ukupan broj varijabli sveden je na samo dva indeksa i to TGI i GCI. Pored izrazito slabe veze između ovih indeksa ( $r = -0,1$ ) oni su imali i najnižu MAC vrednost u poređenju sa ostalim. Između pojedinih indeksa kao što su CIVE i GCI ili TGI i GNDVI nije uočena međusobna povezanost ( $r = 0$ ). Ipak, CIVE i GNDVI su isključeni zbog veće MAC vrednosti u odnosu na TGI i GCI.

Preciznost modela za procenu biomase soje kreiranih pomoću različitih prediktora ocenjena je poređenjem pokošenih i prediktovanih vrednosti sveže biomase soje koje su dobijene na kalibracionim parcelama (Tabela 8).

**Tabela 8.** Ocena preciznosti različitih modela za predikciju biomase biljaka soje. RF (eng. *random forest*), PLSR (eng. *partial least squares regression*), TGI (eng. *triangular greenness index*), GCI (eng. *green chlorophyll index*)

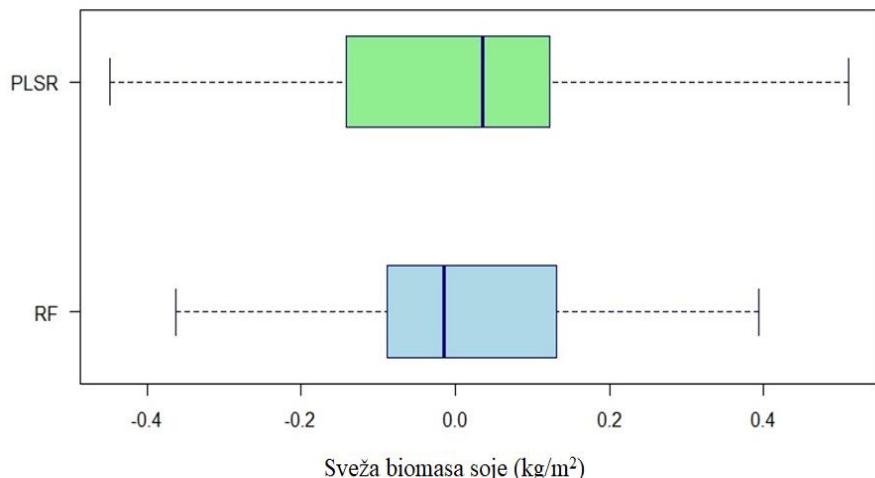
Model	r	R <sup>2</sup>	RMSE (kg/m <sup>2</sup> )	MAE (kg/m <sup>2</sup> )
RF + pokrovnost, visina biljaka, 31 vegetacioni indeks	0,96	0,93	0,28	0,18
RF + pokrovnost, visina biljaka, GCI, TGI	<b>0,97</b>	<b>0,94</b>	<b>0,26</b>	<b>0,17</b>
PLSR + pokrovnost, visina biljaka, 31 vegetacioni indeks	0,97	0,94	0,25	0,18
PLSR + pokrovnost, visina biljaka, GCI, TGI	0,96	0,93	0,27	0,20

Grafički prikaz rezultata dobijenih pomoću modela za predikciju biomase soje dat je na Grafiku 12.



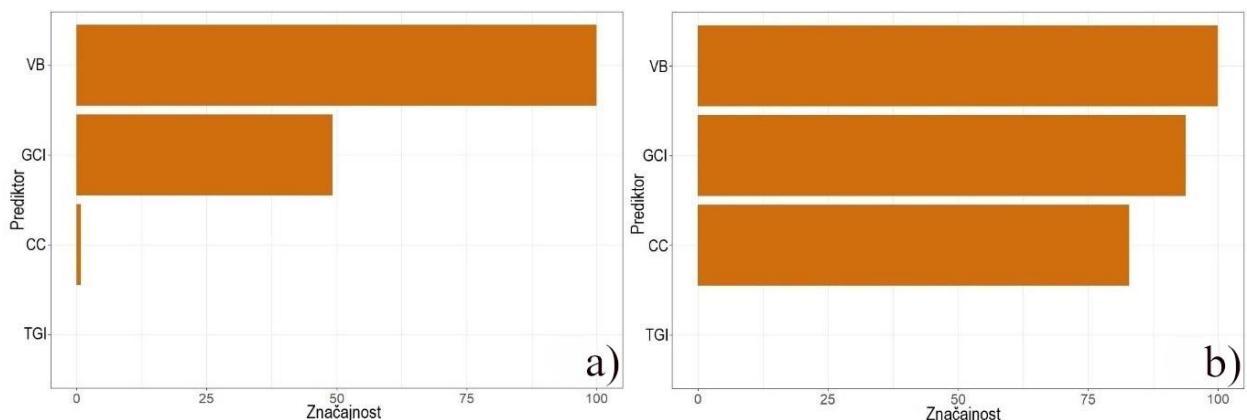
**Grafik 12.** Korelacija između pokošene i prediktovane sveže biomase soje (kg/m<sup>2</sup>). Pokrovnost i visina kombinovana sa 31 vegetacionim indeksom u (a) RF i (b) PLSR; pokrovnost i visina kombinovana sa TGI i GCI u (v) RF i (g) PLSR. RF (eng. *random forest*), PLSR (eng. *partial least squares regression*), TGI (eng. *triangular greenness index*), GCI (eng. *green chlorophyll index*)

Nije uočena značajnija razlika u performansama modela za predikciju sveže biomase soje kombinovanjem visine i pokrovnosti sa kompletnim setom od 31 vegetacionog indeksa i samo sa TGI i GCI indeksom. Zbog toga je dalje poređenje kreiranih modela bazirano isključivo na rezultatima unakrsne validacije dobijenim pri predikciji sveže biomase soje sa redukovanim brojem prediktora. Oba modela (RF i PLSR), pokazala su dobru preciznost o čemu svedoči visok  $R^2$  i niske vrednosti RMSE i MAE. Iako su kod oba modela uočena odstupanja u pozitivnom i negativnom smeru, rezultati dobijeni pomoću RF modela ipak su bili nešto bolji. Niža standardna devijacija (eng. *standard deviation, SD*) između pokošene i prediktovane biomase soje obezbeđena je korišćenjem RF modela ( $SD = 0,25 \text{ kg/m}^2$ ) u odnosu na PLSR ( $SD = 0,27 \text{ kg/m}^2$ ) (Grafik 13).



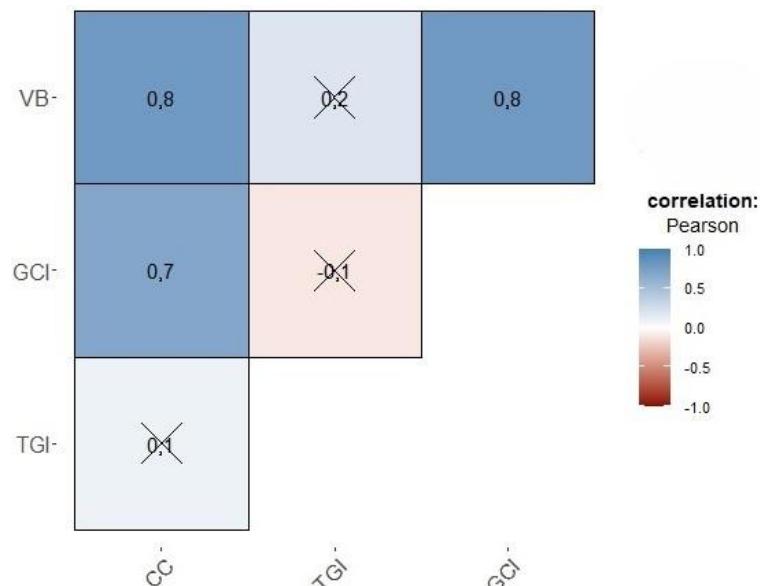
**Grafik 13.** Razlika između pokošene i prediktovane sveže biomase soje ( $\text{kg/m}^2$ ) dobijene pomoću RF (eng. *random forest*) i PLSR (eng. *partial least squares regression*) modela sa redukovanim brojem prediktora. Linije greške prikazuju interval poverenja od 95% a horizontalna linija u okviru *box plot*-a predstavlja medijanu

Iako RF i PLSR imaju različitu matematičku osnovu, za predikciju biomase soje u navedenim algoritmima korišćeni su isti prediktori. Uticaj upotrebljenih varijabli na preciznost predikcije korišćenih modela mašinskog učenja iskazan je u relativnim vrednostima (0 do 100) (Grafik 14).



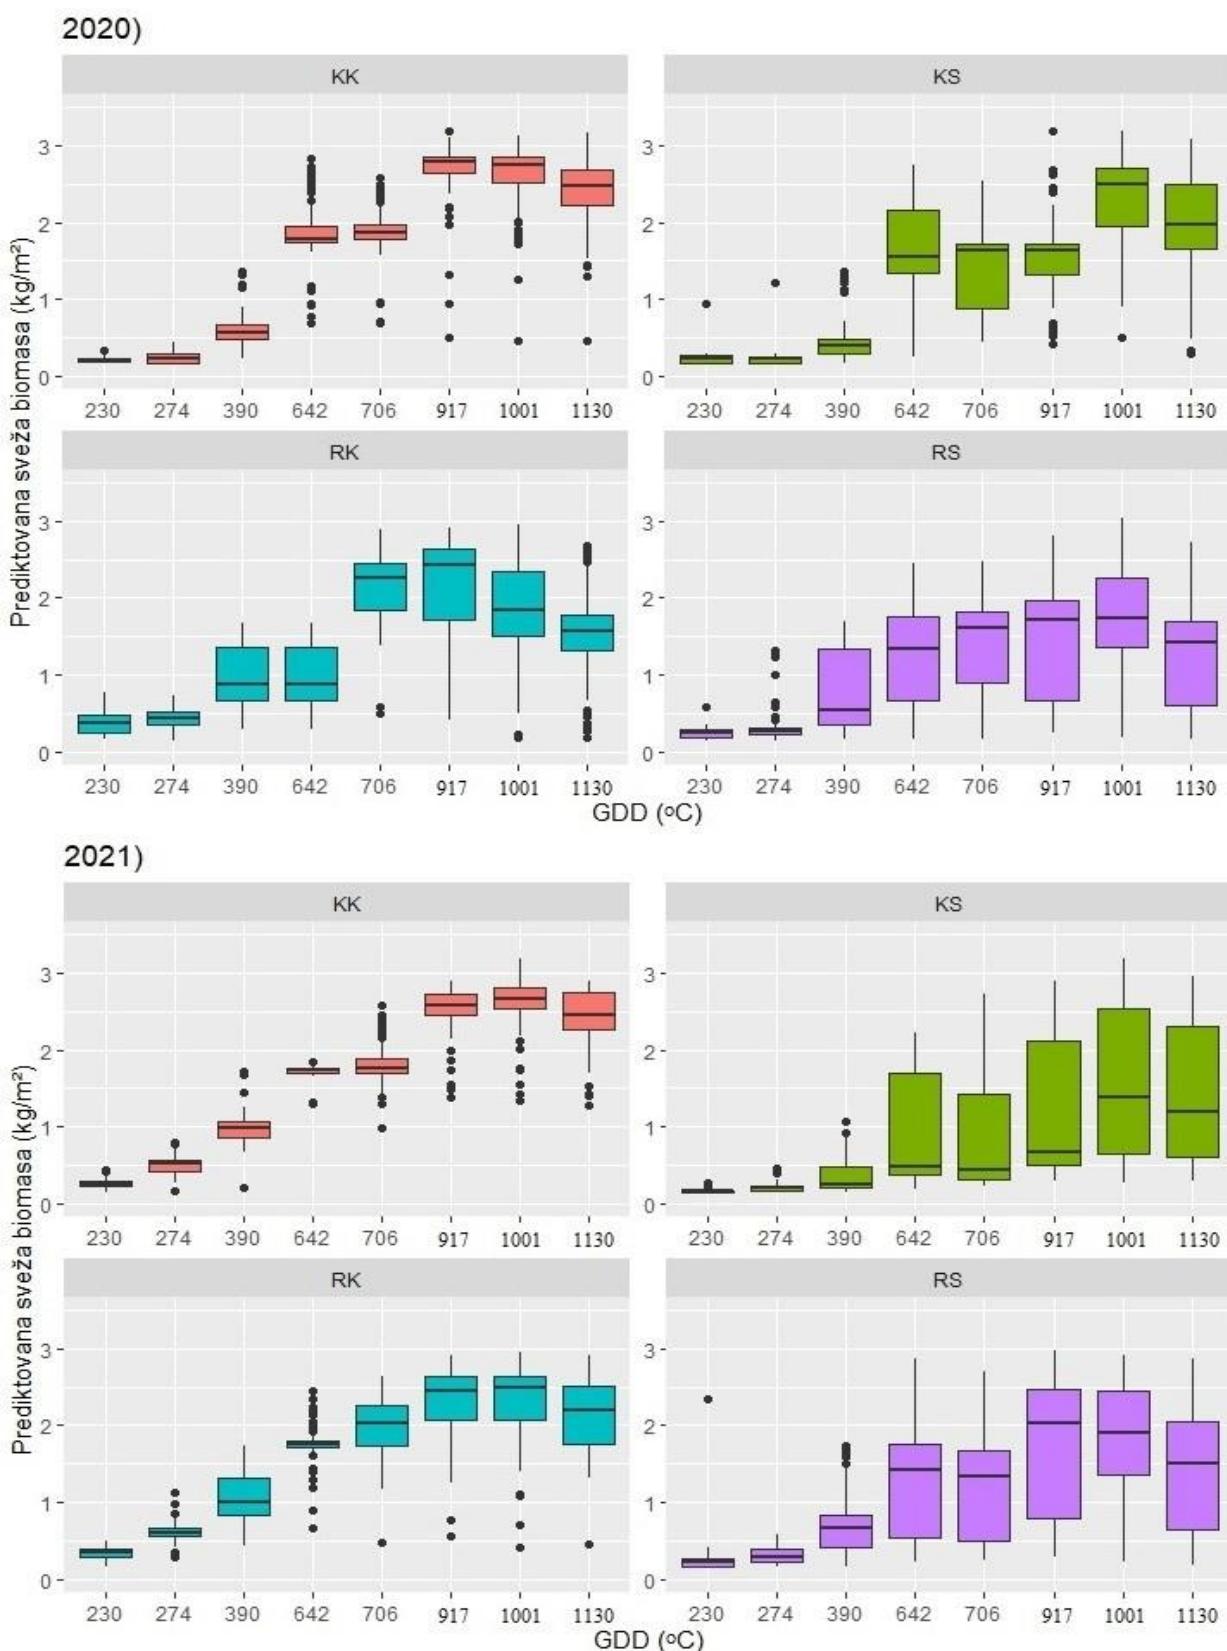
**Grafik 14.** Značajnost prediktora korišćenih u (a) RF i (b) PLSR modelu za predikciju sveže biomase soje. RF (eng. *random forest*), PLSR (eng. *partial least squares regression*), VB (visina biljaka), GCI (eng. *green chlorophyll index*), CC (eng. *canopy cover, pokrovnost*), TGI (eng. *triangular greenness index*)

Kod oba modela rangiranje prediktora po značajnosti bilo je identično. Visina je bila najvažnija zatim GCI, nakon toga pokrovnost i na kraju TGI indeks. Kod PLSR-a visina, GCI i pokrovnost imali su odlučujući uticaj na preciznost predikcije dok je efekat TGI indeksa bio zanemarljiv. Kod RF modela, TGI i pokrovnost nisu imali veći doprinos na konačne performanse. Indeks GCI bio je značajniji za PLSR nego za RF dok je visina kod oba modela bila ključna varijabla u predikciji sveže biomase soje. Odnos između četiri korišćena indeksa prikazan je pomoću korelacionog matriksa koji je kreiran na osnovu izračunatih Pirsonovih korelacionih koeficijenata. Dobijeni rezultati su pokazali da postoji statistički značajna povezanost između visine, pokrovnosti i GCI indeksa dok značajnost nije zabeležena između TGI indeksa i ostala tri prediktora (Slika 18).



**Slika 18.** Korelacioni matriks za prikaz odnosa između četiri odabrana prediktora baziran na vrednostima Pirsonovog korelacionog koeficijenta. VB (visina biljaka), GCI (eng. *green chlorophyll index*), TGI (eng. *triangular greenness index*), CC (eng. *canopy cover*, pokrovnost). Prekrštena polja govore da vrednosti korelacionog koeficijenta nisu statistički značajne ( $p < 0,05$ )

Odabrani RF model iskorišćen je za predikciju sveže biomase svih genotipova iz RK, RS, KK i KS ogleda u 2020. i 2021. godini. Na ovaj način omogućeno je praćenje dinamike nakupljanja organske materije tokom vegetacionog perioda u različitim uslovima sredine (Grafik 15).



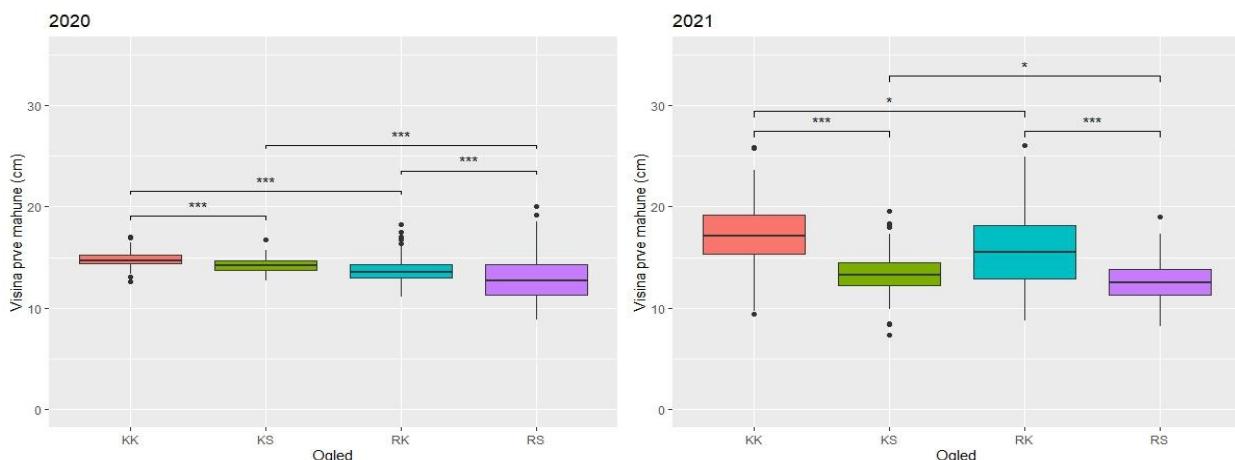
**Grafik 15.** Prediktovana biomasa biljaka soje u 2020. i 2021. godini. Liniye greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola), GDD (eng. *growing degree days*)

Dobijeni rezultati o nakupljanju sveže biomase soje razlikovali su se po godinama, uslovima gajenja ali i grupama zrenja analiziranih genotipova. U 2020. godini pri 390 GDD medialna vrednost sveže biomase sorti iz KK ogleda iznosila je oko  $0,5 \text{ kg/m}^2$  dok je u istoj vremenskoj tački godinu dana kasnije bila duplo veća. Kod ranih sorti najuočljivija razlika između godina bila je pri 642 GDD. U ovoj vremenskoj tački, genotipovi iz RK ogleda su u 2020. godini postigli prosečnu vrednost sveže biomase od oko  $0,9 \text{ kg/m}^2$  dok je naredne godine ona bila preko  $1,7 \text{ kg/m}^2$ . U kontrolnim ogledima (KK i RK), sorte sa dužim vegetacionim periodom nakupljale su veću količinu organske materije u odnosu na rane sorte. Maksimalne vrednosti sveže biomase kod kasnih genotipova iz kontrolnih ogleda bile su i preko  $2,6 \text{ kg/m}^2$  dok kod ranih sorti ona nije prelazila  $2,3 \text{ kg/m}^2$ . Negativan efekat suše na nakupljanje organske materije jasno se uočava analizom dobijenih podataka o biomasi iz KS i RS ogleda. U početnim fazama razvoja nepovoljni uslovi sredine nisu imali toliko značajan uticaj na rast soje koliko nakon 390 GDD. Od tog momenta smanjuje se akumulacija biomase kod genotipova izloženih suši u poređenju sa kontrolom. Tokom dve godine istraživanja u gotovo svakoj vremenskoj tački zabeležena je veća varijabilnost u prediktovanoj biomasi kod genotipova gajenih u nepovoljnim uslovima. Uočena varijabilnost svedoči o različitoj reakciji sorti na stres prouzrokovani ovim abiotičkim faktorom. Dvogodišnji rezultati o prediktovanoj biomasi iskorišćeni su za odabir po pet genotipova u kontrolnim i sušnim uslovima koji su tokom vegetacionog perioda nakupili najveću količinu organske materije. U kontroli su to bile sorte Dumbar, Steara, NS Milan, NS Vasa i ES Mediator a u suši NS-L-510017, Buenos, Neoplanta, Steara i Daciana.

## 6.5. Morfološke, proizvodne i tehnološke osobine soje

### 6.5.1. Visina prve mahune

U okviru druge faze istraživanja, kod analiziranih genotipova soje zabeležene su različite vrednosti visine prve mahune (Grafik 16).



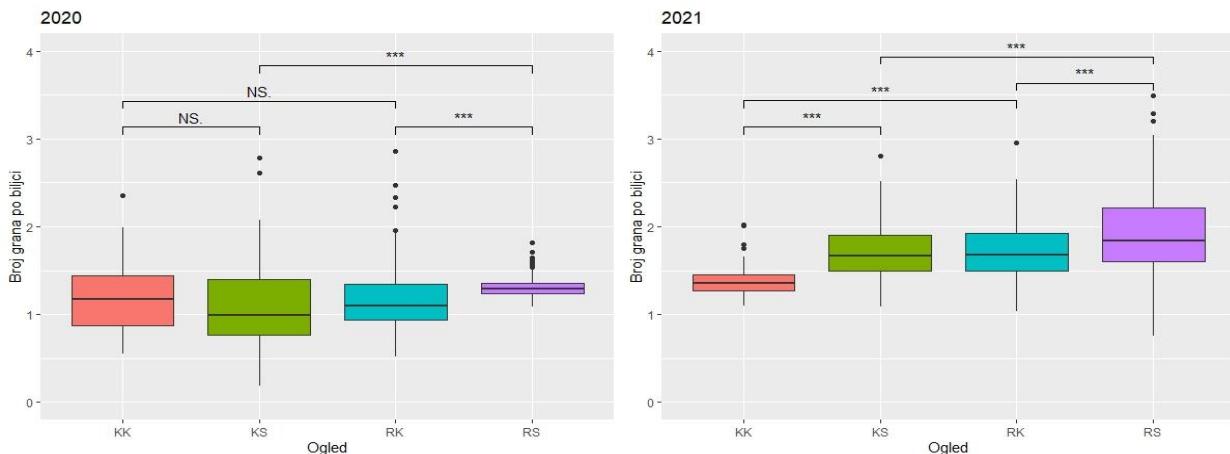
**Grafik 16.** Visina prve mahune u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru box plot-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost ( $* p < 0,05$ ;  $*** p < 0,001$ )

U obe godine kod kasnih sorti, prva mahuna se nalazila na značajno većoj visini nego kod ranih i to kako u kontrolnim tako i u ogledima koji su postavljeni u sušnim uslovim. Efekat dužine vegetacionog perioda bio je izraženiji u 2020. godini odnosu na 2021. godinu. Na osnovu prikupljenih podataka, uočena je razlika između rezultata dobijenih iz ogleda koji su postavljeni u suši u odnosu na kontrolu. Nepovoljni uslovi sredine su u obe godine veoma značajno ( $p < 0,001$ ) redukovali visinu prve mahune i kod ranih i kod kasnih genotipova. Analizom dobijenih podataka izdvojeni su genotipovi kod kojih je visina prve mahune u obe godine bila između 15 i 20 cm što zadovoljava

tehničke zahteve sa aspekta žetve. U kontrolnim uslovima navedene kriterijume ispunile su sorte Zarja, Nicola TD, Tena, NS Albus, Princess, Danica, Harizma, NS Vasa, Trijumf, Kolos, ES Pallador, Neoplanta, NS Maximus, Rubin, Carina F, Iva, NS Sirius, Victoria, Korus, NS Kraljica, Anica, Zita, Richi i Tajfun. Sa druge strane u suši su to bili genotipovi Ada TD, Carla TD, Naskia, Kato, Miruna TD, Dumbar, Smolianka, Eider i Regnum.

### 6.5.2. Broj grana po biljci

Kada je u pitanju broja grana po biljci, dobijene vrednosti su se razlikovale u 2020. i 2021. godini (Grafik 17). U prvoj godini ovog dela istraživanja, nije uočena statistički značajna razlika u prosečnom broju grana po biljci između KK i RK kao i između KK i KS ogleda. Sa druge strane, prikupljeni podaci su pokazali da postoji statistički veoma značajna razlika ( $p < 0,001$ ) u prosečnom broju grana po biljci između KS i RS odnosno RK i RS ogleda.

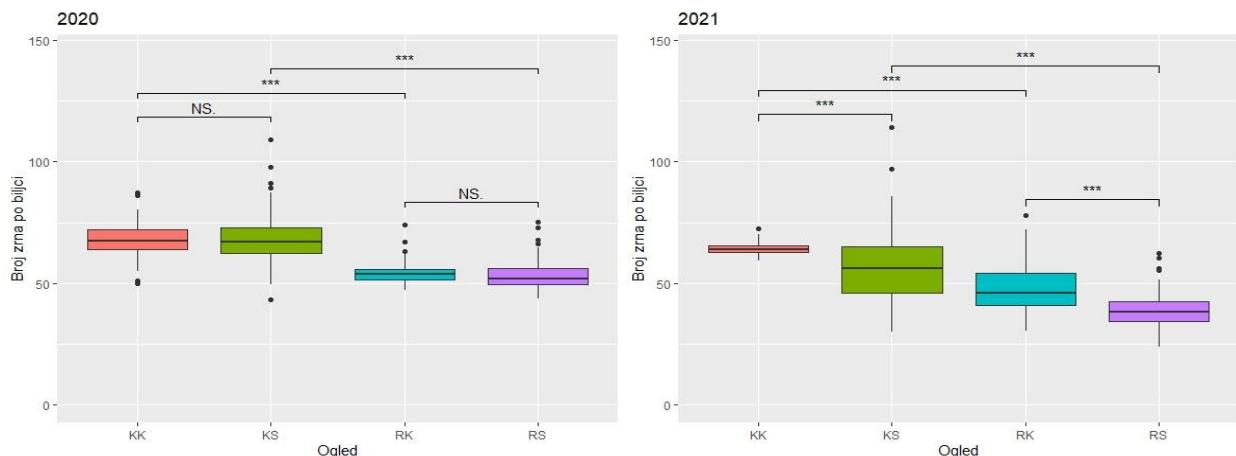


**Grafik 17.** Broj grana po biljci soje u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost (\*\*\*)  $p < 0,001$ , NS - razlika nije statistički značajna

Iako su u prvoj godini nepovoljni uslovi gajenja doveli do pojačanog grananja biljaka soje samo kod materijala sa kraćim vegetacionim periodom, naredne godine povećanje je zabeleženo i u RS i KS ogledima. Sumirano, u 2021. godini grananje je bilo izraženije i u kontrolnim (RK = 1,72 i KK = 1,38) i u ogledima postavljenim u suši (RS = 1,91 i KS = 1,71). Dobijeni podaci ukazuju da su u drugoj godini istraživanja nepovoljni uslovi prouzrokovani sušom doveli do većeg grananja kasnih sorti nego što je to bio slučaj sa genotipovima sa kraćim vegetacionim periodom. Na osnovu dvogodišnjih podataka iz kontrolnih i sušnih uslova izdvojeno je po pet genotipova kod kojih je zabeležen najveći broj bočnih grana. U kontrolnim uslovima to su bili Toyomusume, Perla, Kamishunbetzu, Richi i Gracia a u suši Secca, Toyomusume, Prima, Acme i NS Atlas.

### 6.5.3. Broj zrna po biljci

Broj zrna po biljci je takođe varirao u zavisnosti od dužine vegetacionog perioda analiziranih genotipova ali i uslova sredine u kojima je soja gajena (Grafik 18). U 2020. godini sušni uslovi nisu bitnije uticali na broj zrna po biljci ni kod kasnog ni kod rang materijala. Veoma značajna razlika ( $p < 0,001$ ) u prosečnom broju zrna po biljci zabeležena je između grupa zrenja pri čemu je više zrna dobijeno u ogledima sa kasnim sortama (KK = 67,8 i KS = 68,39) u odnosu na rane (RK = 54,05 i RS = 53,24).

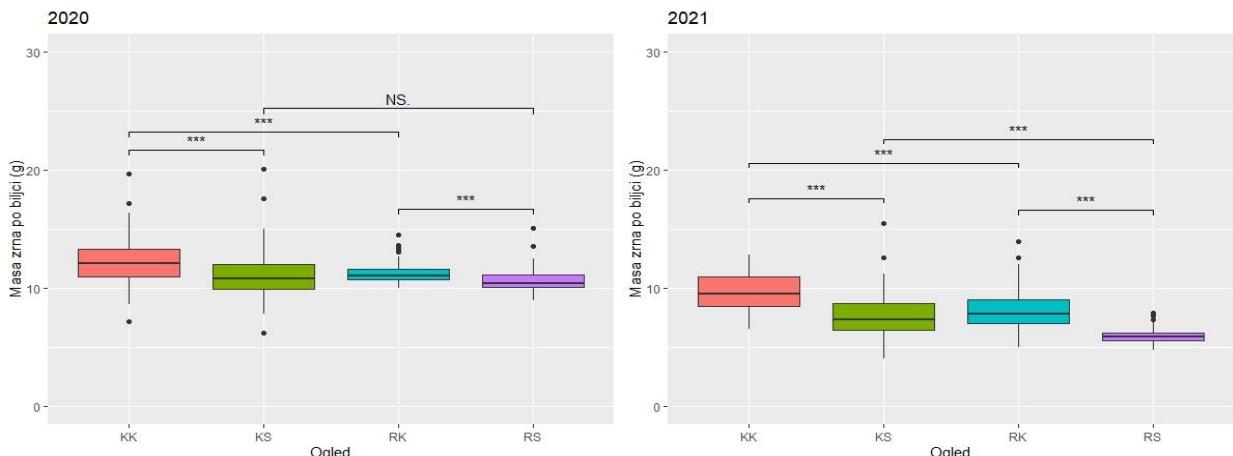


**Grafik 18.** Broj zrna po biljci soje u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru box plot-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. outliers). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost (\*\*\*)  $p < 0,001$ , NS - razlika nije statistički značajna

Sa druge strane, u 2021. godini rezultati su nešto drugačiji pa je statistički veoma značajna razlika ( $p < 0,001$ ) uočena kako po pitanju grupa zrenja tako i po uslovima gajenja. Sorte soje sa dužim vegetacionim periodom imale su veći broj zrna i u kontrolnim i u sušnim uslovima. U odnosu na prethodnu sezonu, u 2021. godini uticaj suše je bio izraženiji. Naime, u RK ogledu prosečan broj zrna po biljci iznosio je 47,94 dok je u suši bio za 9,18 zrna manji (RS = 38,56). Slična razlika (7,9 zrna) uočena je i kod kasnih sorti sa tim što su ovde vrednosti u proseku bile veće (KK = 64,24 zrna a KS = 56,34 zrna). Na osnovu dvogodišnjih rezultata, pet genotipova koji su u kontrolnim ogledima imali najveći prosečan broj zrna po biljci bili su ES Mediator, Fabiana F, Kolos, Steara i ES Pallador. U ogledima postavljenim u suši izdvojili su se Tajfun, Asitka, NS Princeza, Neoplanta i ES Mediator.

## 6.5.4. Masa zrna po biljci

Kako bi se bliže sagledale performanse ispitivanih genotipova soje, pored broja zrna po biljci, analizirana je i masa zrna u okviru RK, KK, RS i KS ogleda (Grafik 19). Prosečna težina semena varirala je između ogleda koji su gajeni u suši i u kontroli. Posmatrajući dve proizvodne sezone jedino između KS i RS ogleda u 2020. godini nije bilo statistički značajne razlike u prosečnoj masi zrna po biljci dok je u svim ostalim slučajevima ona bila na nivou od  $p < 0,001$ .

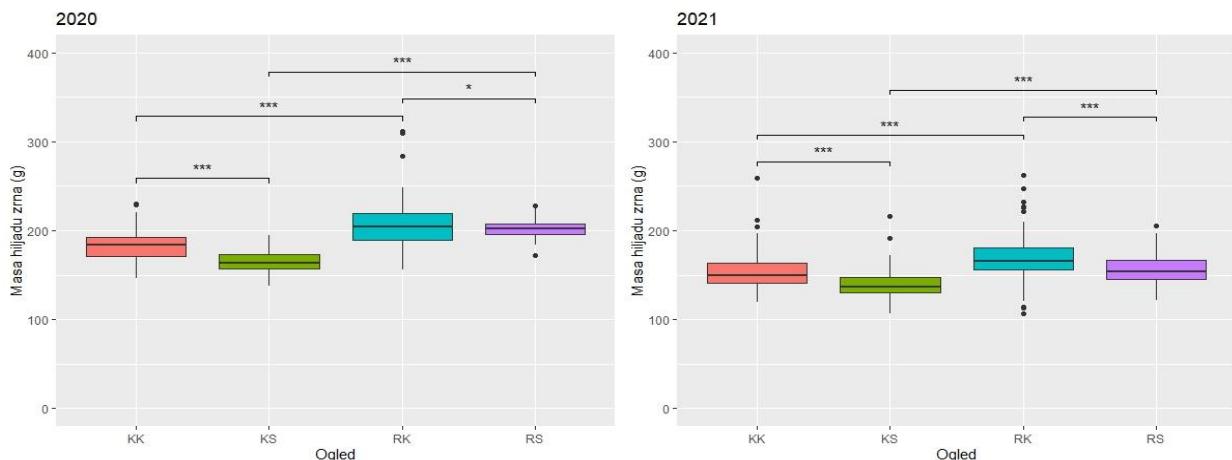


**Grafik 19.** Masa zrna po biljci soje u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu i tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost (\*\*\*)  $p < 0,001$ , NS - razlika nije statistički značajna

U 2020. godini prosečna masa zrna po biljci u RK i KK ogledu je iznosila 11,25 g odnosno 12,22 g dok je u istim ogledima u suši ona bila 10,62 g i 11,04 g. Naredne godine, niže vrednosti ovog parametra izmerene su kako u kontrolnim (RK = 8,3 g i KK = 9,86 g) tako i u ogledima postavljenim u sušnim uslovima (RS = 5,98 g i KS = 7,63 g). Podaci prikupljeni u 2020. godini su pokazali da su nepovoljni uslovi sredine kod ranih sorti redukovali masu zrna po biljci za 5,6% a kod sorti sa dužim vegetacionim periodom za 9,7% u odnosu na kontrolu. Naredne sezone efekat suše je bio još izraženiji pa je prosečna težina zrna u RS i KS ogledima bila niža za 26,5% odnosno 23% u odnosu na kontrolu. Analizom podataka iz 2020. i 2021. godine utvrđeno je da su u kontrolnim uslovima najveću masu zrna po biljci imali ES Mediator, Tajfun, Steara, Kolos i Camelia F dok su u suši to bili genotipovi Obélix, Asitka, Tajfun, ES Pallador i Neoplanta.

## 6.5.5. Masa hiljadu zrna

Masa hiljadu zrna analiziranih genotipova soje razlikovala se kako po uslovima gajenja tako i po grupama zrenja (Grafik 20). Rezultati ogleda koji su postavljeni tokom 2020. i 2021. godine pokazali su da je bez obzira na okruženje, masa hiljadu zrna bila značajno ( $p < 0,001$ ) veća kod genotipova sa kraćim vegetacionim periodom u odnosu na kasne sorte. Pored toga, uočeno je da nepovoljni uslovi prouzrokovani sušom dovode do smanjenja mase 1000 zrna i kod ranog i kod kasnog materijala.

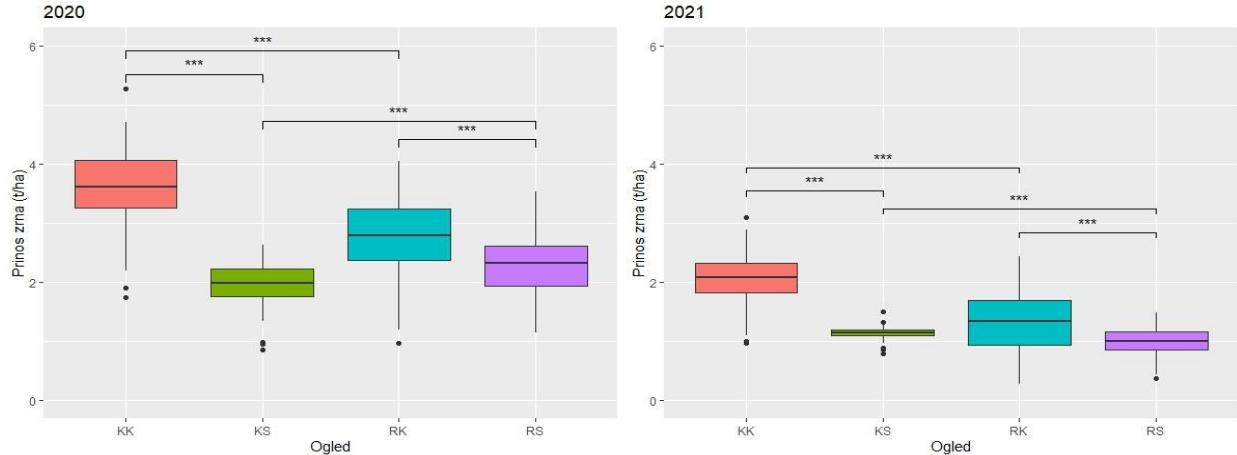


**Grafik 20.** Masa hiljadu zrna u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost (\*  $p < 0,05$ ; \*\*\*  $p < 0,001$ )

Rane sorte gajene u suši imale su veću masu 1000 zrna čak i od kasnih genotipova iz kontrolnih uslova što potvrđuje koliki efekat grupa zrenja ima na vrednost ovog parametra. Prosečne vrednosti mase hiljadu zrna u RS ogledima su u 2020. i 2021. godini bile 202,13 g i 155,99 g dok su u KK ogledu one iznosile 183,29 g odnosno 154,89 g. Sa druge strane, sušni uslovi su doveli do veoma značajnog ( $p < 0,001$ ) smanjenja mase 1000 zrna u svim ogledima osim u slučaju RK i RS ogleda iz 2020. godine gde je razlika bila nešto manje izražena ( $p < 0,05$ ). Zavisno od godine, prosečna masa hiljadu zrna u RS ogledu bila je manja za 2,5-8,1% u odnosu na kontrolu dok je u KS ogledu u obe sezone bila umanjena za oko 10%. Pojedini genotipovi imali su posebno krupno seme pri čemu su pokazali visoku stabilnost po pitanju ove osobine u različitim uslovima gajenja. U kontrolnim uslovima sorte soje sa najvećom prosečnom masom 1000 zrna bile su Gallec, Toyomusume, Toyokomachi, Sigalia i 11-0015-B-B-181-002-006-B-008 dok su se u sušnim izdvojile Bosa, Toyomusume, Lenka, Panonija 8 i Xonia.

## 6.5.6. Prinos zrna

Prinos kao agronomski najznačajnija osobina takođe je varirao i po ogledima i po uslovima gajenja u obe godine istraživanja. Rezultati pokazuju da su bez obzira na grupu zrenja, značajno ( $p < 0,001$ ) veći prosečni prinosi postignuti u kontrolnim u odnosu na sušne uslove i to kako u 2020. tako i u 2021. godini (Grafik 21).

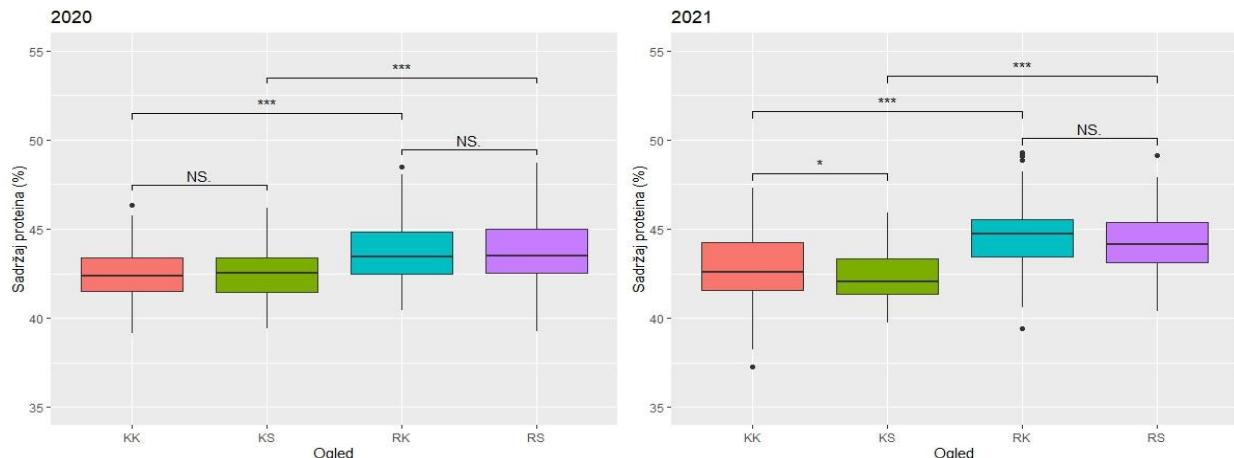


**Grafik 21.** Prosečan prinos u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru box plot-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost (\*\*\*)  $p < 0,001$

Sa druge strane, prinosi genotipova soje koji su analizirani u okviru ove faze istraživanja razlikovali su se i u zavisnosti od dužine vegetacije. Tokom dvogodišnjeg ispitivanja, kasne sorte soje su u gotovo svim ogledima dominirale po pitanju prinsosa. Jedini izuzetak bili su sušni uslovi u 2020. godini gde su rane sorte bile statistički veoma značajno ( $p < 0,001$ ) prinosnije u odnosu na kasne. Iako su se prinosi razlikovali po godinama, nepovoljni uslovi sredine su u obe vegetacione sezone statistički veoma značajno ( $p < 0,001$ ) uticali na smanjenje prinsosa kako kod rane tako i kod kasne germplazme. U obe godine, prosečan prinos u KS ogledima bio je za 45% manji u odnosu na rezultate iz KK ogleda dok je kod ranog materijala redukcija bila manja i iznosila je 16,5% u 2020. odnosno 25% u 2021. godini. Na osnovu dvogodišnjih podataka u kontroli su se kao najprinosnije sorte izdvojile NS Vasa, Tajfun, Buenos, NS Kraljica i Dumbar dok su u suši to bile Dana, GL Melanie, Vidra, Miruna TD i Timirjazevskaja 144.

### 6.5.7. Sadržaj proteina u zrnu

Kada je u pitanju tehnološki kvalitet semena soje, dobijeni rezultati su pokazali da grupa zrenja ima veći uticaj na procentualni udeo proteina u zrnu nego uslovi gajenja. U obe godine istraživanja, sadržaj proteina kod ranih u odnosu na kasne genotipove bio je statistički veoma značajno ( $p < 0,001$ ) veći kako u kontrolnim tako i u sušnim uslovima (Grafik 22).

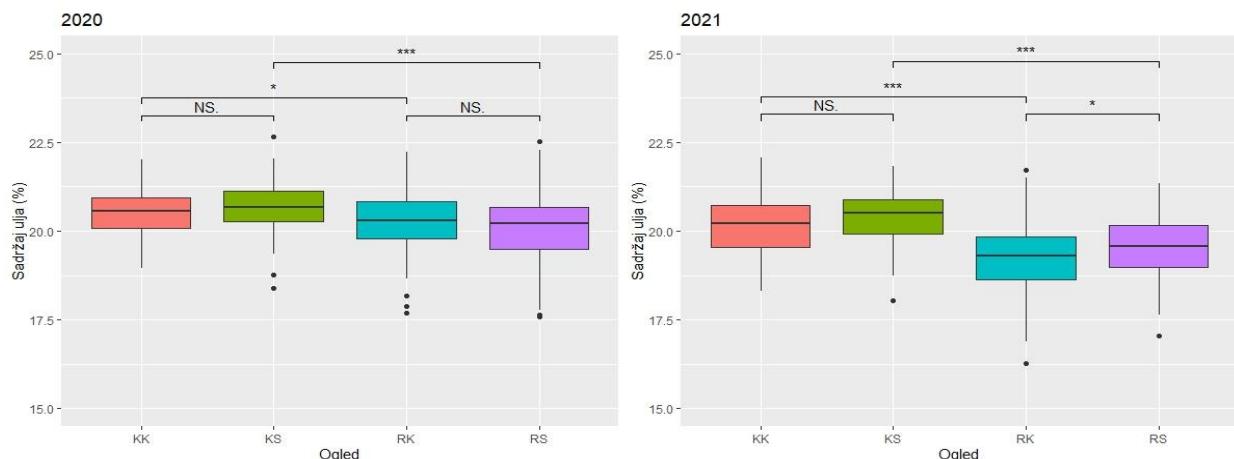


**Grafik 22.** Sadržaj proteina u zrnu soje u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost (\*  $p < 0,05$ ; \*\*\*  $p < 0,001$ ), NS - razlika nije statistički značajna

Razlika u procentualnom udelu proteina između sorti sa kraćim i dužim vegetacionim periodom bila je izraženija u 2021. godini i iznosila je 1,7% u kontroli odnosno 1,95% u suši. Nepovoljni uslovi prouzrokovani nedostatkom vlage u većini slučajeva nisu imali značajnijeg uticaja na sadržaj proteina u analiziranim genotipovima soje. Jedina razlika uočena je u 2021. godini između KK i KS ogleda gde je materijal gajen u kontroli imao statistički značajno ( $p < 0,05$ ) veći procenat proteina u zrnu. Pojedini genotipovi soje su se u oba okruženja istakli kao visokoproteinski. Uzveši podatke iz 2020. i 2021. godine u kontroli su se kao sorte sa najvećim procentualnim sadržajem proteina u zrnu izdvojile Zolta Przebedowska, Kamishunbetzu, Sibniik 315, SOJA 809 i Fiskeby V. Sa druge strane u sušnim uslovima kao visokoproteinski genotipovi označeni su Zolta Przebedowska, NS Kaća, Oriana, Kamianetz i Proteus.

## 6.5.8. Sadržaj ulja u zrnu

Prosečan sadržaj ulja genotipova soje koji su analizirani u okviru ove faze istraživanja se kretao u rasponu od 19,25 do 20,70%, zavisno od godine, uslova gajenja i grupe zrenja (Grafik 23). Kod sadržaja ulja uočeni su obrnuti trendovi u odnosu na izmerene vrednosti proteina pa je tako značajno veći procentualni udeo ulja u zrnu zabeležen kod sorti sa dužim vegetacionim periodom kako u kontrolnim tako i u sušnim uslovima.



**Grafik 23.** Sadržaj ulja u zrnu soje u ogledima postavljenim tokom 2020. i 2021. godine. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*). RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola). Zvezdice predstavljaju statističku značajnost (\*  $p < 0,05$ ; \*\*\*  $p < 0,001$ ), NS - razlika nije statistički značajna

U 2020. godini razlika u sadržaju ulja između kasnih i ranih genotipova koji su gajeni u KK i RK ogledima bila je na nivou od  $p < 0,05$  a u KS i RS na nivou od  $p < 0,001$ . Naredne sezone, grupa zrenja je u oba okruženja statistički veoma značajno ( $p < 0,001$ ) uticala na veći procenat ulja kod kasne germplazme. Kada je u pitanju efekat uslova gajenja na sadržaj ulja u analiziranim genotipovima soje, jedina značajna razlika uočena je u 2021. godini između RK i RS ogleda pri čemu je veći procenat ulja izmeren kod materijala koji je gajan u suši. U svim ostalim slučajevima razlike koje su utvrđene nisu bile statistički značajne. Dvogodišnji rezultati su pokazali da su sorte Naskia, Black Tokyo, NS-L-520019, Tajfun i Trijumf imale najveći procenat ulja u kontrolnim uslovima dok su u suši to bile Selecta 201, Mauthnerov Velkozrun, Black Tokyo, Bačka i Pepita.

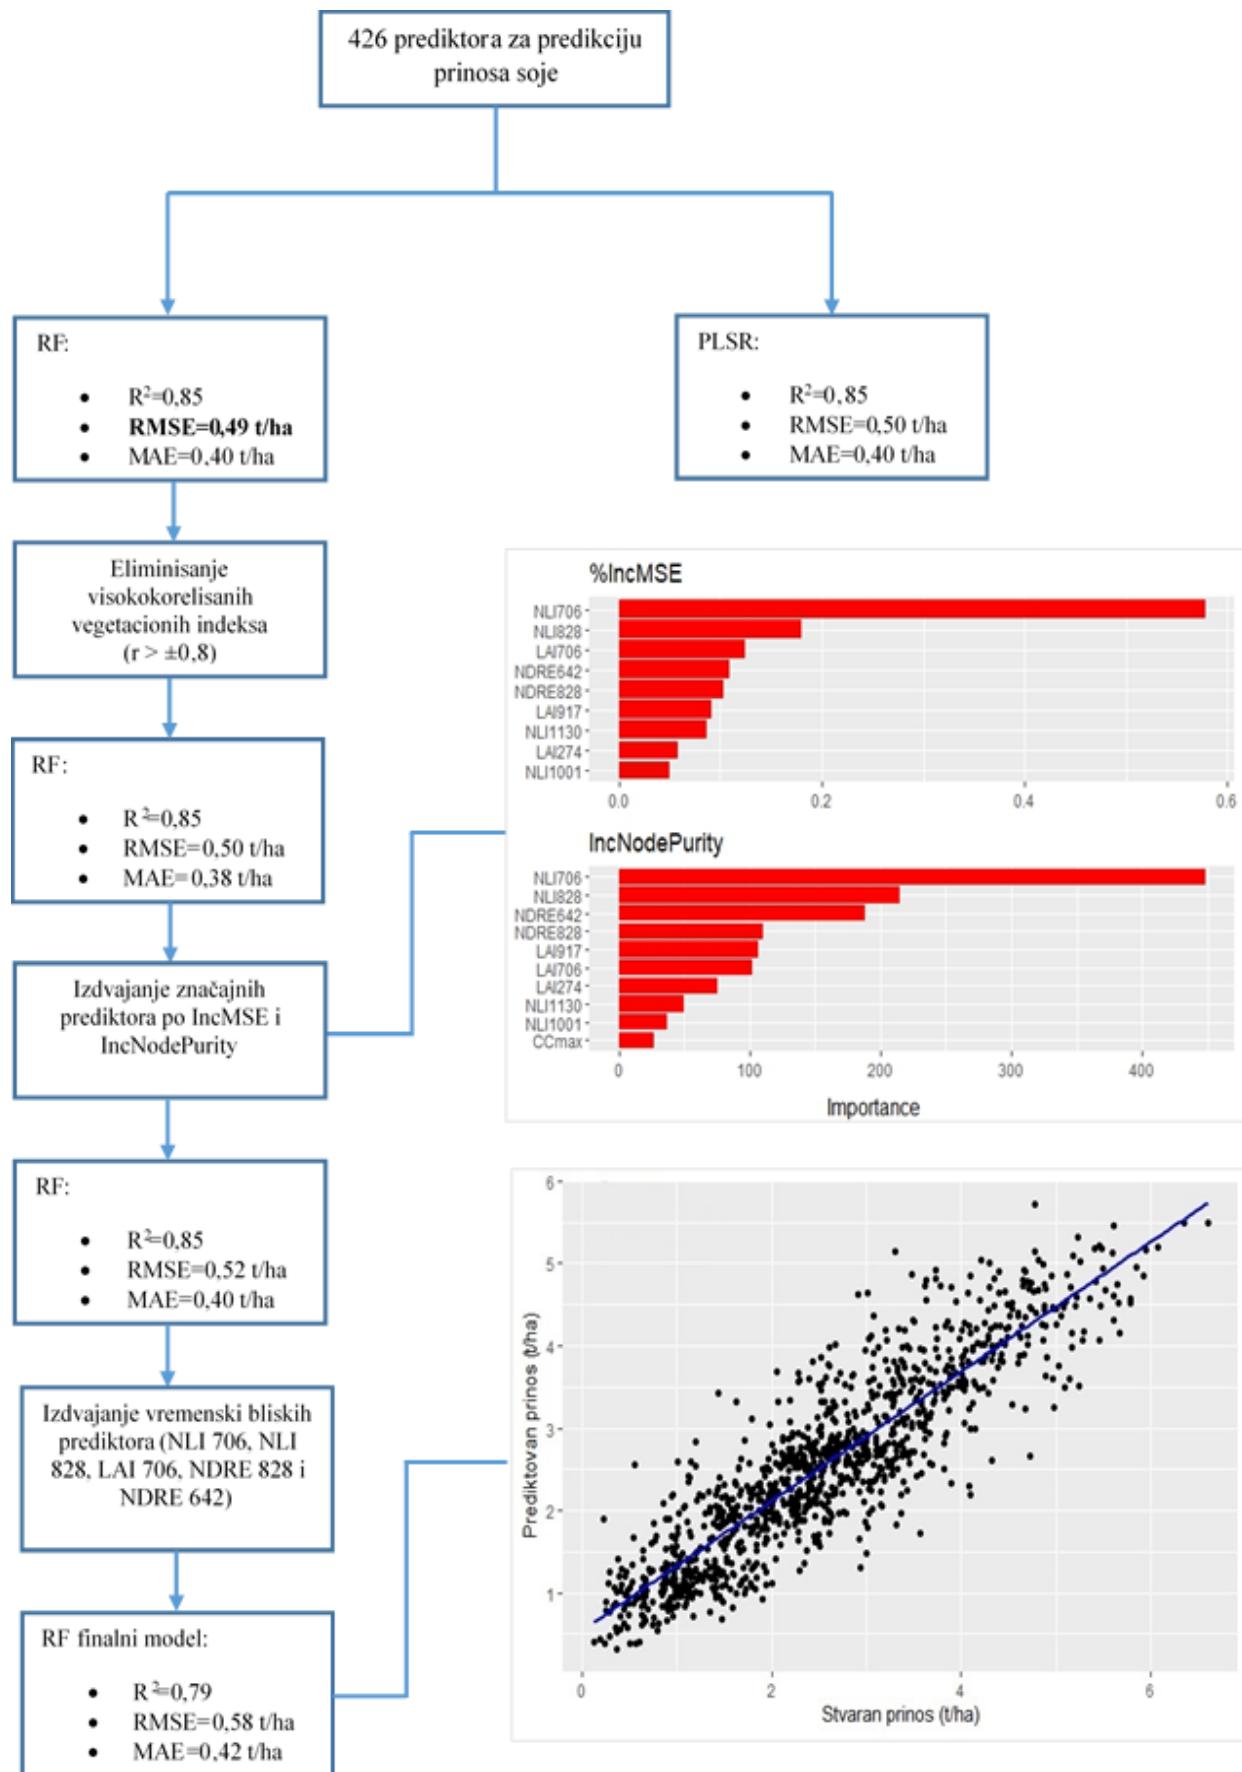
## 6.6. Predikcioni model prinosa soje

Predikcija prinosa soje omogućena je upotrebom RF i PLSR algoritama mašinskog učenja i podataka koji su dobijeni pomoću prethodno kreiranih modela za visokopropusnu fenotipizaciju. Razvoj modela za procenu prinosa odvijao se postupno pri čemu je u svakoj fazi obavljena redukcija broja prediktora u cilju dobijanja maksimalno efikasnog alata. Za ocenu preciznosti modela korišćeni su rezultati unakrsne validacije dobijeni pri poređenju stvarnih i prediktovanih prinosa soje.

Inicijalni set prediktora činilo je ukupno 426 varijabli:

- broj biljaka po jedinici površine,
- pokrovnost i 33 vegetaciona indeksa iz 12 vremenskih tačaka (ukupno 408 prediktora)
- dužina trajanja maksimalne pokrovnosti
- visina i biomasa iz osam vremenskih tačaka (ukupno 16 prediktora)

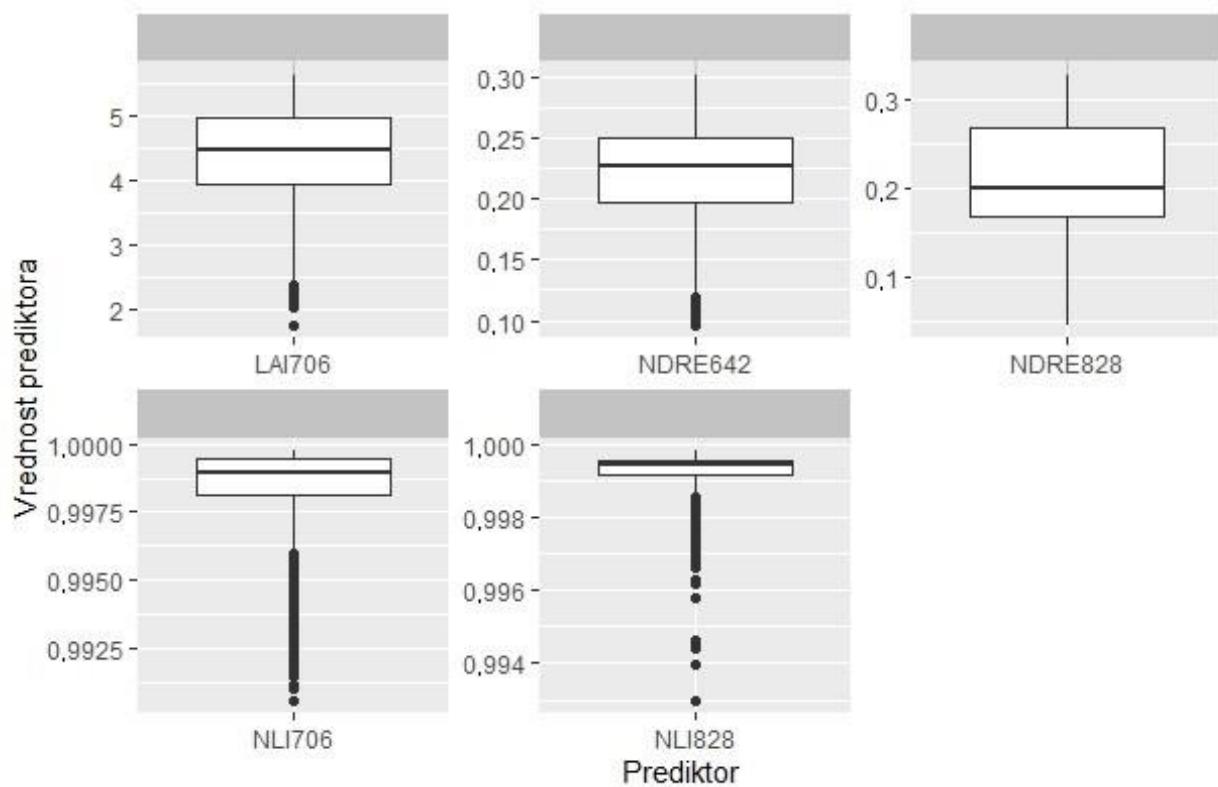
Iako su oba modela obezbedila visoku preciznost, nešto manja greška ( $RMSE = 0,49 \text{ t/ha}$ ) zabeležena je kod RF u odnosu na PLSR model ( $RMSE = 0,50 \text{ t/ha}$ ). Takođe, PLSR je za pojedine parcele predviđao negativne vrednosti prinosa zbog čega je eliminisan iz daljeg rada. U nastavku fokus je bio usmeren na povećanje efikasnosti odabranog RF modela kroz smanjenje broja varijabli koje se odvijalo po fazama. Kompletan tok razvoja modela prikazan je na Slici 19.



**Slika 19.** Uticaj smanjenja broja prediktora na performanse modela za predikciju prinosa soje

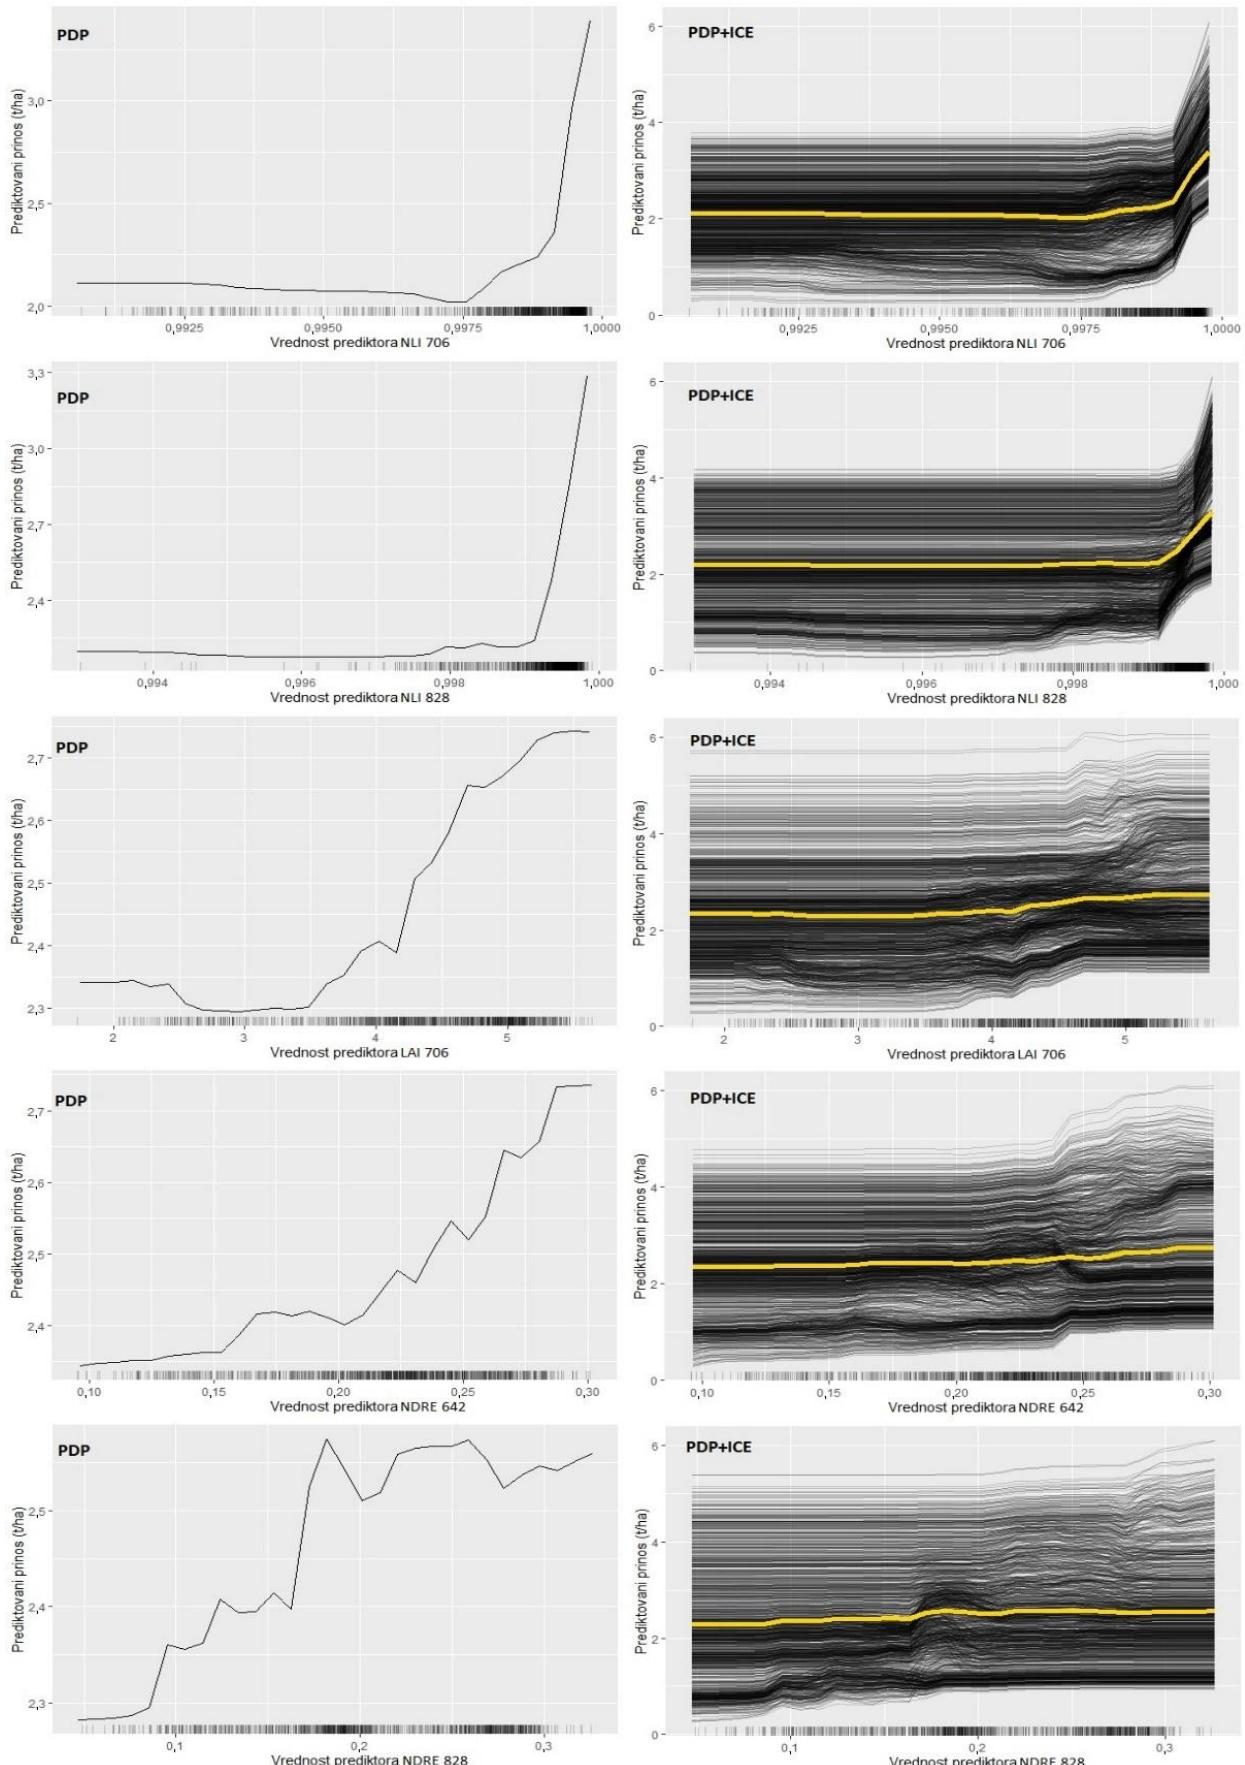
Prvi korak u pravcu povećanja efikasnosti RF modela podrazumevao je utvrđivanje odnosa između vegetacionih indeksa koji su korišćeni kao prediktori. Rezultati su pokazali da je 254 od 528 korelacija bilo veće od prethodno definisane granične vrednosti koja je iznosila  $\pm 0,8$ . Vegetacioni indeksi čija je međusobna korelacija bila iznad zadate su odstranjeni, tako da su kao nezavisni preostali LAI, NLI, NDRE i TGI iz 12 vremenskih tačaka što je broj prediktora sa početnih 426 smanjilo na 78. Model baziran na RF algoritmu ponovo je testiran sa novim, redukovanim setom prediktora. Dobijeni rezultati su pokazali da smanjenje broja varijabli nije imalo većeg uticaja na preciznost modela budući da je RMSE vrednost neznatno povećana sa 0,49 t/ha na 0,50 t/ha. Uticaj 78 pojedinačnih prediktora na nivou od  $p < 0,01$  utvrđen je na osnovu pokazatelja %IncMSE i IncNodePurity. Kao značajni pokazali su se vegetacioni indeksi LAI 274, LAI 390, LAI 706, LAI 917, NLI 706, NLI 828, NLI 1130, NDRE 642 i NDRE 828 i dužina trajanja maksimalne pokrovnosti. Jedinstveni set od deset odabralih varijabli i predloženi RF model obezbedili su visoko poklapanje između stvarnih i prediktovanih vrednosti prinosa soje ( $R^2 = 0,85$ ). Kako je i pored značajnog smanjenja broja varijabli (426→78→10) zadržana visoka preciznost modela, sagledane su mogućnosti za kreiranje maksimalno efikasnog alata. U tu svrhu je od deset najznačajnijih prediktora odabранo pet koji su prikupljeni u tri međusobno najbliže vremenske tačke. Finalni model baziran na RF algoritmu i prediktorima NLI 706, NLI 828, LAI 706, NDRE 828 i NDRE 642 obezedio je dobru preciznost u proceni prinosa soje pri čemu je greška zadržana ispod 0,6 t/ha.

Kako bi se bliže sagledalo pet prediktora koji su korišćeni u finalnom modelu za predikciju prinosa soje analizirane su njihove pojedinačne vrednosti. Dobijeni podaci o varijablama su pokazali postojanje razlika između parcela i vremenskih tačaka tokom vegetacionog perioda soje u kojoj su određene (Grafik 24).



**Grafik 24.** Vrednosti odabranih prediktora u finalnom RF (eng. *random forest*) modelu za predikciju prinosa soje. Linije greške prikazuju interval poverenja od 95%, horizontalna linija u okviru *box plot*-a predstavlja medijanu a tačke vrednosti izvan opsega (eng. *outliers*)

Prosečna vrednost prediktora LAI 706 iznosila je 4,32 dok su minimum i maksimum bili 1,75 odnosno 5,63. Veliki raspon u vrednostima zabeležen je i kod NDRE vegetacionog indeksa koji je kao prediktor odabran pri 642 i 828 GDD. Kod NDRE 642 vrednosti su se kretale od 0,1 do 0,3 a kod NDRE od 0,05 do 0,33. Iako su podaci o ovom indeksu prikupljeni u dve vremenske tačke između kojih je razlika gotovo 200 GDD, prosečna vrednost je bila skoro ista i iznosila je 0,22 kod NDRE 642 odnosno 0,21 kod NDRE 828. U odnosu na prethodna dva vegetaciona indeksa, kod NLI 706 i NLI 828 razlike u pojedinačnim vrednostima mogle su se uočiti tek na trećoj ili četvrtoj decimali. Na svim parcelama soje koje su analizirane za potrebe kreiranja modela za predikciju prinosa, NLI 706 i NLI 828 imali su vrednost veću od 0,99. Podaci o odabranim prediktorima pokazali su manju ili veću varijabilnost na osnovu kojih je obavljena predikcija prinosa u okviru RF modela. Dalja analiza pokazuje kretanje prinosa na osnovu promene vrednosti prediktora što je i prikazano na PDP i PDP+ICE graficima (Grafik 25).



**Grafik 25.** Varijabilnost prinosa soje prediktovanog pomoću predloženog RF modela pri različitim vrednostima prediktora, prikazana pomoću PDP (leva kolona) i PDP+ICE (desna kolona) grafikona.  
 RF (eng. *random forest*), PDP (eng. *partial dependence plot*), ICE (eng. *individual conditional expectation*)

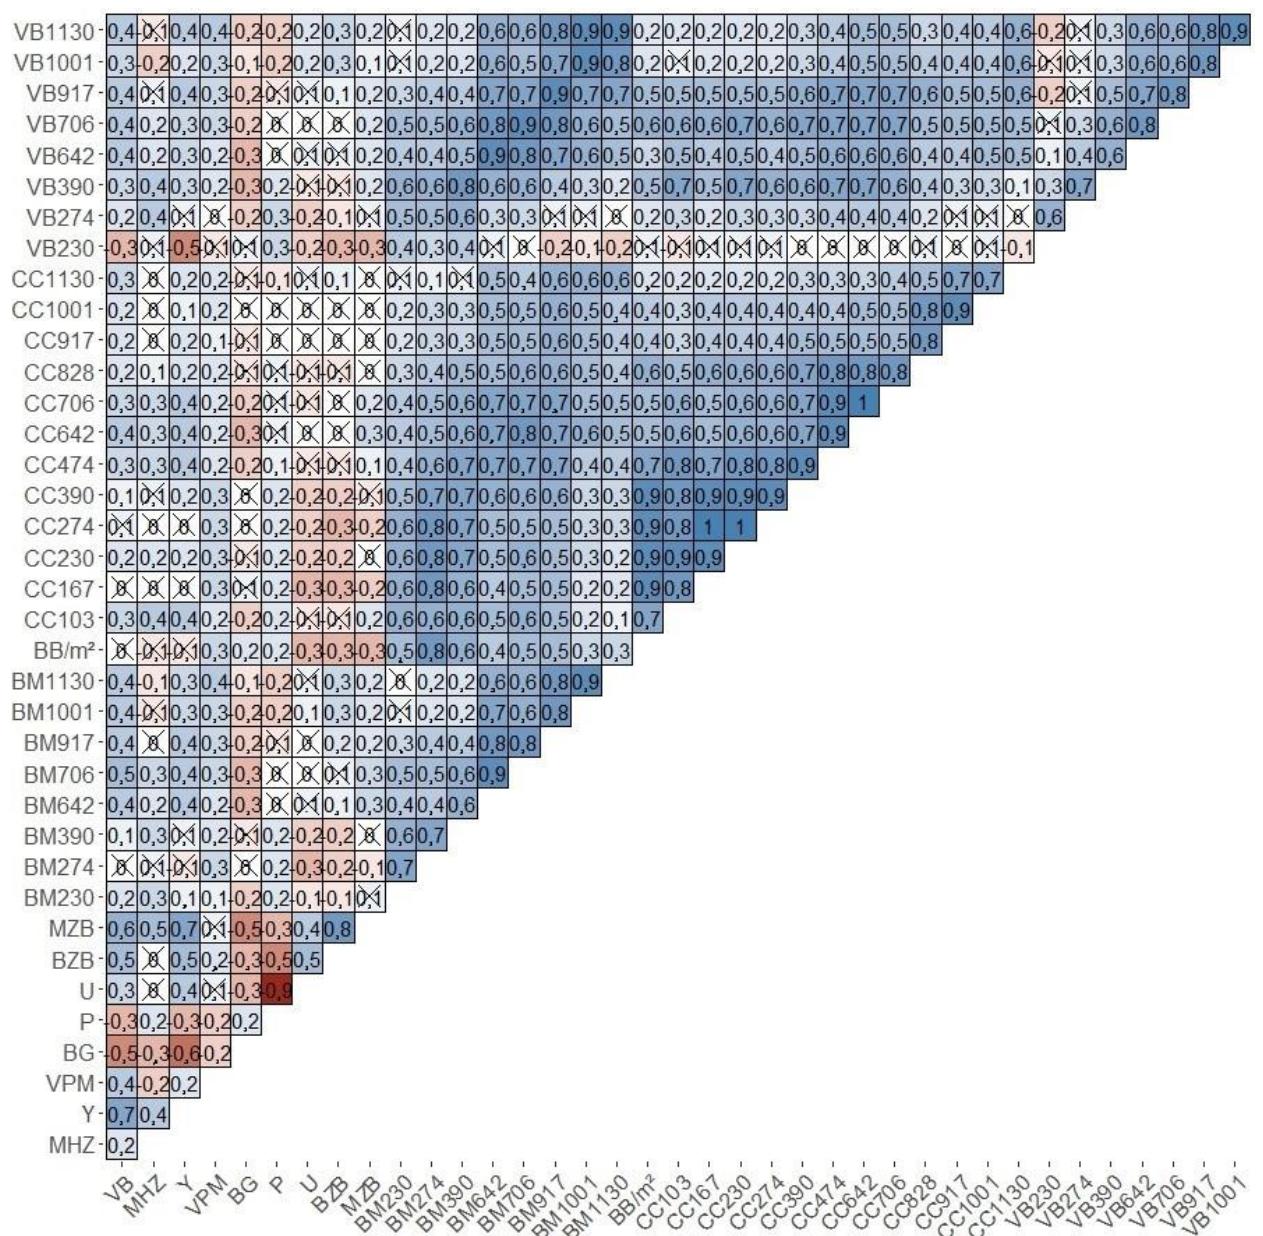
Na zbirnom PDP+ICE grafikonu za NLI 706 utvrđeno je da se prelomna tačka javlja pri vrednosti od oko 0,9975. Nakon toga dolazi do jače diferencijacije između pojedinačnih parcela soje. Ovo je jasnije istaknuto na individualnom PDP grafiku na kom se vidi kako sa povećanjem vrednosti prediktora iznad prelomne tačke, prediktovani prinos sa oko 2 t/ha vrlo brzo raste na preko 3 t/ha. Slična situacija sa istim indeksom zabeležena je i pri 828 GDD sa tim što je u ovom slučaju granica pomerena na preko 0,999. Kod prediktora LAI 706, ujednačen trend u prediktovanom prinosu zadržava se sve do vrednosti varijable od oko 3,5. Sa daljim povećanjem LAI 706 do vrednosti od oko 5,5, prediktovani prinos ima trend rasta sa približno 2,3 t/ha na oko 2,75 t/ha. Poslednja dva prediktora koja su korišćena pri kreiranju modela za predikciju prinosa soje bili su NDRE 642 i NDRE 828. Kod prve varijable do promene dolazi pri vrednosti većoj od 0,15 kada prediktovani prinos sa oko 2,35 t/ha kreće da raste sve do oko 2,75 t/ha. Nakon toga, kada NDRE 642 dostigne približno 0,28, vrednosti prinosa ulaze u plato. Kod istog indeksa ali pri 828 GDD, primetne su dve prelomne tačke odnosno dva skoka prinosa koja se javljaju kao posledica promene vrednosti prediktora. Prva se dešava već pri oko 0,9 kada se odvajaju prinosi veći od 2,3 t/ha, pri čemu oni rastu sve do oko 2,4 t/ha odnosno dok NDRE 828 ne dostigne vrednost od oko 0,16. Posle toga se javlja i drugi nagli skok, kada sa daljim porastom varijable do približno 0,18 prinos raste na oko 2,5 t/ha.

Na osnovu podataka o prediktovanom prinosu koji su dobijeni pomoću finalnog RF modela u kontrolnim uslovima kao najprinosniji genotipovi izdvojili su se ES Pallador, Tajfun, NS Vasa, NS-L-510017 i NS-L-510016. Sa druge strane u sušnim uslovima pet najproduktivnijih sorti bile su Krajina, Buenos, Grignon 14, NS-L-510017 i NS Virtus.

## **6.7. Karakterizacija genotipova soje na osnovu klasične i visokopropusne fenotipizacije**

Mogućnost korišćenja visokopropusne fenotipizacije za potrebe karakterizacije germplazme soje testirana je u dva pravca. Prvi se odnosio na izdvajanje superiornih genotipova soje na osnovu podataka koji su dobijeni pomoću kreiranih modela za visokopropusnu fenotipizaciju tokom druge faze istraživanja. Pet genotipova koji su ostvarili najbolje rezultate po pitanju parametara pokrovnosti (najmanje vremena potrebno za dostizanje 50% pokrovnosti i dužina trajanja maksimalne pokrovnosti), biomase i prinosa odabrani su posebno za kontrolne i sušne uslove. Kod visine u oba okruženja su izdvojene sve one sorte čija je maksimalna visina bila između 100 i 110 cm. Genotipovi izdvojeni pomoću visokopropusne fenotipizacije predstavljaju germplazmu sa superiornim agronomskim i oplemenjivačkim osobinama i kao takvi mogu biti iskorišćeni pri stvaranju novih sorti soje.

Drugi pravac je podrazumevao proveru veze između prediktovanih vrednosti broja biljaka po jedinici površine, pokrovnosti, visine i biomase i podataka o morfološkim, tehnološkim i proizvodnim karakteristikama genotipova soje koji su testirani u okviru druge faze istraživanja. Dobijanje informacije o postojanju veze između navedenih osobina moglo bi doprineti efikasnijem i preciznijem odabiru čistih linija koje nastaju nakon ukrštanja roditelja. U tu svrhu je utvrđena koreaciona veza između vrednosti visine prve mahune, broja grana po biljci, broja zrna po biljci, mase zrna po biljci, mase hiljadu zrna, prinosa, sadržaja proteina i ulja koje su dobijene klasičnom fenotipizacijom i podataka dobijenih pomoću modela visokopropusne fenotipizacije, korelacije kod kojih nije utvrđena statistička značajnost ( $p < 0,05$ ) su precrteane (Slika 20).



**Slika 20.** Korelacioni matriks sa vrednostima Pirsonovog koeficijenta korelacije između različitih osobina soje. VB (Visina biljaka), MHZ (masa hiljadu zrna), Y (prinos), VPM (visina prve mahune), BG (broj grana), P (sadržaj proteina), U (sadržaj ulja), BZB (broj zrna po biljci), MZB (masa zrna po biljci), BM (biomasa), BB/m<sup>2</sup> (broj biljaka/m<sup>2</sup>), CC (eng. *canopy cover*, pokrovnost)

Veća korelacija zabeležena je između podataka o četiri kvantitativne osobine za koje su kreirani predikcioni modeli nego između vrednosti ovih parametara i morfoloških, proizvodnih i kvalitativnih osobina. Pirsonovi koeficijenti između morfoloških karakteristika, prinosa i sadržaja proteina i ulja sa jedne strane i prediktovanih vrednosti broja biljaka, pokrovnosti, visine i biomase sa druge strane kretale su se u rasponu od -0,5 do 0,5. Granične vrednosti ostvarene su samo u dva slučaja i to između prinosa zrna i prediktovane visine pri 230 GDD ( $r = -0,5$ ). Maksimalna pozitivna veza ( $r = 0,5$ ) zabeležena je između visine u zrenju i prediktovane biomase pri 706 GDD. U svim ostalim slučajevima korelacija između analiziranih osobina je bila manja ili je nije ni bilo (masa hiljadu zrna i pokrovnost pri 167 ili 274 GDD). Kada su u pitanju masa i broj zrna po biljci, gotovo da nije uočena veza ovih parametara sa prediktovanim vrednostima pokrovnosti nakon 706 GDD što nije bio slučaj sa visinom ili biomasom u istim vremenskim tačkama. Najniže vrednosti korelacionog koeficijenta između sadržaja proteina i ulja i prediktovane pokrovnosti, visine i biomase zabeležene su u istom delu vegetacionog perioda i to od 642 do 917 GDD. Za broj grana i visinu prve mahune

rezultati su obrnuti. Broj grana je u većini slučajeva bio negativno korelisan sa gotovo svim osobinama koje su određene pomoću predikcionih modela dok je visina prve mahune bila u negativnoj korelaciji samo sa prediktovanom visinom biljaka pri 230 GDD. Prinos kao najznačajnija osobina bio je najmanje korelisan sa brojem biljaka po jedinici površine ( $r = 0,1$ ) dok je sa ostale tri osobine jačina veze zavisila od vremenske tačke u kojoj su predikcije obavljene. Ipak, treba istaći da su veće vrednosti Pirsonovog koeficijenta zabeležene kada je prinos upoređen sa pokrovnošću, prediktovanom visinom i biomasom izmerenim u kasnijim u odnosu na ranije faze razvoja (pre 642 GDD).

## 7. DISKUSIJA

Primena alata daljinske detekcije i fotogrametrijska obrada prikupljenih podataka sve više postaje prepoznata kao mogućnost za povećanje genetičke dobiti kroz brzo i precizno određivanja važnih fenotipskih pokazatelja (Makanza i sar., 2018; Moreira i sar., 2019; Jangra i sar., 2021; Roth i sar., 2022). Preciznost pri predikciji osobina od interesa obezbeđena je upotrebom mašinskog učenja kroz kreiranje različitih modela zasnovanih na varijablama koje predstavljaju podatke dobijene obradom fotografija biljaka (Maimaitijiang i sar., 2017; Zhou i sar., 2019a; Pratama i sar., 2020). Istraživanje sprovedeno u okviru ove doktorske disertacije rezultovalo je kreiranjem specifičnih modela za visokopropusnu fenotipizaciju kvantitativnih osobina soje, koje su od praktičnog značaja za oplemenjivanje. Upotrebom podataka koji su bazirani na refleksiji i fotogrametriji, omogućeno je uspešno predviđanje različitih parametara kao što su broj biljaka po jedinici površine, pokrovnost, visina, biomasa i prinos soje.

Budući da su modeli zasnovani na daljinskoj detekciji, važnu ulogu u njihovom kreiranju imali su vegetacioni indeksi koji predstavljaju različite odnose reflektovanog sunčevog zračenja u određenim spektrima, od strane biljaka (Khan i sar., 2018). Kao takvi, oni omogućavaju ne samo klasifikovanje vegetacije (Ritchie i sar., 2010; Hamuda, 2016) već mogu biti upotrebljeni i za determinaciju kompleksnijih parametara poput biomase (Hunt i sar., 2005), sadržaja hlorofila (Sánchez-Sastre i sar., 2020) ili prinosa (Maresma i sar., 2016). Imajući u vidu njihov potencijal, vegetacioni indeksi iskorišćeni su i u istraživanju na soji prilikom kreiranja modela za visokopropusnu fenotipizaciju. Pri proceni pokrovnosti i visine biljaka, vegetacioni indeksi upotrebljeni su pre svega za maskiranje zemljišta odnosno isticanje vegetativne mase soje. Sa druge strane, kod modela za predikciju broja biljaka po jedinici površine i biomase, indeksi su korišćeni i kao variable u RF i PLSR algoritmima mašinskog učenja. Određivanje kompleksnijih osobina, poput biomase, može biti zasnovano na prostoj linearnoj regresiji sa različitim vegetacionim indeksima (Lussem i sar., 2018), visinom (Lati i sar., 2013) ili pokrovnošću (Pandey i sar., 2016). Međutim, upotreba matematičkih algoritama pruža mogućnost za kombinovanje različitih prediktora koji korišćeni zajedno, mogu osigurati veću preciznost. O tome svedoče i druga istraživanja u kojima su bolji rezultati u određivanju biomase postignuti kada su kao prediktori u isto vreme korišćeni vegetacioni indeksi i visina u odnosu na modele koji su baziranim samo na podacima o refleksiji (Tilly i sar., 2015). Na osnovu tog saznanja, prilikom kreiranja modela za predikciju biomase soje kao inicijalne variable korišćeni su vegetacioni indeksi, visina ali i pokrovnost. Budući da je širi pristup pokazao zavidne rezultate u predviđanju akumulirane organske materije ( $R^2 = 0,94$ ), slično je urađeno i prilikom kreiranja modela za predviđanje prinosa. Kako se radi o složenoj, agronomski najznačajnijoj osobini, set prediktora je dodatno proširen sa podacima o biomasi i broju biljaka po jedinici površine. Važno je istaći da su svi modeli za visokopropusnu fenotipizaciju kalibrисани na divergentnoj germplazmi soje koja je ispitivana u višegodišnjim ogledima i to u različitim uslovima sredine što je bitno doprinelo njihovoј robustnosti.

## 7.1. Model za predikciju broja biljaka po jedinici površine

Broj biljaka po jedinici površine predstavlja značajan pokazatelj na osnovu kog je moguće sagledati kvalitet nicanja i potencijalne gubitke tokom sezone što je od velikog značaja kako sa proizvodnog tako i istraživačkog stanovišta. Upotreboom vegetacionih indeksa i RF algoritma mašinskog učenja kreiran je model koji obezbeđuje visoku preciznost pri predikciji broja biljaka soje po jedinci površine što je potvrđeno na osnovu  $R^2$  vrednosti koje su dobijene pri kalibraciji ( $R^2 = 0,80$ ) i evaluaciji ( $R^2 = 0,76$ ) modela. Predloženi model je i prilikom provere na nezavisnom setu podataka zadržao visoku preciznost što nije bio slučaj kod sličnog modela koji su predložili Habibi i sar., (2020). Navedeni autori su za predikciju broja biljaka soje takođe koristili RF i podatke o spektralnoj refleksiji koji su uključivali vrednosti R, G, B i NIR kanala kao i NDVI iz četiri vremenske tačke. Iako je model pokazao dobre performanse na trening setu podataka ( $R^2 = 0,81$ ), prilikom provere na nezavisnom materijalu (test set) preciznost je značajno opala ( $R^2 = 0,67$ ). U pomenutom istraživanju za kreiranje RF modela korišćeni su satelitski snimci sa niskom rezolucijom (3m/piksela) što ograničava njegovu upotrebljivost za potrebe oplemenjivačkih programa u kojima je većina eksperimentalnih parcela manjih dimenzija ( $8-10 \text{ m}^2$ ). Sa druge strane model predložen u okviru ove doktorske disertacije baziran je na podacima koji su dobijeni obradom fotografija visoke rezolucije (i do nekoliko cm/piksela) što omogućava detaljniju analizu oplemenjivačkog materijala.

Kod predloženog modela za predikciju broja biljaka soje pored visoke preciznosti i odgovarajuće robusnosti, uočena su i određena odstupanja između prediktovanih i ručno izbrojanih vrednosti. Greška se javljala u dva pravca, kada model potceni ili preceni broj biljaka koji se zaista nalazi na eksperimentalnoj parceli. Kao glavni razlozi zbog čega je model prediktovao manji broj biljaka/ $\text{m}^2$  izdvajaju se specifična arhitektura biljaka i tehnologija proizvodnje odnosno gustina setve. Imajući u vidu da soja predstavlja usev koji je sklon granjanju a ujedno se seje na svega 3 do 5 cm razmaka u redu, vrlo brzo dolazi do međusobnog preklapanja između pojedinačnih biljaka. Na osnovu toga, moglo bi se zaključiti da bi model kreiran na soji bio precizniji da su kao prediktori korišćeni vegetacioni indeksi iz ranijih faza umesto onih iz V4 i R3. Rezultati drugih studija idu u prilog ovoj tvrdnji budući da su Koh i sar., (2019) postigli veću preciznost ( $R^2 = 0,86-0,88$ ) pri predikciji broja biljaka šafranske na osnovu podataka koji su prikupljeni u fazi 2-4 lista. Sa druge strane izbor faza prilikom kreiranja modela na soji nije obavljen slučajno već upravo zbog toga da bi se izbegle greške u predikciji koje su mogle da se dese iz dva razloga. Da su analize obavljene suviše rano, određen broj biljaka bi usled neujednačenog nicanja bio izuzet što bi dovelo do pogrešnog kalibrisanja modela. Drugi razlog koji bi mogao da bude izvor greške da je model kreiran na osnovu podataka prikupljenih u ranijim fazama je potencijalni gubitak biljaka tokom sezone koji se može javiti kao posledica međurednog kultiviranja ili štetnog uticaja biotičkih i abiotičkih faktora. Sa druge strane situacije u kojima je prediktovani broja biljaka veći od stvarnog najčešće se javljaju zbog postojanja korova na analiziranim parcelama. Njihovo prisustvo se negativno odražava na performanse modela za predikciju broja biljaka budući da povećavaju količinu biljnih piksela na fotografijama (Wilke i sar., 2021). Na osnovu navedenog može se zaključiti da je za maksimalnu preciznost modela neophodno da prilikom procene broja biljaka, parcele za koje se obavlja predikcija budu čiste od korova kako ne bi došlo do ometanja modela.

Predloženi model za predikciju broja biljaka soje pored robusnosti karakteriše i jednostavnost, budući da njegova primena ne zahteva dodatne transformacije fotografija koje su uočene u drugim primerima. U studiji obavljenoj na kukuruzu zabeležena je niska korelacija ( $R^2 = 0,023$ ) između broja zelenih piksela i ručno izbrojanih biljaka (Gnädinger i Schmidhalter, 2017). Tek nakon što je model korigovan na osnovu dodatne obrade prikupljenih fotografija, rezultati su se značajno popravili ( $R^2 = 0,89$ ). Za razliku od navedenog primera, model razvijen u okviru ove doktorske disertacije zasnovan je isključivo na mašinskom učenju i vegetacionim indeksima čije su vrednosti dobijene kombinovanjem podataka o refleksiji iz vidljivog (RGB) dela spektra. Pojedinačni uticaj vegetacionih indeksa prikazan je kroz IncNodePurity pri čemu veće vrednosti ovog pokazatelja ukazuju na

značajniji efekat varijable na krajnji rezultat predikcije (Khun i sar., 2008). U proseku, vrednosti vegetacionih indeksa koje su izračunate u R3 fazi predstavlja su značajnije prediktore nego vrednosti istih indeksa koje su prikupljene ranije, tokom V4 faze. Biljke u R3 fazi su robusnije i sa više listova što je uticalo na povećanje broja zelenih piksela po parceli a time i na indekse koji su dobijeni u tom trenutku. Ipak, prediktori iz V4 faze takođe su imali važnu ulogu u krajnjoj predikciji posebno u slučaju NGRD i ExGR indeksa, što je potvrđeno visokim vrednostima IncNodePurity.

Kreirani model iskorišćen je za procenu broja biljaka po jedinici površine na svim parcelama u okviru ogleda koji su postavljeni tokom 2020. i 2021. godine što je omogućilo sagledavanje efekata uslova spoljašne sredine na vrednosti ovog parametra. Iako je u 2021. godini prosečan broj biljaka/m<sup>2</sup> u svakom ogledu bio veći u poređenju sa identičnim ogledima u 2020. godini, isti trendovi uočeni su u obe godine. Rezultati modela su pokazali da su postojale razlike u brojnosti biljaka između ogleda koji su postavljeni u suši u odnosu na kontrolu. Manji broj biljaka/m<sup>2</sup> zabeležen na eksperimentalnim parcelama soje koja je gajena u sušnim uslovima može biti posledica lošijeg nicanja koje je prouzrokovano nedostatkom vlage na početku vegetacionog perioda (Hamasaki i sar., 2008). Sa druge strane, kontinuirana suša tokom sezone može dovesti do potpunog propadanja biljaka što se takođe negativno odražava na preciznost modela. Bez obzira na razloge smanjenja broja biljka po jedinici površine, predloženi model je prepoznao prisutnu varijabilnost kod analiziranih parcella i time potvrdio svoju robustnost i primenljivost u različitim uslovima sredine.

## 7.2. Model za predikciju pokrovnosti soje

Posedovanje alata za brzu i preciznu procenu pokrovnosti biljaka soje može biti od velikog značaja budući da brzina zatvaranja redova predstavlja veoma važnu osobinu koja utiče na količinu presretnute svetlosti (Purcell, 2000), smanjenje gubitka vode iz zemljišta evaporacijom (Purcell i Specht, 2004) ili konkurentnost gajenog useva prema korovima (Fickett i sar., 2013). Imajući u vidu da biljke najviše svetlosti upijaju pri potpunoj ispunjenosti vegetativnog prostora, poželjno je da gajeni genotipovi što pre postignu maksimalnu pokrovnost koja će se zadržati dovoljno dugo i time omogućiti punu efikasnost procesa fotosinteze (Lee, 2006). Kao svojstvo koje karakteriše visoka heritabilnost i jaka veza sa prinosom (Xavier i sar., 2017), pokrovnost može biti korišćena pri selekciji visokoproduktivnih genotipova soje. U prethodnom istraživanju koje su sproveli Jarquin i sar., (2018) podaci o pokrovnosti oplemenjivačke germplazme soje doprineli su značajnom povećanju preciznosti genomske selekcije. Navedena studija je ujedno pokazala da nema značajne razlike ako se kao kriterijumi za selekciju koriste podaci o pokrovnosti koji su prikupljeni tokom celog vegetacionog perioda ili samo iz početnih faza razvoja. U drugom istraživanju, Moreira i sar. (2019) su takođe utvrdili da prosečna vrednost pokrovnosti iz početnih razvojnih faza može biti uspešno iskorišćena za povećanje genetičke dobiti selekcije kroz rani odabir visokoprinosnih genotipova soje.

Prikupljanje podataka o pokrovnosti danas je olakšano upotrebom savremenih alata kao što su bespilotne letelice i digitalne kamere te analizom prikupljenih fotografija useva. Imajući u vidu da pokrovnost predstavlja projekciju lisne površine na zemljište, predikcioni model kreiran u okviru ove doktorske disertacije zasnovan je na proceni udela biljnih piksela koji ispunjavaju pojedinačne ROI-je odnosno eksperimentalne parcele. Ovakav pristup isključuje potrebu za primenom složenih algoritama mašinskog učenja koji zahtevaju dodatno vreme za obradu (Bosilj i sar., 2018) a u velikom broju slučajeva i određeni nivo ljudskog nadzora (Coy i sar., 2016). Ključni element kod predloženog modela za predikciju pokrovnosti soje odnosi se na pravilnu segmentaciju vegetacije i eliminisanje pozadinskih šumova pomoću kontrasta u boji između biljaka i zemljišta. Od ranije je poznato da se za isticanje biljnih piksela na fotografijama uspešno mogu koristiti RGB vegetacioni indeksi kao što su ExG (Woebbecke i sar., 1995) ili ExG-ExR (Meyer i Neto, 2008). Patrignani i Ochsner (2015) su upravo na osnovu ExG indeksa i odnosa R/G i B/G kanala dobijenih obradom fotografija biljaka, kreirali mobilnu aplikaciju za procenu pokrovnosti useva. Primena navedenog rešenja pokazala se uspešnom za potrebe procene pokrovnosti soje budući da je dobijen visok nivo podudaranja

( $R^2 = 0,94$ ) pri poređenju sa drugim, od ranije poznatim metoda čiji se rad zasniva na količini presretnute svetlosti od strane biljaka (Shepherd i sar., 2018). Budući da upotreba ovog metoda zahteva pojedinačno fotografisanje svake analizirane parcele, njegovi glavni nedostaci u odnosu na model kreiran analizom fotografija dobijenih pomoću bespilotne letelice ogledaju se u manjoj propusnosti i većem učešću radne snage.

Za segmentaciju vegetacije se pored indeksa koji su kreirani na osnovu podataka o refleksiji svetlosti iz vidljivog dela spektra mogu upotrebiti i oni koji su bazirani na NIR svetlosti među kojima se posebno izdvaja NDVI (Nitsch i sar., 1991). Iako je njegova efikasnost prepoznata odavno, NDVI je ranije bio manje korišćen pre svega zbog toga što je dobijanje podataka o refleksiji iz NIR dela spektra bilo ograničeno preskupim uređajima koji nisu imali dovoljnu propusnost. Konstantni tehnički napredak doprineo je razvoju pristupačnijih i sposobnijih bespilotnih letelica koje su opremljene i NIR senzorima pa se NDVI danas često koristi kako za potrebe detekcije pojedinačnih biljaka (Ampatzidis i Parte, 2019) tako i za određivanje same pokrovnosti (de la Casa i sar., 2016). I u našem slučaju, NDVI se pokazao kao veoma koristan za postizanje odgovarajućeg kontrasta između zelene vegetacije i pozadine. Kako biljni materijal reflektuje više NIR svetlosti a upija značajno veću količinu crvenog zračenja u odnosu na zemljište, upotreba NDVI-ja se pokazala veoma efikasnom za potrebe njihove diferencijacije. Da bi se u potpunosti eliminisali nepotrebni šumovi na fotografijama, pored vegetacionih indeksa neophodno je primeniti i neke od *threshold* metoda koji omogućavaju kreiranje binarne slike. Kod modela na soji korišćen je *Otsu* metod koji se zasniva na razdvajanju objekta koji je u prvom planu (biljka) i ostatka pozadine na osnovu histograma sivih piksela. Ovaj način se i u ranijim istraživanjima pokazao kao uspešan alat za segmentaciju zelene vegetacije (Guo i sar., 2013; Haug i sar., 2014).

Na tačnost procene pokrovnosti može uticati više različitih faktora. Jedan od važnih činilaca je i osvetljenje odnosno njegova neujednačenost na pojedinačnim fotografijama. Za prevazilaženje ove vrste problema često se pre određivanja pokrovnosti useva pristupa dodatnoj obradi snimaka (Sadeghi-Tehran i sar., 2017). Jedan od najpoznatijih metoda transformacije slika odnosi se na korišćenje takozvanog  $L^*a^*b^*/CIELAB$  (Trussell i sar., 2005) umesto klasičnog RGB sistema boja. U CIELAB-u,  $L^*$  se odnosi na osvetljenost,  $a^*$  uključuje boju u okviru crveno-zelene ose dok se  $b^*$  odnosi na boju vezanu za plavo zelenu osu (Ly i sar., 2020). Istraživanja sprovedena na pirinču pokazala su visoku preciznost CIELAB metoda za potrebe segmentacije biljaka u uslovima različitog osvetljenja (Bai i sar., 2013). Prilikom kreiranja protokola za procenu pokrovnosti u okviru ove doktorske disertacije izbegнута је захтевна procedura dodatne transformacije prikupljenih slika korišćenjem NDVI i *Otsu* metode što je omogućilo uspešno maskiranje neželjenih objekata (zemljište i korovi) koji nisu predmet analize. Eliminisanje korova sa fotografija često je zahtevnije od odstranjivanja piksela zemljišta. Kada su prisutni, model ih prepoznaje kao biljnu masu i povećava vrednosti pokrovnosti gajenog useva. Kako bi se greška modela svela na što manju meru, važno je da analizirane parcele budu čiste od korova. Konačno, kao važan segment ovog ali i ostalih prediktivnih modela je i precizno pozicioniranje ROI-ja svake parcele. Kod neodgovarajućeg postavljanja ROI-ja, prediktovana pokrovnost može biti niža od stvarne zbog toga što nije došlo do potpunog obuhvatanja svih piksela biljaka na analiziranoj parseli. Sa druge strane, nepravilan ROI jedne parcele može uključiti i vegetativnu masu susednih i tako narušiti preciznost modela. Ovo je posebno bitno prilikom snimanja velikog broja parcela u više vremenskih tačaka tokom sezone. U takvim situacijama, jednom kreirani set ROI-ja koristi se kontinuirano zbog čega automatizacija ove faze predstavlja važan korak koji treba da obezbedi odgovarajuću efikasnost modela prilikom prikupljanja ove vrste podataka. U studiji na soji, visok stepen automatizacije prilikom pravilnog označavanja parcela obezbeđen je upotreborom GCP-a. Navedeni markeri omogućili su da ortomozaici svakog pojedinačnog snimanja u 2020. a onda i u 2021. godini budu ujednačeni po x i y osi čime je osigurano da mreža ROI-ja kreirana na prvom snimku bude uz manje korekcije korišćena i na svim ostalim.

Predloženi model iskorišćen je za praćenje promene pokrovnosti analiziranih genotipova soje u 12 vremenskih tačaka tokom 2020. i 2021. godine. Budući da je biljni materijal ispitivan u kontrolnim i sušnim uslovima, dobijeni podaci su doprineli preciznom sagledavanju dinamike pokrovnosti tokom vegetacionog perioda soje gajene u različitim sredinama. Rezultati su ukazali na postojanje razlike između sušnih uslova i kontrole. Sorte gajene u nepovoljnem okruženju koje je prouzrokovano sušom, sporije su rasle i bile su manje robusne u poređenju sa onim u kontrolnim ogledima. Pored toga, rezultati predikcionog modela su pokazali da je genotipovima gajenim u RS i KS ogledima bilo potrebno više vremena za zatvaranje redova pod uslovom da je do njega i došlo. Ovaj podatak ukazuje da je suša negativno uticala na brzinu dostizanja kao i na trajanje maksimalne pokrovnosti i to posebno kod kasnih sorti odnosno genotipova sa dužim vegetacionim periodom. Ovakvi rezultati bili su očekivani s obzirom da je poznato da nedostatak vlage nepovoljno utiče na produciju lisne mase i samim tim dovodi do smanjenja pokrovnosti kod biljaka (Lewthwaite i Triggs, 2012).

### 7.3. Model za predikciju visine biljaka soje

Visini kao važnom pokazatelju rasta i razvoja biljaka se pridaje velika pažnja prilikom stvaranja novih sorti u okviru oplemenjivačkih programa (Berry i sar., 2014). Budući da je visina pozitivno korelisana sa brojem nodija i mahuna po biljci, ona indirektno utiče i na prinos zrna (Perić, 2009). Sa druge strane genotipovi soje sa izrazito visokim stablom skloni su poleganju koje u zavisnosti od faze u kojoj se javi može dovesti do smanjenja prinosa od 12 do preko 30% (Sarkar i sar., 2023). Imajući u vidu značaj navedene osobine, jedan od ciljeva ove studije bio je kreiranje modela za brzu i efikasnu predikciju visine biljaka soje na osnovu fotogrametrijske obrade snimaka. Rezultati istraživanja koje je sprovedeno tokom dve vegetacione sezone na kalibracionom setu podataka pokazali su da je moguće uspešno predvideti visinu soje analizirajući fotografije koje su prikupljene pomoću multispektralne kamere i bespilotne letelice. Preciznost modela potvrđena je visokim  $R^2$  koji je iznosio 0,92 i niskom greškom ( $RMSE = 6,88 \text{ cm}$ ) pri poređenju prediktovanih i ručno izmerenih vrednosti.

Rezultati predikcije visine biljaka dobijeni pomoću modela kreiranog na soji pokazali su tačnost na nivou koji je sličan onima iz prethodnih istraživanja kod kojih je visina takođe određena na osnovu razlike DMP-a i DMT-a (Villareal i sar., 2020). Upotreba elevacionih modela u cilju određivanja visine biljaka soje pokazala se kao jednostavniji izbor u odnosu na korišćenje LiDAR-a. U istraživanju iz 2021. godine, visina biljaka prediktovana je na osnovu modela visine useva (eng. *crop height model*, CHM) koji je kreiran pomoću podataka prikupljenih LiDAR senzorom montiranim na bespilotnu letelicu (Luo i sar., 2021). Rezultati navedene studije su pokazali da korišćenje aktivnog senzora prilikom determinacije visine soje ima niži predikcioni potencijal ( $R^2 = 0,48$ ) u odnosu na modele bazirane na razlici DMP-a i DMT-a. Preciznost podataka koji su prikupljeni pomoću LiDAR-a najniža je u početnim fazama razvoja biljaka pre svega zato što niska pokrovnost useva smanjuje mogućnost adekvatnog odbijanja laserskog zraka senzora (Guo i sar., 2019). Kod korišćenja elevacionih modela, pokrovnost nema velikog efekta na predikciju visine čime je obezbeđena odgovarajuća preciznost od samog početka vegetacionog perioda.

Primena DMP-a i DMT-a pri određivanju visine biljaka može biti ograničena raznim faktorima poput promene osvetljenja prilikom snimanja useva (Araus i Cairns, 2014). Pored toga, veoma važan činilac koji značajno doprinosi preciznosti modela za predikciju visine biljaka predstavlja korišćenje GCP-a. Upotreba referentnih tačaka nepohodna je za pravilno georeferisanje snimaka kako bi se obezbedila visoka tačnost prilikom procene visine (Hu i sar., 2018). Kod modela kreiranog na soji, primena GCP-a osigurala je da predikcija u svakoj vremenskoj tački bude na visokom nivou što  $RMSE$  vrednosti koje su se kretale od 3,56 cm do 10,17 cm i potvrđuju. Li i sar., (2024) su koristeći elevacione modele i referentne tačke obavili predikciju visine biljaka soje u tri razvojne faze (cvetanje, zametanje mahuna i nalivanje zrna) uz ostvarenu preciznost od  $R^2 = 0,83$  i

$RMSE = 4,7$  cm pri poređenju sa ručno izmerenim vrednostima. U odnosu na navedenu studiju zbirna greška modela kreiranog u okviru ove doktorske disertacije bila je nešto veća ( $RMSE = 6,88$  cm), pre svega zbog toga što je u našem slučaju za kalibraciju modela korišćen veći broj tačaka sa početka vegetacionog perioda. U ranijim fazama razvoja, procena visine na osnovu snimaka je otežana zbog toga što su biljke sitnije a šum prouzrokovani pikselima zemljišta koji su posledica još uvek nesklopljenih redova izraženiji. Sa druge strane ovakav pristup pri kreiranju modela za predikciju visine biljaka osigurao je veću robusnost imajući u vidu da je kalibracija obavljena na materijalu čija je visina bila u rasponu od 12 do 105 cm.

Jedan od faktora koji takođe može uticati na odstupanje između prediktovanih i ručno izmerenih visina je i poleganje glavnog stabla. Kod soje se to najčešće dešava u kasnijim fazama razvoja što smanjuje preciznost kreiranog modela. Negativan efekat poleganja na predikciju visine uočen je u prethodnim istraživanjima na ječmu (Tilly i sar., 2014) i pšenici (Madec i sar., 2017). Da bi se eliminisao ili barem umanjio efekat poleganja, predikciju visine moguće je obaviti i na osnovu podataka o spektralnoj refleksiji. Visina visokog vijuka i luterke određena je na osnovu 11 vegetacionih indeksa zasnovanim na svetlosti iz NIR dela spektra (Payero i sar., 2004). U navedenoj studiji svi vegetacioni indeksi bili su visokokorelirani sa visinom luterke ( $R^2 > 0,9$ ) dok je predikcija visine drugog useva bila značajno manje precizna, sa  $R^2$  vrednostima koje su se kretale između 0,38 i 0,76 zavisno od indeksa. Dobijeni rezultati ukazuju da određivanje visine biljaka bazirano na refleksiji u mnogome zavisi od biljne vrste za koju se model kreira.

U istraživanju na uljanoj repici, predikcija visine biljaka uporedno je obavljena na dva načina; pomoću elevacionih modela i pomoću 13 indeksa od kojih je šest kreirano na osnovu podataka iz vidljivog dela spektra (Xie i sar., 2021). Dobijeni rezultati su pokazali veću preciznost modela koji su bazirani na DMT-u i DMP-u u odnosu na performanse vegetacionih indeksa čije su se  $R^2$  vrednosti kretale u širokom rasponu od 0,042 do 0,73, zavisno od indeksa i faze razvoja. Prilikom kreiranja predikcionog modela u okviru ove doktorske disertacije, podaci o refleksiji upotrebljeni su isključivo za obračun SCI indeksa koji je korišćen za isticanje biljnog materijala prilikom obrade fotografija. Navedeni indeks omogućio je eliminaciju zemljišnih piksela što je bilo od posebnog značaja u ranim fazama razvoja kada još nije došlo do zatvaranja redova lisnom masom. Na taj način osigurana je visoka preciznost modela u različitim fazama razvoja soje bez bojazni da bi ona mogla biti narušena usled pozadinskih šumova.

Robusnost kreiranog modela dodatno je ispitana determinacijom visina svih genotipova koji su ispitivani u okviru RK, RS, KK i KS ogleda tokom 2020. i 2021. godine. Rezultati predikcije su omogućili praćenje toka vegetacionog perioda divergentne germplazme soje sagledavanjem dinamike rasta analiziranih genotipova koji su gajeni u različitim uslovima sredine. Genotipovi iz RK i KK ogleda ne samo da su bili viši, nego su i brže rasli u odnosu na isti materijal koji je bio zastupljen u RS i KS ogledima. Dobijeni podaci samo potvrđuju ranije tvrdnje da nedostatak vlage ima negativan efekat na razvoj useva (Reddy i sar., 2004; Wijewardana i sar., 2017). Rezultati istraživanja iz 2019. godine su pokazali da suša zavisno od intenziteta, može smanjiti visinu biljaka soje i do 33% u odnosu na optimalnu obezbeđenost vodom (Wijewardana i sar., 2019). Podaci koji su prikupljeni u pomenutoj studiji ukazuju da do redukcije usled nepovoljnog dejstva suše dolazi već u ranim fazama razvoja. Do sličnog zaključka može se doći sagledavanjem rezultata koji su dobijeni pomoću modela kreiranog u okviru ove doktorske disertacije. Razlike u prediktovanim visinama između genotipova gajenih u suši i onih u kontroli, počinju da se javljaju već oko 390 GDD i kako sezona odmiče one postaju sve izraženije. Takođe, od tog momenta uočava se veća varijabilnost pojedinačnih vrednosti kod genotipova iz RS i KS ogleda u odnosu na one iz kontrole. Ova pojava ukazuje da su analizirane sorte različito reagovale na nepovoljne uslove sredine, što može ukazivati na potencijalnu tolerantnost određenih genotipova na sušu.

## 7.4. Model za predikciju biomase soje

Kod soje, količina akumulirane organske materije predstavlja važno svojstvo koje je u pozitivnoj vezi sa prinosom (Calviño i sar., 2003). Pored toga na osnovu nakupljene biomase moguće je sagledati stanje useva te količinu presretnute svetlosti od strane biljaka (Maimaitijiang i sar., 2019). Oplemenjivanje usmereno na povećanje prinosu kod novih sorti soje takođe pozitivno utiče i na biomasu. Tamagno i sar. (2020) su utvrdili da je u periodu od 1980. do 2013. godine prinos kod novih sorti rastao u proseku 0,74% a biomasa 0,41% godišnje. Nakupljanje biomase posebno je važno od R1 do R5 faze razvoj soje budući da u je utvrđeno da genotipovi sa većim CGR-om imaju veći potencijal za prinos (Vega i sar., 2001). Imajući u vidu značaj ovog pokazatelja u okviru ove doktorske disertacije kreiran je model za brzu, preciznu i nedestruktivnu procenu biomase soje.

Predikcioni model baziran je na RF i PLSR algoritmima mašinskog učenja te setu prediktora koji su inicijalno činili podaci o visini, pokrovnosti i 31 vegetacioni indeks (PRILOG 2; indeksi označeni sa °) koji su dobijeni obradom fotografija kalibracionih parcela soje. Upotreba komplettnog seta prediktora je i u slučaju RF ( $R^2 = 0,93$ ; MAE = 0,18 kg/m<sup>2</sup>) i PLSR ( $R^2 = 0,94$ ; MAE = 0,18 kg/m<sup>2</sup>) modela omogućila uspešnu procenu biomase soje. Kod velikog broja indeksa zabeležena je visoka međusobna korelacija što je omogućilo redukovanje njihovog broja. Dalje analize ukazale su na mogućnost korišćenja samo TGI i GCI indeksa umesto svih prediktora koji su zasnovani na refleksiji. S obzirom da se radilo o značajnom smanjenju broja varijabli, neophodno je bilo ispitati koliki je uticaj navedena redukcija imala na performanse RF i PLSR modela prilikom predikcije biomase soje. Dobijeni rezultati su pokazali da set prediktora sačinjen od podataka o visini, pokrovnosti i samo dva umesto 31 vegetacionog indeksa nije imala značajnijeg uticaja na preciznost korišćenih modela mašinskog učenja. U odnosu na rezultate dobijene pomoću PLSR modela ( $R^2 = 0,93$ ; MAE = 0,20 kg/m<sup>2</sup>), RF ( $R^2 = 0,94$ ; MAE = 0,17 kg/m<sup>2</sup>) je koristeći redukovani set varijabli imao manju grešku pri predikciji količine akumulirane organske materije zbog čega je odabran kao novi alat za procenu biomase soje.

Ipak i pored visoke preciznosti RF modela, postojale su određene razlike u prediktovanoj i pokošenoj biomasi ( $RMSE = 0,26$  kg/m<sup>2</sup>). Jedan od razloga za ovakva odstupanja u dobijenim rezultatima mogao bi biti u samim prediktorima. Kao glavna varijabla sa najvećim uticajem na performanse modela izdvojila se visina biljaka. Zbog negativnog efekta koji ima na predikciju visine, pisanje može posredno uticati i na smanjenje preciznosti prilikom predviđanja biomase (Zheng i sar., 2019). Za razliku od visine, efekat dva preostala vegetaciona indeksa nije bio podjednak. U odnosu na GCI indeks, prediktor TGI nije imao velikog uticaja na preciznost kreiranog modela. Uticaj GCI-ja može se objasniti time što što su za njegov obračun korišćene vrednosti G i posebno važnog NIR kanala čija je povezanost sa biomasom od ranije poznata (Geng i sar., 2021). Sa druge strane, TGI je baziran na podacima koji se odnose na refleksiju svetlosti u vidljivom delu spektra. Ovaj deo svetlosti ne prodire toliko duboko u biljno tkivo kao NIR (Thompson i sar., 2019; Zhang i sar., 2019a) što može biti razlog zašto je GCI imao veći značaj za predikciju biomase soje u odnosu na TGI. Ovo je posebno važno u kasnijim razvojnim fazama u kojima su biljke više i robusnije, sa mnogo preklopljenih listova što dovodi do zatvaranja redova. Upotreba dodatnih vegetacionih indeksa koji su zasnovani na NIR kanalu ne bi doprinela poboljšanju modela zbog visoke korelacije ( $r > 0,8$ ) između navedenih indeksa i korišćenog GCI-ja. Preciznost modela može biti ugrožena prisustvom korova koji mogu povećati pokrovnost a takođe i dovesti do promene u spektralnoj refleksiji analiziranih parcela. U tom slučaju, model može nepravilno proceniti vrednosti biomase biljaka zbog čega je važno da parcele za koje se obavlja predikcija biomase budu čiste od korova.

U istraživanju sprovedenom na ječmu, procena biomase određena je samo na osnovu visine što je rezultovalo tačnošću od  $R^2 = 0,72$  (Tilly i sar., 2015). Visina je i u ovom slučaju takođe određena pomoću elevacionih modela kreiranjem površinskog modela useva (eng. *crop surface model*, CSM) što je osiguralo visoku preciznost dobijenih podataka u poređenju sa ručno izmerenim vrednostima. Procena biomase isključivo korišćenjem visine pojednostavljuje čitav proces ali može imati i

određene nedostatke. U navedenoj studiji na ječmu, usled odsustva drugih varijabli, nedostaci koji se mogu javiti kod jednog prediktora ne mogu se nadomestiti drugim. Sa druge strane, upotreba više različitih prediktora poput vegetacionih indeksa, visine i pokrovnosti zajedno, može zahtevati više vremena ali obezbeđuje veću tačnost modela. To potvrđuju i Maimaitijiang i sar. (2019) koji su analizirali mogućnost procene akumulirane organske materije soje uz pomoć različitih varijabli. Rezultati navedenog istraživanja su pokazali da se precizniji rezultati predikcije biomase dobijaju istovremenim korišćenjem prediktora koji se zasnivaju na spektralnoj refleksiji i fotogrametriji ( $R^2 = 0,92$ ) nego pri korišćenju samo jedne vrste podataka kao što je prosečna visina ( $R^2 = 0,80$ ). Kombinovani set prediktora uspešno je iskorišćen i za procenu nadzemne mase paradajza (Johansen i sar., 2020). Ukupno šest vegetacionih indeksa, uključujući G-R indeks (Motohka i sar., 2010), NDRE i različite varijacije NDVI-ja su u algoritmu mašinskog učenja korišćeni zajedno sa površinom, dužinom i visinom biljaka. Ovakav pristup predikciji biomase obezbedio je visoku preciznost dobijenih rezultata ( $R^2 = 0,88$ ). Iako je najveći uticaj pri određivanju biomase imala površina biljnog pokrivača, vegetacioni indeksi (naročito G-R) su takođe bili od velikog značaja. Za razliku od istraživanja na soji gde je visina bila presudna, u studiji sprovedenoj na paradajzu ona nije imala veliku ulogu. Ovo može biti objašnjeno različitim tipom rasta kod ove dve biljne vrste. Soju dominantno karakteriše uspravno glavno stablo dok je kod paradajza nadzemna masa položena horizontalno što uslovjava manje variranje u visini između pojedinačnih biljka. Kod drugih biljnih vrsta sa uspravnim rastom, visina je takođe prepoznata kao jedan od ključnih prediktora prilikom određivanja biomase pomoću različitih modela mašinskog učenja (Han i sar., 2019). U navedenom istraživanju za predikciju biomase kukuruza su pored vegetacionih indeksa i visine korišćeni i određeni zapreminske parametri. Inicijalni set prediktora kasnije je redukovana zbog toga što su pojedine varijable bile međusobno visokokorelisane. Odstranjivanje navedenih varijabli je obavljenko kako bi se eliminisao potencijalni uticaj multikolinearnosti na performanse modela i to na isti način kao kod istraživanja koja su sprovedena u okviru ove disertacije na soji. Sve prethodno navedeno ukazuje da je odabir odgovarajućeg seta prediktora koji su specifični za arhitekturu određene biljne vrste od presudnog značaja za uspešno predviđanje biomase.

Model koji je kreiran u okviru ove doktorske disertacije iskorišćen je za predikciju biomase svih 206 genotipova koji su ispitivani tokom 2020. i 2021. godine. Budući da su u svakoj godini vrednosti biomase prediktovane u osam vremenskih tačaka, tok vegetacionog perioda divergentnih genotipova soje gajenih u različitim uslovima sagledan je i po pitanju ovog parametra. Dobijeni rezultati su pokazali da su genotipovi soje akumulirali manje organske materije u RS i KS ogledima u poređenju sa kontrolnim uslovima. Redukcija biomase kao posledica nepovoljnih uslova gajenja mogla se očekivati budući da su slični rezultati već dobijeni u ranijim studijama na soji i kukuruzu (Ge i sar., 2011; Fenta i sar., 2014). Negativan efekat suše kod soje dovodi do smanjenja visine i ukupne lisne površine (Dong i sar., 2019). Štaviše, vodni deficit prouzrokuje promene u spektralnoj refleksiji biljnog tkiva što dovodi do većeg odbijanja svetlosti iz vidljivog dela spektra dok u isto vreme refleksija NIR-a opada (Atti i sar., 2004). Ovo znači da je suša uticala na vrednosti TGI i GCI indeksa u RS i KS ogledima s obzirom da su oni direktno zavisni od refleksije biljaka. Predloženi model za procenu biomase soje prepoznao je promene koje su se desile kod korišćenih prediktora što je dokazano na osnovu varijabilnosti prediktovanih rezultata u ispitivanim okruženjima. Razlika u akumuliranoj biomasi između genotipova gajenih u suši i onih u kontroli posebno je bila uočljiva nakon 390 GDD kako za rane tako i za kasne sorte. Jedan od glavnih razloga zašto je do razdvajanja došlo u tom momentu je taj što je efekat suše počeo osetnije da utiče na visinu koja je označena kao najvažniji prediktor. Ipak, najveće razlike u akumulaciji biomase uočene su nešto kasnije budući da je poznato da se najveća šteta prouzrokovana nedostatkom vlage javlja nakon cvetanja odnosno tokom generativne faze (Pejić i sar., 2011). Dobijeni rezultati pokazali su da kasni genotipovi akumuliraju više organske materije u odnosu na rane što je uglavnom posledica dužeg vegetacionog perioda. Sve prethodno navedeno govori u prilog robusnosti predloženog RF modela koja se temelji na dokazanoj sposobnosti da prepozna drugačije vrednosti biomase soje i to ne samo između različitih uslova gajenja (RS/RK i KS/KK) već i u okviru pojedinačnih ogleda.

## 7.5. Model za predikciju prinosa soje

Povećanje prinosa predstavlja osnovni zadatak oplemenjivača prilikom stvaranja novih sorti soje. Na kraju postupka selekcije koji zahteva mnogo vremena i radne snage, od više stotina pa i hiljada oplemenjivačkih linija, svega nekoliko bude odabранo za priznavanje. Primenom visokopropusne fenotipizacije može se uticati na povećanje genetičke dobiti od selekcije kroz analizu većeg broja genotipova uz precizniju i bržu analizu osobina od interesa (Araus i sar., 2018). Posedovanje modela za predikciju prinosa pružilo bi mogućnost za testiranje performansi analiziranih genotipova soje u ranijim fazama oplemenjivanja, što bi značajno doprinelo poboljšanju efikasnosti celokupnog procesa (Zhou i sar., 2021). Imajući to u vidu, jedan od ciljeva ove doktorske disertacije bio je i kreiranje modela za predikciju prinosa soje za čiji razvoj su korišćeni savremeni alati zasnovani na daljinskoj detekciji i fotogrametriji.

Inicijalni model za procenu prinosa soje kreiran je na osnovu 426 prediktora (broj biljaka po jedinici površine; pokrovnost i 33 vegetaciona indeksa koji su određeni u 12 vremenskih tačaka; dužina trajanja maksimalne pokrovnosti, visine i biomase iz 8 vremenskih tačaka) koji su korišćeni u RF i PLSR algoritmima mašinskog učenja. Predikcija je obavljena za 1113 eksperimentalnih parcela na kojima su u različitim uslovima (suša i kontrola), bili posejani divergentni genotipovi soje okviru RS, RK, KS i KK ogleda. Rezultati oba modela su pokazali sličnu tačnost ( $R^2 = 0,85$ ) s tim što je kod RF-a zabeležena nešto niža greška ( $RMSE = 0,49 \text{ t/ha}$ ) u odnosu na PLSR ( $RMSE = 0,50 \text{ t/ha}$ ) pri poređenju prediktovanog i stvarnog prinosa. Preciznost modela koji su kreirani u okviru ove disertacije bila je veća u odnosu na one iz drugih studija. Maimaitijiang i sar. (2020) su za procenu prinosa soje takođe koristili mašinsko učenje i različite spektralne (vegetacioni indeksi), strukturne (visina i pokrovnost), termalne (temperatura listova) i teksturne (parametri zasnovani na učestalosti piksela biljaka) prediktore iz R3 faze razvoja. U navedenoj studiji koristeći sve prediktore, RF i PLSR su ostvarili sličnu tačnost od  $R^2 = 0,66$ , odnosno  $R^2 = 0,65$ . Isti autori navode da se u njihovom istraživanju prilikom procene prinosa najbolje pokazao DNN (eng. *deep neural network*) algoritam zasnovan na dubokom učenju čija je preciznost iznosila  $R^2 = 0,72$  što je i dalje bitno niže u odnosu na rezultate ostvarene u našem slučaju. Sa druge strane, Zhou i sar. (2021) su uz pomoć CNN-a i podataka o visini i refleksiji iz tri razvojne faze: V6 (šest troliski), R1 i R6 (završetak nalivanja zrna)-R8 uspeli da procene prinos sa tačnošću od  $R^2 = 0,78$ . Očito da je veći broj vremenskih tačaka a samim tim i prediktora koji su korišćeni u pomenutoj studiji uticao i na veću preciznost predikcionog modela. U odnosu na prethodno navedene primere, kod inicijalnog modela koji je kreiran u okviru ove doktorske disertacije korišćen je značajno veći broj varijabli što može biti jedan od razloga za njegovu veću preciznost. Iako dodatne varijable mogu doprineti poboljšanju performansi predikcionog modela, njihova upotreba zahteva dodatno vreme za obradu čime se povećava složenost celokupnog procesa. U našem slučaju, kod finalnog RF modela obavljen je fazno smanjenje broja varijabli kako bi se dobio što efikasniji alat za predikciju prinosa soje.

U prvoj fazi eliminisani su visokokorelirani indeksi nakon čega su kao jedinstveni preostali LAI, NLI, NDRE i TGI a njihove vrednosti dobijene u 12 vremenskih tačaka korišćene su u daljem radu. Smanjenjem broja vegetacionih indeksa od početnih 426 varijabli preostalo je ukupno 78. Koristeći redukovani set prediktora u predloženom RF modelu zadržan je inicijalni nivo preciznosti ( $R^2 = 0,85$ ). Manji broj prediktora omogućio je sagledavanje njihove pojedinačne značajnosti na osnovu %IncMSE i IncNodePurity vrednosti. Koristeći navedene parametre izdvojeno je 10 najvažnijih prediktora (LAI 274, LAI 390, LAI 706, LAI 917, NLI 706, NLI 828, NLI 1130, NDRE 642 i NDRE 828 i dužina trajanja maksimalne pokrovnosti). I nakon ove redukcione faze, preciznost je zadržana na visokom nivou budući da je  $R^2$  vrednost sa početnih 0,85 pala na 0,83 a greška porasla za svega 0,03 t/ha. Konačan set varijabli kreiran je u cilju postizanja maksimalne efikasnosti modela. Imajući u vidu da je 10 prethodno korišćenih prediktora bilo iz udaljenih vremenskih tačaka (najraniji 274 GDD a najkasniji 1130 GDD) finalni model baziran je na samo pet vegetacionih indeksa NLI 706, NLI 828, LAI 706, NDRE 828 i NDRE 642. Na ovaj način omogućena je uspešna predikcija

prinosa soje ( $R^2 = 0,79$  i  $RMSE = 0,58$  t/ha) isključivo na osnovu podataka o spektralnoj refleksiji biljaka koji su prikupljeni u relativno uskom vremenskom intervalu od 186 GDD, koliko iznosi razlika između najranijeg (NDRE 642) i najkasnijeg (NDRE 828) prediktora.

Odabrane varijable koje su se izdvojile kao najznačajnije ukazuju da je prinos soje u najvećoj vezi sa vegetacionim indeksima čije su vrednosti izmerene u drugoj polovini vegetacionog perioda odnosno u generativnoj fazi. Ovo je u skladu sa zaključcima do kojih se došlo i u drugim studijama. Rezultati prethodnog istraživanja na soji ukazali su da je predikcija prinosa najuspešnija kada se za predviđanje koriste vrednosti vegetacionih indeksa koje su prikupljene od faze cvetanja ( $R^2$ ) do nalivanja zrna (R5) (Gao i sar., 2018). Sličan princip uočen je i kod drugih biljnih vrsta poput pšenice, gde je analizirana veza između prinosa i NDVI-ja čije su vrednosti merene tokom čitavog vegetacionog perioda (Adeniyi i sar., 2020). Rezultati navedene studije su pokazali da je najveća korelacija postignuta u fazi zametanja zrna odnosno nakon oplodnje. Značajno je istaći da je svaki od vegetacionih indeksa koji su korišćeni u finalnom modelu kreiranom u okviru ove doktorske disertacije baziran na NIR kanalu, što potvrđuje značaj refleksije svetlosti iz ovog dela spektra za predviđanje prinosa. Ova tvrdnja je u saglasnosti sa rezultatima drugih istraživanja koja su pokazala da se bolji rezultati predikcije prinosa dobijaju upotrebovom indeksa koji su bazirani na NIR svetlosti u odnosu na podatke iz drugih delova spektra (Gianquinto i sar., 2011; Shammi i sar., 2024).

Procena prinosa samo na osnovu refleksije olakšava postupak dobijanja podataka o najvažnijoj agronomskoj osobini tokom sezone. Istovremeno to znači da robustnost predikcionog modela zavisi od dinamike vegetacionih indeksa. Analiza odabralih prediktora pokazala je da kod svakog postoji određena prelomna tačka i kada se ona dostigne dolazi do promene u prinosu analiziranih genotipova soje. Kod NLI indeksa usled male varijabilnosti u zabeleženim vrednostima diferencijacija je nešto teža dok kod ostalih razlike između pojedinačnih merenja ukazuju na jasne promene u prinosu. Rezultati su pokazali generalni trend rasta prinosu sa porastom vrednosti odabralih prediktora. Iako ideja da superiorni genotipovi soje mogu biti odabrani samo na osnovu odabralih vegetacionih indeksa, ovaj podatak ipak treba uzeti sa rezervom. Naime, da bi se ovo potvrdilo neophodna su dodatna testiranja modela u drugim okruženjima, sa novim materijalom kako bi se proverila validnost prediktora. Ovo je od posebnog značaja budući da je kod kreiranog modela za predikciju prinosu soje ipak zabeležen određeni stepen greške. Jedan od razloga koji je doveo do odstupanja je i determinacija realnih vrednosti vegetacionih indeksa koja može biti narušena lisnom masom korova koji mogu uticati na promenu refleksije parcele, dovesti do nerealno velikih vrednosti određenih indeksa i time onemogućiti pravilnu predikciju prinosu (Wahab i sar., 2018). Ipak i pored šumova koji mogu uticati na parametre spektralne refleksije, performanse odabranog RF algoritma ostale su na zavidnom nivou. Kalibracija modela na divergentnoj germplazmi soje analiziranoj u različitim uslovima sredine tokom dve vegetacione sezone omogućila je pokrivanje širokog spektra vrednosti prediktora na kojima se predikcija bazira. Ova činjenica ukazuje na visok nivo robustnosti modela i preporučuje ga kao novi alat za predikciju prinosu soje.

## 7.6. Tumačenje kvantitativnih i kvalitativnih osobina soje dobijenih klasičnom fenotipizacijom

Analize morfoloških parametara genotipova soje gajenih tokom 2020. i 2021. godine su pokazale da je prva fertilna nodija u proseku bila na većoj visini kod kasnih sorti u odnosu na rane, bez obzira da li su biljke gajene u sušnim uslovima ili u kontroli. Do sličnih zapažanja došlo se i u prethodnom istraživanju na istoj biljnoj vrsti koje je pokazalo da visina prve mahune zavisi od grupe zrenja odnosno da se kod sorti sa dužim vegetacionim periodom prva mahuna nalazi na većoj udaljenosti od tla (Edwards i Purcell, 2005). Suša je i u ovom slučaju negativno uticala na sve analizirane genotipove soje smanjivši visinu na kojoj se nalazi prva mahuna i to posebno u 2021. godini kada je redukcija kod obe grupe iznosila oko 3,5 cm. U istraživanju koje je 2019. godine sprovedeno na tri sorte soje, analiziran je efekat različitih faktora na brojne osobine među kojima je i

visina prve mahune (Neugschwandtner i sar., 2019). U navedenoj studiji prosečna visina prve mahune iznosila je 11,6 cm što je manje u odnosu na podatke prikupljene u okviru ove disertacije. Naime, iako su nepovoljni uslovi sredine imali uticaja na ispoljavanje navedene osobine, prosečna udaljenost prve fertilne nodije od tla je u svim ogledima u obe godine istraživanja bila između 12,69 cm i 16,95 cm. Ove vrednosti su iznad uobičajenih koje iznose od 7,5 cm do 12,5 cm (Grabau i Pfeiffer, 1990). Dobijeni podaci ukazuju da analizirane sorte soje sa aspekta tehnologije proizvodnje prvu mahunu obrazuju na odgovarajućoj visini što je važno za smanjenje gubitka semena prilikom kombajniranja.

Razvoj bočnih grana se kod ispitivanog materijala razlikovao zavisno od grupe zrenja. Analiza podataka je pokazala da su se sorte sa kraćim vegetacionim periodom više granale u odnosu na kasne sorte. Ovo je posebno bilo istaknuto u 2021. godini kada je grananje ranih sorti bilo veće i do 20%. Navedeni rezultati su u saglasnosti sa navodima Pierozan Junior i sar. (2015) koji su u okviru svog istraživanja između ostalog analizirali i grananje kod četiri sorte soje različite grupe zrenja. Rezultati navedene studije su pokazali da najmanji broj bočnih grana obrazuju sorte sa najdužim trajanjem vegetacionog perioda. Slični rezultati zabeleženi su i u istraživanju u kom je analiziran efekat različitih setvenih normi na formiranje bočnih grana pri čemu je takođe konstatovano da ranije sorte obrazuju veći broj grana posebno pri manjem broju biljaka po jedinci površine (Xu i sar., 2021). Kada je u pitanju efekat suše na grananje biljaka, rezultati prethodnih studija na soji ukazuju da nedostatak vlage negativno utiče na formiranje bočnih grana (Mirakhori i sar., 2009). Istraživanje sprovedeno u okviru ove doktorske disertacije je pokazalo da osim u slučaju kasnih sorti u 2020. godini, sušni uslovi su prouzrokovali pojačano grananje biljaka u svim ogledima. Veće grananje u RS i KS ogledima posebno je bilo izraženo u 2021. godini kada su biljke gajene u suši u proseku imale 15-20% više bočnih grana nego u kontroli. Jače grananje koje je uočeno u suši može biti posledica manjeg broja biljaka/m<sup>2</sup> koji je zabeležen na parcelama u okviru RS i KS ogleda što je dodatno stimulisalo formiranje bočnih grana.

U pogledu broja zrna po biljci prikupljeni podaci su pokazali da sorte sa dužim vegetacionim periodom imaju značajno veći potencijal u odnosu na rane genotipove. Pored toga, one su se pokazale stabilnije kad je u pitanju produkcija zrna u različitim godinama i u različitim sredinama. To potvrđuju zabeležene vrednosti koje su se kod kasnih genotipova kretale od 56,34 do 68,39 zrna/biljci dok su kod ranih bile u rasponu od 38,56 do 54,05. Od ranije je poznato da broj zrna po biljci predstavlja komponentu prinosa koja umnogome zavisi od spoljašnjih uslova gajenja (Hrustić i sar., 1998). Rezultati prethodnih istraživanja na soji pokazala su da suša negativno utiče na proizvodnju zrna po biljci pri čemu redukcija može biti i preko 26% (Perić i sar., 2013). Podaci o prosečnom broju zrna/biljci koji su prikupljeni u okviru ove doktorske disertacije ukazuju da faktori spoljašnje sredine u 2020. godini nisu imali bitniji efekat budući da nije zabeleženo veće odstupanja između kontrolnih i u sušnih ulova. Nasuprot tome, suša je u narednoj godini značajno redukovala broj zrna po biljci analiziranih genotipova soje pri čemu je redukcija kod ranih iznosila oko 20% a kod kasnih oko 12% u odnosu na kontrolu.

Da su uslovi gajenja bili nepovoljniji u 2021. u odnosu na 2020. godinu, govore i rezultati o prosečnoj masi zrna po biljci. Vrednosti ove osobine su u prvoj godini istraživanja čak i u ogledima u suši (RS i KS) bile veće nego kod genotipova koji su naredne godine gajeni u kontroli. Ipak i pored toga su uočene određene pravilnosti koje su se javile u obe vegetacione sezone. Izuzimajući KS i RS oglede iz 2020. godine, u svim ostalim je zabeležena značajno veća masa zrna po biljci kod kasnih u poređenju sa ranim sortama kao i u kontrolnim u odnosu na sušne uslove. Prosečna masa zrna/biljci u svim ogledima u kojima je bio zastupljen kasni materijal iznosila je 10,13 g a ranog 8,99 g. Teža zrna koja su izmerena kod kasnih genotipova posledica su dužeg perioda nalivanja semena koji je omogućen dužim vegetacionim periodom. Do sličnih rezultata došli su i autori Nenadić i sar. (2013) koji su analizirajući tri sorte soje različite grupe zrenja (0, I i II) takođe ustanovili da masa zrna po biljci raste sa produženjem vegetacionog perioda. Suša je u 2020. godini redukovala prinos zrna po biljci za oko 5,5% kod ranih i oko 10% kod kasnih genotipova soje. Naredne godine negativan efekat nedostatka vlage bio je još izraženiji pa je prinos u RS ogledu bio za oko 26,5% a u KS za oko 23%

manji u odnosu na kontrolne oglede. Dobijeni rezultati u skladu su sa prethodnim istraživanjima u kojima je takođe zabeleženo da suša ima negativan efekat na prinos zrna soje po biljci (Srebrić i Perić, 2014).

U okviru ovog istraživanja rezultati su pokazali da je veća masa 1000 zrna zastupljena kod ranih sorti. Da je ova osobina veoma uslovljena grupom zrenja govori činjenica da su sorte sa kraćim vegetacionim periodom koje su gajene u sušnim uslovima imale veću masu 1000 semena i od kasnih genotipova koji su gajeni u kontroli. Pored toga, kod ranih genotipova osim krupnijeg semena zabeležena je i nešto veća tolerantnost na sušu. Nepovoljni uslovi sredine su kod ove grupe masu 1000 semena redukovali u proseku za oko 5% dok je kod kasnih sorti smanjenje bilo duplo veće u odnosu na kontrolu. Iako se efekat suše razlikovao u zavisnosti od grupe zrenja, nesumnjiv je njen negativan uticaj i na ovaj činilac prinosa. Dobijeni rezultati u skladu su sa istraživanjem Chowdhury i sar. (2016) u okviru kog je utvrđeno da nedostatak vlage može smanjiti težinu 1000 zrna i do 26% u odnosu na uslove optimalne obezbeđenosti vodom. Pored toga veoma je važno i u kom momentu vegetacionog perioda se suša javila. U okviru studije na soji iz 2018. godine analiziran je uticaj suše u četiri razvojne faze (nicanje, grananje, cvetanje-zametanje mahuna i nalivanje zrna) na masu 1000 zrna (Wei i sar., 2018). Rezultati navedenog istraživanja su pokazali da nedostatak vlage u fazi nalivanja zrna može smanjiti masu 1000 semena i do 50% čime se ističu veće posledice suše u kasnjim fazama razvoja biljaka.

Budući da su vrednosti gotovo svih osobina koje utiču na formiranje prinosa bile niže u 2021. godini, tako je i sam prinos analiziranih genotipova soje bio manji u odnosu na 2020. godinu. Posmatrajući pojedinačne proizvodne sezone, podaci ukazuju na veću produktivnost kasnih sorti (2,2 t/ha; prosek svih ogleda) u poređenju sa ranim materijalom (1,83 t/ha; prosek svih ogleda). Od ranije je poznato da genotipovi sa dužim vegetacionim periodom imaju veći potencijal za prinos (Arslan i sar., 2006; Glamočlija i sar., 2010). Jedan od razloga za to krije se u tome što nalivanje zrna kod kasnih sorti traje veći broj dana u odnosu na rane. Sa druge strane, kasne sorte su takođe podložnije suši što potvrđuju i rezultati koji su prikupljeni u okviru ove doktorske disertacije. Genotipovi iz KS ogleda su u obe godine istraživanja imali skoro duplo niži prinos u odnosu na kontrolu dok je kod ranih sorti zabeležen manji pad koji se kretao od 16,5% do 25%. To je dovelo do toga da su u suši sorte sa kraćim vegetacionim periodom u 2020. godini ostvarile značajno veći prinos u odnosu na kasni materijal. Dobijeni rezultati u skladu su sa istraživanjem koje su sproveli Mandić i sar. (2020) u okviru kog je tokom dve godine (jedna godina okarakterisana kao sušna) analiziran efekat nedostatka vlage na prinos tri sorte različite grupe zrenja (0, I i II). Navedena studija je pokazala da je najmanju tolerantnost na sušu koja se manifestovala najvećim smanjenjem prinosa imala sorta sa najdužim vegetacionim periodom. Manja osjetljivost ranih genotipova na stresne uslove koji su prouzrokovani nedostatkom vode može biti objašnjena time što ove sorte kritične faze razvoja prolaze nešto ranije, pre nastupanja najsušnijeg perioda koji je najčešće praćen i visokim temperaturama. Analize obavljene u ovoj disertaciji su pokazale da najprinosnije sorte gajene u povoljnim okruženjima (RK i KK) nisu uspele da zadrže podjednako visoku produktivnost i u suši. Ovakva saznanja su od velikog značaja za donošenje prave odluke o izboru odgovarajućeg sortimenta prilikom zasnivanja proizvodnje ali i za proces stvaranja novih sorti u okviru oplemenjivačkih programa. Takođe, važno je napomenuti da su se u okviru kasne grupe, sorte novosadskog Instituta za ratarstvo i povtarstvo posebno istakle kao vodeće kako u optimalnim tako i u uslovima nedostatka vlage, čime se ističe njihova robusnost u različitim okruženjima.

Rezultati analize kvaliteta semena ispitivanih genotipova soje pokazali su stabilne vrednosti kada je u pitanju hemijski sastav zrna. Podaci su pokazali da grupa zrenja ima veći uticaj na sadržaj proteina i ulja u zrnu dok je efekat uslova sredine manje značajan. Prosečan sadržaj proteina u ogledima sprovedenim tokom dvogodišnjeg istraživanja kretao se od 42,28% do 44,54% dok je sadržaj ulja bio između 19,25% i 20,7% u odnosu na suvu materiju zrna. Izmerene vrednosti sadržaja proteina značajno su veće u odnosu na podatke do kojih su došli MacMillan i Gulden (2020) u svojoj studiji. U navedenom trogodišnjem istraživanju koje je sprovedeno u Kanadi, prosečan sadržaj

proteina u zrnu soje bio je nešto iznad 34%. Ovakva razlika je očekivana budući da je od ranije poznato da tehnološki kvalitet soje opada sa povećanjem geografske širine (Hburgh i sar., 1990). Varijabilnost hemijskog sastava semena koja je uočena kod sorti koje su analizirane u okviru ove doktorske disertacije u značajno većoj meri je posledica razlika uočenih između grupa zrenja nego između uslova gajenja. U prilog tome govore vrednosti maksimalnog odstupanja rezultata za sadržaj proteina u kontrolnim i sušnim uslovima koje je iznosilo 0,6% dok je najveća razlika između ranih i kasnih genotipova bila 1,95%. Sličan trend zabeležen je i kod procentualnog udela ulja u zrnu. Na osnovu obavljenih analiza jasno je utvrđeno da sorte sa kraćim vegetacionim periodom imaju značajno veći sadržaj proteina u zrnu u odnosu na kasne sorte. Navedena tvrdnja je u skladu sa istraživanjem Randelović i sar. (2010) koji takođe ističu veće vrednosti proteina kod ranog sortimenta. Nasuprot tome, procentualni udio ulja u zrnu ispitivanih genotipova soje bio je veći kod kasne germplazme. Dobijeni rezultati razlikuju se od zaključaka do kojih su došli Jovanović i sar. (1992), koji navode da kasne sorte imaju niži sadržaj ulja u zrnu odnosu na rane. I pored uočenih razlika, ističe se podatak da je prosečni sadržaj proteina u svakom ogledu bio iznad 42% a ulja oko 20% što ukazuje na značajan potencijal analiziranih sorti kada je u pitanju kvalitet semena. To se posebno odnosi na određene sorte sa izrazito visokim vrednostima ovih parametara koje mogu biti posebno interesantne kako za proizvođače tako i za rad oplemenjivača.

## 7.7. Selekcija superiorne germplazme soje na osnovu klasične i visokopropusne fenotipizacije

Potencijal visokopropusne fenotipizacije u procesu odabira najboljih linija koje nastaju nakon planske hibridizacije roditelja može biti iskorišćen za uključivanje novih i/ili lakše određivanje osobina koje su već prate u okviru oplemenjivačkih programa. Iako visokopropusna fenotipizacija zasnovana na daljinskoj detekciji i fotogrametriji može zahtevati relativno visoka inicijalna ulaganja, dugoročno gledano ona predstavlja efikasniju alternativu tradicionalnom (ručnom) načinu prikupljanja podataka. O tome svedoče i rezultati istraživanja koje su sprovedeni Reynolds i sar. (2019) u kom se navodi da upotreba bespilotnih letelica za potrebe snimanja jedne eksperimentalne parcele iznosi svega 0,29\$ po danu.

Efikasnost i preciznost različitih senzora do sada je iskorišćena za prikupljanje podataka o rastu i razvoju brojnih biljnih vrsta poput pamuka (Andrade-Sanchez i sar., 2013), soje (Bai i sar., 2016) i pšenice (Crain i sar., 2016). Uprkos sve većoj primeni digitalnih tehnologija, većina istraživanja bazirana je na podacima u jednoj vremenskoj tački (Han i sar., 2018) čime se ograničava dobijanje potpune informacije o samoj osobini i njenoj interakciji sa ostalim svojstvima. Zbog toga je u okviru ove doktorske disertacije bliže sagledana veza između vremenskih podataka visokopropusne fenotipizacije i morfoloških, proizvodnih i tehnoloških karakteristika ispitivanih genotipova.

Dobijeni rezultati korelace analize su pokazali da jačina veze između osobina tehnološkog kvaliteta (sadržaj proteina i ulja), komponenti prinosa i prinosa sa jedne i vrednosti pokrovnosti, visine i biomase sa druge strane zavisi od razvojnih faza u kojima su podaci prikupljeni. Kao primer može se uzeti odnos prinosa i prediktovanih vrednosti pokrovnosti tokom sezone. Naime, ako se izuzme prva vremenska tačka (103 GDD) jasno se vidi da je veza između ove dve osobine niža u početnim fazama, nakon čega dostiže maksimum ( $r = 0,4$ ) polovinom vegetacionog perioda (474-706 GDD) a posle toga ponovo opada. Navedeni rezultati saglasni su sa istraživanjem autora Jarquin i sar. (2020) koji navode približno iste maksimalne vrednosti korelacionog koeficijenta ( $r = 0,33-0,44$ ) između prinosa i pokrovnosti koje su takođe dostignute sredinom sezone. Sličan princip zabeležen je i između visine biljaka u zrenju i prediktovanih vrednosti biomase, s tom razlikom što se u ovom slučaju nakon dostizanja maksimalnih vrednosti Pirsonovog koeficijenta korelacije one zadržavaju na istom nivou sve do poslednje vremenske tačke. Veza između mase i broja zrna po biljci i pokrovnosti je u skoro svakoj tački do 474 GDD negativna a nakon toga skoro da i ne postoji.

Prosečan broj grana imao je negativne vrednosti korelacionog koeficijenta sa visinom i pokrovnošću u gotovo svim vremenskim tačkama. Ovi rezultati samo potvrđuju tvrdnje prethodnih autora koji navode da je broj grana obrnuto srazmeran visini glavnog stabla i gustini setve (Mellendorf, 2011).

Poznato je da su sadržaj proteina i ulja u zrnu soje negativno korelisani odnosno da sa povećanjem sadržaja proteina, procenat ulja opada (Rotundo i sar., 2016). Imajući to u vidu, ne čudi podatak da je i odnos ove dve osobine prema vrednostima dobijenim pomoću visokopropusne fenotipizacije suprotan. Bliže rečeno, ako je neka prediktovana osobina u pozitivnoj vezi sa sadržajem proteina onda je u negativnoj sa procentualnim udelom ulja i obrnuto. Takođe, kada su u pitanju parametri kvaliteta, ponovo je u proseku jača veza postignuta sa podacima o prediktovanim vrednostima iz ranijih vremenskih tačaka, posebno kada su u pitanju pokrovnost i biomasa a nešto manje visina.

Za razliku od tri osobine čiji su vrednosti prikupljene u različitim momentima tokom vegetacionog perioda, prediktovani broj biljaka po jedinici površine je određen kao jedinstvena vrednost na osnovu podataka o refleksiji u V4 i R3 fazama razvoja soje. Ipak i ovaj podatak se u velikoj meri podudara sa ostalima, pri čemu su se vrednosti korelacionog koeficijenta kretale od -0,3 do 0,3. Dobijeni rezultati pokazuju da je broj biljaka/m<sup>2</sup> bio negativno korelisan sa prinosom, masom 1000 zrna, masom zrna po biljci, brojem zrna po biljci i sadržajem ulja dok je uočena pozitivna veza sa procentualnim udelom proteina u zrnu, brojem grana i visinom prve mahune. Takođe treba istaći da nije uočena povezanost između broja biljaka i visine biljaka u zrenju budući da je vrednost korelacionog koeficijenta bila 0. Izmerene vrednosti samo su delimično saglasne sa podacima drugih istraživanja. U prethodnoj studiji na soji, Gulluoglu i sar. (2017) takođe ističu pozitivnu korelaciju između broja biljaka po jedinici površine i visine prve mahune dok u većini slučajeva setvena norma nema značajnijeg uticaja na masu 1000 zrna. Sa druge strane, isti autori navode da povećanje broja biljaka/m<sup>2</sup> pozitivno utiče na prinos, visinu biljaka u zrenju i broj zrna po biljci a negativno na broj grana što je u suprotnosti sa rezultatima našeg istraživanja.

Odnos između četiri kvantitativna pokazatelja dobijena pomoću predikcionih modela i pojedinih morfoloških, proizvodnih i tehnoloških osobina soje bio je raznolikog karaktera ali je ipak kod većine zabeležena određena veza. To ukazuje na potencijal korišćenja digitalnih tehnologija i mašinskog učenja za ranu procenu oplemenjivačkog materijala i efikasniju produkciju čistih linija prilikom odabira superiornih genotipova soje. O tome svedoče brojne studije u okviru kojih su kreirani različiti protokoli za evaluaciju oplemenjivačkog materijala tokom procesa selekcije. Neki od njih su vezani za osobine koje posredno utiču na performanse genotipova kao što su pravilno određivanje datuma zrenja (Narayanan i sar., 2019) ili poleganja useva (Sarkar i sar., 2023). Pored toga uveliko se testira mogućnost selekcije superiornih genotipova soje isključivo na osnovu mašinskog učenja i podataka daljinske detekcije. Jedan od primera je i istraživanje Zhou i sar. (2022) u kojem je postignut visok stepen poklapanja (preko 70%) između linija koje su odabrane na tradicionalan način od strane oplemenjivača i pomoću modela za procenu prinosa kreiranog na osnovu podataka dobijenih obradom fotografija biljaka.

Kombinujući podatke klasične i visokopropusne fenotipizacije obavljena je selekcija superiorne germplazme soje na osnovu dve strategije. Prva se odnosila na kontrolne uslove i odabir visokoprinosnih genotipova sa povoljnim vrednostima osobina koje su važne sa tehničkog aspekta žetve. Visina biljaka kao i udaljenost prve mahune od tla, predstavljaju veoma značajna svojstva koja mogu imati veliki uticaj na gubitke u žetvi. Pored visokog prinosa, zadata optimalna visina prve mahune (15-20 cm) uočena je kod tri sorte NS Vasa, Tajfun i NS Kraljica a odgovarajuća visina biljaka (100-110 cm) kod sorti Dumbar i NS Vasa. Drugi princip podrazumevao je selekciju genotipova koji su se i u kontrolnim i u sušnim uslovima izdvojili na osnovu sadržaja proteina i mase 1000 zrna, dva važna pokazatelja tehnološkog kvaliteta semena. U oba okruženja visok procentualni ideo proteina u zrnu zabeležen je kod sorte Zolta Przebedowska dok se Toyomusume istakao kao genotip sa izrazito krupnim semenom. Sorte soje koje su izdvojene na osnovu pomenutih strategija

imaju veliki potencijal za korišćenje u budućim oplemenjivačkim programima kao izvor elitnih osobina. Na ovaj način doprinosi se povećanju preciznosti i efikasnosti procesa selekcije čiji je krajnji cilj stvaranje novih superiornih sorti soje.

Studija na soji sprovedena u okviru ove disertacije predstavlja pionirski poduhvat na našim prostorima na osnovu kog je obavljena karakterizacija divergentne germplazme soje iz drugačije perspektive, na inovativan i savremen način. Dobijeni rezultati bi mogli da doprinesu boljem razumevanju procesa rasta i razvoja koji se odvijaju tokom vegetacionog perioda soje. Pored praktičnog značaja koji je prikazan kroz kreirane modele za predikciju važnih kvantitativnih osobina, ovo istraživanje pružilo je uvid u mogućnosti korišćenja daljinske detekcije i fotogrametrije za potrebe oplemenjivanja soje te predstavlja dobru osnovu za dalji rad u oblasti visokopropusne fenotipizacije.

## 8. ZAKLJUČAK

U četvorogodišnjoj studiji, podaci dobijeni obradom fotografija koje su prikupljene pomoću bespilotne letelice i digitalne kamere iskorišćeni su za potrebe kreiranja modela za visokopropusnu fenotipizaciju važnih kvantitativnih osobina soje. Kalibrisanje modela je obavljeno na divergentnoj germplazmi koju su sačinjavali genotipovi sa različitim morfološkim, tehnološkim i proizvodnim karakteristikama. Rezultati višegodišnjeg istraživanja doveli su do ispunjenja ciljeva koji su postavljeni u okviru doktorske disertacije te omogućili izvođenje sledećih zaključaka:

- Na osnovu daljinske detekcije i fotogrametrijske analize digitalnih fotografija analiziranih genotipova soje koje su pomoću bespilotne letelice prikupljene tokom vegetacionog perioda, kreirani su pouzdani modeli za predikciju broja biljaka po jedinici površine, pokrovnosti, visine, biomase i prinosa.
- Modeli za visokopropusnu fenotipizaciju soje koji su kreirani i ocenjeni na osnovu analize odabralih genotipova omogućili su uspešnu procenu parametara rasta i svih ostalih genotipova u okviru postavljenih ogleda.
- Svi modeli su kreirani na osnovu prediktora iz dvogodišnjih istraživanja pri čemu su modeli za pokrovnost, visinu, biomasu i prinos razvijeni pomoću podataka koji su prikupljeni na biljnem materijalu posejanom na dva tipa zemljišta. Višegodišnja istraživanja sprovedena u različitim uslovima gajenja, omogućila su ispoljavanje varijabilnosti u vrednostima prediktora korišćenih za kreiranje predikcionih modela. Na ovaj način, osigurana je robusnost modela budući da su pokazali pouzdane rezultate u svim ispitivanim okruženjima.
- Za potrebe kreiranja modela za predikciju broja biljaka po jedinici površine, kao prediktori su isključivo korišćeni vegetacioni indeksi odnosno podaci o spektralnoj refleksiji. Kod pokrovnosti i visine, indeksi su upotrebljeni za filtraciju biljnih piksela a sama predikcija zasnovana je na fotogrametrijskoj obradi snimaka. U modelu za predikciju biomase pored prediktora koji su bazirani na refleksiji svetlosti upotrebljeni su i podaci o pokrovnosti i visini. Konačno, pri razvoju modela za predikciju prinosa soje korišćen je set prediktora koji se sastojao od vegetacionih indeksa i varijabli dobijenih pomoću prethodno kreirana četiri modela za visokopropusnu fenotipizaciju.
- Predikcija broja biljaka po jedinici površine i biomase bazirana je na RF algoritmu mašinskog učenja koji je obezbedio visoku preciznost prilikom poređenja ručno izbrojanih i prediktovanih vrednosti ove dve osobine ( $R^2 = 0,76$ ) i ( $R^2 = 0,94$ ).
- Kreirani modeli za visokopropusnu fenotipizaciju kvantitativnih osobina soje uspešno su iskorišćeni za određivanje ovih parametara i kod ostalih genotipova koji su testirani u okviru druge faze istraživanja. Na ovaj način upotreboom daljinske detekcije i fotogrametrije obavljena je karakterizacija velikog broja sorti soje.
- Dinamička promena parametara rasta analiziranih genotipova soje sagledana je na osnovu podataka dobijenih pomoću kreiranih predikcionih modela. U obe vegetacione sezone pokrovnost je određena u 12 a visina i biomasa u osam vremenskih tačaka koje su izražene u vidu GDD-a. Na osnovu prediktovanih vrednosti navedenih osobina koje su određene u različitim vremenskim tačkama omogućeno je praćenje toka vegetacionog perioda divergentne germplazme soje gajene u različitim uslovima.
- Na osnovu korelace analize je utvrđen odnos između podataka o broju biljaka/m<sup>2</sup>, pokrovnosti, visini i biomasi koji su dobijeni pomoću predikcionih modela i pojedinih morfoloških, proizvodnih i kvalitativnih osobina soje. Zabeležene vrednosti Pirsonovog korelacionog koeficijenta između navedenih pokazatelja bile su u rasponu od -0,5 do 0,5 što ukazuje na potencijal visokopropusne fenotipizacije za ranu karakterizaciju oplemenjivačkog materijala.

- Podaci dobijeni pomoću klasične i visokopropusne fenotipizacije iskorišćeni su za poređenje genotipova soje koji su analizirani tokom druge faze istraživanja. Najpre su u svakom okruženju (suša i kontrola) izdvojene sorte koje su ostvarile najbolje rezultate na osnovu proučavanih osobina. Na osnovu dobijenih podataka i dve strategije od kojih je jedna bila usmerena na prinos a druga na kvalitet, obavljena je finalna selekcija superiorne germplazme soje. Prema prvoj strategiji, genotipovi koji su pored visokog prinosa imali i optimalnu visinu prve mahune (15-20 cm) bili su NS Vasa, Tajfun i NS Kraljica a odgovarajuću visinu biljaka (100-110 cm) Dumbar i NS Vasa. Kod drugog principa selekcije odabrani su genotipovi koji su se i u kontrolnim i u sušnim uslovima izdvojili na osnovu sadržaja proteina i mase 1000 zrna. Po pitanju sadržaja proteina odabrana je sorta Zolta Przebedowska a po pitanju mase 1000 semena sorta Toyomusume. Odabrani genotipovi su pokazali veliki potencijal i kao takvi bi mogli biti uključeni u oplemenjivačke programe kao nov izvor elitnih osobina.

## 9. LITERATURA

- Abebe, A.M., Kim, Y., Kim, J., Kim, S.L., Baek, J. (2023). Image-based high-throughput phenotyping in horticultural crops. *Plants*, 12, 2061.
- Aber, J. S., Marzolff, I., Ries, J. B. (2010). Small-format aerial photography: Principles, techniques and geoscience applications. Elsevier Science, 21-32.
- Adeniyi, O.D., Szabo, A., Tamás, J., Nagy, A. (2020). Wheat yield forecasting based on landsat ndvi and savi time series. *Preprints*, 2020070065.
- Afonnikov, D.A., Genaev, M.A., Doroshkov, A.V., Komyshev, E. G., Pshenichnikova, T. A. (2016). Methods of high-throughput plant phenotyping for large-scale breeding and genetic experiments. *Russian Journal of Genetics*, 52, 688-701.
- AgiSoft PhotoScan Professional (version 1.7.2.) (Software). (2021\*). Retrieved from <http://www.agisoft.com/downloads/installer/>.
- Ahmar, S., Gill, R.A., Jung, K., Faheem, A., Qasim, M.U., Mubeen, M., Zhou, W. (2020). Conventional and molecular techniques from simple breeding to speed breeding in crop plants: Recent advances and future outlook. *International Journal of Molecular Sciences*, 21, 2590.
- Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., Notarnicola, C. (2015). Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. *Remote Sensing*, 7.
- Al-Tamimi, N., Brien, C., Oakey, H., Berger, B., Saade, S., Ho, Y.S., Schmöckel, S.M., Tester, M., Negrão, S. (2016). Salinity tolerance loci revealed in rice using high-throughput non-invasive phenotyping. *Nature Communications*, 7, 13342.
- Amiteye, S. (2021). Basic concepts and methodologies of DNA marker systems in plant molecular breeding. *Heliyon*, 7(10), e08093.
- Ampatzidis, Y., Partel, V. (2019). UAV-based high-throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. *Remote Sensing*, 11, 410.
- Anderson, E.J., Ali M.L., Beavis, W.D., Chen, P., Clemente, T.E., Diers, B.W., Graef, G.L., Grassini, P., Hyten, D.L., McHale, L.K., Nelson R.L., Parrott, W.A., Patil, G.B., Stupar, R.M., Tilmon, K.J. (2019). Soybean [*Glycine max* (L.) Merr.] breeding: History, improvement, production and future opportunities. In: Al-Khayri, J., Jain, S., Johnson, D. eds. *Advances in plant breeding strategies: Legumes*. Springer, Cham, 391-426.
- Andrade-Sánchez, P., Gore, M. A., Heun, J. T., Thorp, K. R., Carmo-Silva, A. E., French, A. N., Salvucci, M.E., White, J.W. (2013). Development and evaluation of a field-based high-throughput phenotyping platform. *Functional Plant Biology*, 41, 68-79.
- Araus, J. L., Cairns, J. E. (2014). Field high-throughput phenotyping: The new crop breeding frontier. *Trends in Plant Science*, 19(1), 52-61.
- Araus, J. L., Kefauver, S. C., Zaman-Allah, M., Olsen, M. S., Cairns, J. E. (2018). Translating high-throughput phenotyping into genetic gain. *Trends in Plant Science*, 23, 451-466.
- Archer, E. (2022). rfPermute: Estimate permutation p-values for random forest importance metrics. R package (version 2.5.1.).
- Arslan, M., Isler, N., Caliskan, S. (2006). Effects of cultivar maturity on growth and yield of double cropped soybean. *Acta Agriculturae Scandinavica, Section B-Soil & Plant Science*, 56(1), 39-46.

- Atti, S., Bonnell, R., Smith, D., Prasher, S. (2004). Response of an indeterminate soybean (*Glycine max* (L.) Merrill) to chronic water deficit during reproductive development under greenhouse conditions. Canadian Water Resour Journal/Revue Canadienne des ressources hydrauliques, 29(4), 209-22.
- Avtar, R., Watanabe, T. (2020). Unmanned aerial vehicle: Applications in agriculture and environment. Springer.
- Bai, D., Li, D., Zhao, C., Wang, Z., Shao, M., Guo, B., Liu, Y., Wang, Q., Li, J., Guo, S., Wang, R., Li, Y., Qiu, L., Jin, X. (2022). Estimation of soybean yield parameters under lodging conditions using RGB information from unmanned aerial vehicles. Frontiers in Plant Science, 13, 1012293.
- Bai, G., Ge, Y. F., Hussain, W., Baenziger, P. S., Graef, G. (2016). A multisensor system for high-throughput field phenotyping in soybean and wheat breeding. Computers and Electronics in Agriculture, 128, 181-192.
- Bai, H., Purcell, L.C. (2018). Aerial canopy temperature differences between fast- and slow-wilting soya bean genotypes. Journal of Agronomy and Crop Science, 204(3), 243-251
- Bai, X. D., Cao, Z. G., Wang, Y., Yu, Z. H., Zhang, X. F., Li, C. N. (2013). Crop segmentation from images by morphology modeling in the CIE L\*a\*b\* color space. Computers and Electronics in Agriculture, 99, 21-34.
- Bajgain, R., Kawasaki, Y., Akamatsu, Y., Tanaka, Y., Kawamura, H., Katsura, K., Shiraiwa, T. (2015). Biomass production and yield of soybean grown under converted paddy fields with excess water during the early growth stage. Field Crops Research, 180, 221-227.
- Ballester, C., Hornbuckle, J., Brinkhoff, J., Smith, J., Quayle, W. (2017). Assessment of in-season cotton nitrogen status and lint yield prediction from unmanned aerial system imagery. Remote Sensing, 9(11), 1149.
- Banerjee, B.P., Joshi, S., Thoday-Kennedy, E., Pasam, R.J., Tibbits, J., Hayden, M., Spangenberg, G., Kant, S. (2020). High-throughput phenotyping using digital and hyperspectral imaging-derived biomarkers for genotypic nitrogen response. Journal of Experimental Botany, 71(15), 4604-4615.
- Basal, O., Szabo, A. (2020). Physiomorphology of soybean as affected by drought stress and nitrogen application. Scientifica, 2020, 6093836.
- Bastiaans, L., Paolini, R., Baumann, D. T. (2008). Focus on ecological weed management: What is hindering adoption? Weed Research, 48(6), 481-491.
- Bastidas, A.M., Setiyono, T.D., Dobermann, A., Cassman, K.G., Elmore, R.W., Graef, G.L., Specht, J.E. (2008). Soybean sowing date: The vegetative, reproductive, and agronomic impacts. Crop Science, 48, 727-740.
- Bauer, M.E., Cipra, J.E. (1973). Identification of agricultural crops by computer processing of ERTS-MSS data. Proceedings of the Symposium on Significant Results from ERTS-I, NASA SP-327, Washington, D.C., 205-212.
- Beisel, N. S., Callaham, J. B., Sng, N. J., Taylor, D. J., Paul, A.L., Ferl, R. J. (2018). Utilization of single-image normalized difference vegetation index (SI-NDVI) for early plant stress detection. Applications in Plant Sciences, 6(10), e01186.
- Bellaloui, N., Smith, J.R., Ray, J.D., Gillen, A.M. (2009). Effect of maturity on seed composition in the early soybean production system as measured on near-isogenic soybean lines. Crop Science, 49, 608-620.

Bendig, J., Willkomm, M., Tilly, N., Gnyp, M.L., Bennertz, S., Qiang, C., Miao, Y., Lenz-Wiedemann, V.I.S., Bareth, G. (2013). Very high resolution crop surface models (CSMs) from UAV-based stereo images for rice growth monitoring in Northeast China. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 40, 45-50.

Berry, P. M., Kendall, S., Rutherford, Z., Orford, S., Griffiths, S. (2014). Historical analysis of the effects of breeding on the height of winter wheat (*Triticum aestivum*) and consequences for lodging. Euphytica, 203(2), 375-383.

Berveglieri, A., Imai, N.N., Watanabe, F.S.Y., Tommaselli, A.M.G., Ederli, G.M.P., de Araújo, F.F., Lupatini, G.C., Honkavaara, E. (2024). Remote prediction of soybean yield using UAV-based hyperspectral imaging and machine learning models. AgriEngineering, 6, 3242-3260.

Bokhorst, S.F., Tømmervik, H., Callaghan, T.V., Phoenix, G.K., Bjerke, J.W. (2012). Vegetation recovery following extreme winter warming events in the sub-Arctic estimated using NDVI from remote sensing and handheld passive proximal sensors. Environmental and Experimental Botany, 81, 18-25.

Bongomin, O., Lamo, J., Guina, J.M., Okello, C., Ocen, G.G., Obura, M., Alibu, S., Owino, C.A., Akwero, A., Ojok, S. (2024). UAV image acquisition and processing for high-throughput phenotyping in agricultural research and breeding programs. The Plant Phenome Journal, 7(1), e20096.

Boon, M.A., Drijfhout, A.P., Tesfamichael, S. (2017). Comparison of a fixed-wing and multi-rotor UAV for environmental mapping applications: A case study. ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences.

Borra-Serrano, I., De Swaef, T., Quataert, P., Aper, J., Saleem, A., Saeys, W., Somers, B., Roldán-Ruiz, I., Lootens, P. (2020). Closing the phenotyping gap: high resolution UAV time series for soybean growth analysis provides objective data from field trials. Remote Sensing, 12, 1644.

Bosilj, P., Duckett, T., Cielniak, G. (2018). Connected attribute morphology for unified vegetation segmentation and classification in precision agriculture. Computers in Industry, 98, 226-240.

Brim, C.A. (1966). A modified pedigree method of selection in soybeans. Crop Science, 6, 220.

Bronick, C.J., Lal, R. (2005). Soil structure and management: A review. Geoderma 124, 3-22.

Bullock, D., Khan, S., Rayburn, A. (1998). Soybean yield response to narrow rows is largely due to enhanced early growth. Crop Science, 38, 1011-1016.

Burssens, S., Pertry, I., Ngudi, D., Kuo, Y., Montagu, V., Lambein, F. (2011). Soya, human nutrition and health. In: Soya bean meal and its extensive use in livestock feeding and nutrition. InTech: London, UK, 8.

Burton, J.W., Miranda, L. (2013). Soybean improvement: Achievements and challenges. Ratarstvo i povratarstvo, 50, 44-51.

Calviño, P., Sadras, V., Andrade, F. (2003). Development, growth and yield of late-sown soybean in the southern Pampas. European Journal of Agronomy, 19(2), 265-275.

Carciochi, W. D., Schwalbert, R., Andrade, F. H., Corassa, G. M., Carter, P., Gaspar, A. P., Schmidt, J., Ciampitti, I. A. (2019). Soybean seed yield response to plant density by yield environment in North America. Agronomy Journal, 111(4), 1923-1932.

Carpenter, A. C., Board, J. E. (1997). Branch yield components controlling soybean yield stability across plant populations. Crop Science, 37(3), 885.

- Carter, T. Jr., Hymowitz, T., Nelson, R. (2004). Biogeography, local adaptation, Vavilov, and genetic diversity in soybean. In: Werner, D. ed. Biological resources and migration. Berlin, Germany, Springer, 47-59.
- Casadesús, J., Villegas, D. (2014). Conventional digital cameras as a tool for assessing leaf area index and biomass for cereal breeding. *Journal of Integrative Plant Biology*, 56, 7-14.
- Casagrande, C.R., Sant'ana, G.C., Meda, A.R., Garcia, A., Souza Carneiro, P.C., Nardino, M., Borem, A. (2022). Association between unmanned aerial vehicle high-throughput canopy phenotyping and soybean yield. *Agronomy Journal*, 114(3), 1581-1598.
- Chang, A., Jung, J., Maeda, M. M., Landivar, J. (2017). Crop height monitoring with digital imagery from unmanned aerial system (UAS). *Computers and Electronics in Agriculture*, 141, 232-237.
- Chang, J., Clay, D.E., Clay, S.A., Reese, C.L. (2013). Using remote sensing technique to assess soybean yield limiting factors. In: Clay, D.E., Carlson, C.G., Clay, S.A., Wagner, L., Deneke, D., Hay, C. eds. iGrow soybean: Best management practices for soybean production. South Dakota State University, SDSU Extension, Brookings, SD.
- Che, Y., Wang, Q., Xie, Z., Zhou, L., Li, S., Hui, F., Wang, X., Li, B., Ma, Y. (2020). Estimation of maize plant height and leaf area index dynamics using an unmanned aerial vehicle with oblique and nadir photography. *Annals of Botany*, 126(4), 765-773.
- Chen, D., Neumann, K., Friedel, S., Kilian, B., Chen, M., Altmann, T., Klukas, C. (2014). Dissecting the phenotypic components of crop plant growth and drought responses based on high-throughput image analysis. *Plant Cell*, 26, 4636-4655.
- Chen, K.I., Erh, M.H., Su, N.W., Liu, W.H., Chou, C.C., Cheng, K.C. (2012). Soyfoods and soybean products: From traditional use to modern applications. *Applied Microbiology and Biotechnology*, 96, 9-22.
- Chowdhury, J., Karim, M., Khaliq, Q., Solaiman, A., Ahmed, J. (2016). Genotypic variations in growth, yield and yield components of soybean genotypes under drought stress conditions. *Bangladesh Journal of Agricultural Research*, 40(4), 537-550.
- Christopher, J., Richard, C., Chenu, K., Christopher, M., Borrell, A., Hickey, L. (2015). Integrating rapid phenotyping and speed breeding to improve stay-green and root adaptation of wheat in changing, water-limited, Australian environments. *Procedia Environmental Sciences*, 29, 175-176.
- Clarke, T.R., Moran, M.S., Barnes, E.M., Pinter, P.J., Qi, J. (2001). Planar domain indices: A method for measuring a quality of a single component in two-component pixels. *IEEE International Geoscience and Remote Sensing Symposium*, Sydney, Australia, 9-13 July.
- Cobb, J.N., DeClerck, G., Greenberg, A., Clark, R., McCouch, S. (2013). Next-generation phenotyping: requirements and strategies for enhancing our understanding of genotype-phenotype relationships and its relevance to crop improvement. *Theoretical and Applied Genetics*, 126(4), 867-87.
- Coy, A., Rankine, D., Taylor, M., Nielsen, D.C., Cohen, J. (2016). Increasing the accuracy and automation of fractional vegetation cover estimation from digital photographs. *Remote Sensing*, 8, 474.
- Crain, J. L., Wei, Y., Barker, J., Thompson, S. M., Alderman, P. D., Reynolds, M., Zhang, N., Poland, J. (2016). Development and deployment of a portable field phenotyping platform. *Crop Science*, 56, 965-975.
- Cutler, D.R., Edwards, T.C., Bear, K.H., Cutler, A., Hess, K.T., Gibson, J., Lawler, J.J. (2007). Random Forests for classification in ecology. *Ecology*, 88, 2783-2792.

de la Casa, A., Ovando, G., Bressanini, L., Martínez, J. (2016). Using NDVI from a modified digital camera to estimate potato crop cover under different conditions of nitrogen fertilization. *AgriScientia*, 33(2), 75-88.

Deery, D., Jimenez-Berni, J., Jones, H., Sirault, X., Furbank, R. (2014). Proximal remote sensing buggies and potential applications for field-based phenotyping. *Agronomy*, 4, 349-379.

Deery, D., Jones, H., Sirault, X., Furbank, R. (2014). Proximal remote sensing buggies and potential applications for field-based phenotyping. *Agronomy*, 4(3), 349-379.

Delgado-Vera, C., Aguirre-Munizaga, M., Jiménez-Icaza, M., Manobanda-Herrera, N., Rodríguez-Méndez, A. (2017). A photogrammetry software as a tool for precision agriculture: A case study. In: Valencia-García, R., Lagos-Ortiz, K., Alcaraz-Mármol, G., Del Cioppo, J., Vera-Lucio, N., Bucaram-Leverone, M. eds. *Technologies and innovation. Communications in Computer and Information Science*. Springer, Cham, 749.

Deliry, S.I., Avdan, U. (2021). Accuracy of unmanned aerial systems photogrammetry and structure from motion in surveying and mapping: A review. *Journal of the Indian Society of Remote Sensing*, 49, 1997-2017.

Diondra, W., Ivey, S., Washington, E., Woods, S., Walker, J., Krueger, N., Sahnawaz, M., Kassem, M. A. (2008). Is there a correlation between plant height and yield in soybean? *Reviews in Biology and Biotechnology*, 7, 70-76.

Dong, S., Jiang, Y., Dong, Y., Wang, L., Wang, W., Ma, Z., Yan, C., Ma, C., Liu, L. (2019). A study on soybean responses to drought stress and rehydration. *Saudi Journal of Biological Sciences*, 26(8), 2006-17.

Dong, Y., Yang, X., Liu, J., Wang, B.H., Liu, B.L., Wang, Y.Z. (2014). Pod shattering resistance associated with domestication is mediated by a NAC gene in soybean. *Nature Communications* 5(1), 3352.

Dorđević, V., Ćeran, M., Miladinović, J., Balešević-Tubić, S., Petrović, K., Miladinov, Z., Marinković, J. (2019). Exploring the performance of genomic prediction models for soybean yield using different validation approaches. *Molecular Breeding*, 39(5).

Echeverry-Galvis, M.A., Peterson, J.K., Sulo-Caceres, R. (2014). The social nestwork: Tree structure determines nest placement in Kenyan weaverbird colonies. *PLoS ONE*, 9(2), e88761.

Edwards, J.T., Purcell, L.C. (2005). Soybean yield and biomass responses to increasing plant population among diverse maturity groups: I. Agronomic characteristics. *Crop Science*, 45, 1770-7.

Egli, D. B. (2013). The relationship between the number of nodes and pods in soybean communities. *Crop Science*, 53(4), 1668-1676.

Egli, D. B. (2019). Crop growth rate and the establishment of sink size: A comparison of maize and soybean. *Journal of Crop Improvement*, 1-17.

Falconer, D.S., Mackay, T.F.C. (1996). *Introduction to quantitative genetics*. 4th Edition, Addison Wesley Longman, Harlow.

Faostat, Food and Agriculture Organization of the United Nations. <https://www.fao.org/faostat/en/#home>, poslednja provera 12.12.2024.

Fenta, B., Beebe, S., Kunert, K., Burridge, J., Barlow, K., Lynch, J., Foyer, C. (2014). Field phenotyping of soybean roots for drought stress tolerance. *Agronomy*, 4(3), 418-35.

Fickett, N.D., Boerboom, C.M., Stoltenberg, D.E. (2013). Soybean yield loss potential associated with early-season weed competition across 64 site-years. *Weed Science*, 61,500-7

Frankelius, P., Norrman, C., Johansen, K. (2019). Agricultural innovation and the role of institutions: Lessons from the game of drones. *Journal of Agricultural and Environmental Ethics*, 32(5), 681-707.

Friedman, J.H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 1189-1232.

Fu, Z., Jiang, J., Gao, Y., Krienke, B., Wang, M., Zhong, K., Cao, Q., Tian, Y., Zhu, Y., Cao, W., Liu, X. (2020). Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle. *Remote Sensing*, 12, 508.

Gajić, B., Kresović, B., Tapanarova, A., Životić, L., Todorović, M. (2018). Effect of irrigation regime on yield, harvest index and water productivity of soybean grown under different precipitation conditions in a temperate environment. *Agricultural Water Management*, 210, 224-231.

Gao, F., Anderson, M., Daughtry, C., Johnson, D. (2018). Assessing the variability of corn and soybean yields in central Iowa using high spatiotemporal resolution multi-satellite imagery. *Remote Sensing*, 10(9), 1489.

Ge, T., Sui, F., Bai, L., Tong, C., Sun, N. (2011). Effects of water stress on growth, biomass partitioning, and water-use efficiency in summer maize (*Zea mays* L.) throughout the growth cycle. *Acta Physiologiae Plantarum*, 34(3), 1043-53.

Geng, L., Che, T., Ma, M., Tan, J., Wang, H. (2021). Corn biomass estimation by integrating remote sensing and long-term observation data based on machine learning techniques. *Remote Sensing*, 13, 2352.

Ghosh, S., Watson, A., Gonzalez-Navarro, O.E., Ramirez-Gonzalez, R.H., Yanes, L., Mendoza-Suárez, M., Simmonds, J., Wells, R., Rayner, T., Green, P., Hafeez, A., Hayta, S., Melton, R. E., Steed, A., Sarkar, A., Carter, J., Perkins, L., Lord, J., Tester, M., Osbourn, A., Moscou, M.J., Nicholson, P., Harwood, W., Martin, C., Domoney, C., Uauy, C., Hazard, B., Wulff, B.B.H., Hickey, L. T. (2018). Speed breeding in growth chambers and glasshouses for crop breeding and model plant research. *Nature protocols*, 13, (12), 2944-2963.

Gianquinto, G., Orsini, F., Fecondini, M., Mezzetti, M., Sambo, P., Bona, S. (2011). A methodological approach for defining spectral indices for assessing tomato nitrogen status and yield. *European Journal of Agronomy*, 35(3), 135-143.

Gill, T., Gill, S.K., Saini, D.K., Chopra, Y., de Koff, J.P., Sandhu, K.S. (2022). A comprehensive review of high-throughput phenotyping and machine learning for plant stress phenotyping. *Phenomics*, 2(3), 156-83.

Glamočlija, D., Spasić, M., Živanović, T., Ikanović, J., Filipović, V., Milutinović, M. (2010). Genotipske specifičnosti soje u uslovima intenzivne ishrane azotom. *Zbornik naučnih radova Instituta PKB Agroekonomik*. Institut PKB Agroekonomik, Padinska skela, 16(1-2), 137-143.

Gnädinger, F., Schmidhalter, U. (2017). Digital counts of maize plants by unmanned aerial vehicles (UAVs). *Remote Sensing*, 9, 544.

Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., Pretty, J., Robinson, S., Thomas, S. M., Toulmin, C. (2010). Food security: The challenge of feeding 9 billion people. *Science*, 327, 812-818.

Goldstein, A., Kapelner, A., Bleich, J., Pitkin, E. (2015). Peeking inside the black box: Visualizing statistical learning with plots of individual conditional expectation. *Journal of Computational and Graphical Statistics*, 24(1), 44-65.

Grabau, L. J., Pfeiffer, T. W. (1990). Assessment of soybean stubble losses in different cropping systems. *Applied Agricultural Research*, 5, 96-101.

Gulluoglu, L., Bakal, H., Sabagh, A.E.L., Arioglu, H. (2017). Soybean managing for maximize production: Plant population density effects on seed yield and some agronomical traits in main cropped soybean production. *Journal of Experimental Biology and Agricultural Sciences*, 5, 31-37.

Guo, H., Dou, C., Zhang, X., Han, C., Yue, X. (2016). Earth observation from the manned low Earth orbit platforms. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 103-118.

Guo, T., Fang, Y., Cheng, T., Tian, Y., Zhu, Y., Chen, Q., Qiu, X., Yao, X. (2019). Detection of wheat height using optimized multi-scan mode of LiDAR during the entire growth stages. *Computers and Electronics in Agriculture*, 165, 104959.

Guo, W., Fukatsu, T., Ninomiya, S. (2015). Automated characterization of flowering dynamics in rice using field-acquired time-series RGB images. *Plant Methods*, 11, 7.

Guo, W., Rage, U. K., Ninomiya, S. (2013). Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model. *Computers and Electronics in Agriculture*, 96, 58-66.

Haemmerle, M., Hoefle, B., (2016). Direct derivation of maize plant and crop height from low-cost time-of-flight camera measurements. *Plant Methods*, 12, 50.

Hallauer, A.R., Miranda Filho, J.B., Carena, M.J. (2010). Quantitative genetics in maize breeding. Springer, New York.

Hamasaki, T., Sameshima, R., Hirota, T. (2008). Delayed emergence of soybeans due to drought and soil crust does not extend the period from emergence to flowering. *Journal of Agricultural Meteorology*, 64, 4, 233-242.

Hamuda, E., Glavin, M. Jones, E. (2016). A survey of image processing techniques for plant extraction and segmentation in the field. *Computers and Electronics in Agriculture*, 125, 184-199.

Han, L., Yang, G., Dai, H., Xu, B., Yang, H., Feng, H., Yang, X. (2019). Modeling maize above-ground biomass based on machine learning approaches using UAV remote sensing data. *Plant Methods*, 15, 1-19.

Han, L., Yang, G., Yang, H., Xu, B., Li, Z., Yang, X. (2018). Clustering field-based maize phenotyping of plant-height growth and canopy spectral dynamics using a UAV remote sensing approach. *Frontiers in Plant Science*, 9, 1638.

Hanmugapriya, P., Rathika, S., Ramesh, T., Janaki, P. (2019). Applications of remote sensing in agriculture-A review. *International Journal of Current Microbiology and Applied Sciences*, 8(1), 2270-2283.

Hassan, M.A., Yang, M., Fu, L., Rasheed, A., Zheng, B., Xia, X., Xiao, Y., He, Z. (2019). Accuracy assessment of plant height using an unmanned aerial vehicle for quantitative genomic analysis in bread wheat. *Plant Methods*, 15, 37.

Hastie, T., Tibshirani, R., Friedman, J. (2009). *The Elements of Statistical Learning*, 2nd edition, Springer, New York/Berlin/Heidelberg.

Haug, S., Michaels, A., Biber, P., Ostermann, J. (2014). Plant classification system for crop/ weed discrimination without segmentation. *IEEE Winter Conference on Applications of Computer Vision (WACV)*, 1142-1149.

Heslot, N., Yang, P., Sorrells, M. E., Jannink, L. (2011). Genomic selection in plant breeding: A comparison of models. *Crop Science*, 52(1), 146-160.

Holman, F.H., Riche, A.B., Michalski, A., Castle, M., Wooster, M.J., Hawkesford, M.J., (2016). High-throughput field phenotyping of wheat plant height and growth rate in field plot trials using UAV based Remote Sensing. *Remote Sensing*, 8, 1031.

Hrustić, M., Jocković, Đ., Vidić, M. (1998). Oplemenjivanje soje u Institutu za ratarstvo i povrtarstvo. U: Hrustić, M., Jocković, Đ., Vidić, M. edi. Soja. Institut za ratarstvo i povrtarstvo, Novi Sad i Sojaprotein, Bečej, 135-153.

Hu, P., Chapman, S. C., Wang, X., Potgieter, A., Duan, T., Jordan, D., Guo, Y., Zheng, B. (2018). Estimation of plant height using a high-throughput phenotyping platform based on unmanned aerial vehicle and self-calibration: Example for sorghum breeding. *European Journal of Agronomy*, 95, 24-32.

Hunt, E. R. J., Cavigelli, M., Daughtry, C. S. T., McMurtrey, J. I. Walthall, C. L. (2005). Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. *Precision Agriculture*, 6, 359-378.

Hurburgh, C., Jr., Brumm, T., Guinn, J., Hartwig, R. (1990). Protein and oil patterns in U.S. and world soybean markets. *Journal of the American Oil Chemists' Society*, 67, 966-973.

Hymowitz, T. (2004). Speciation and cytogenetics. In: Boerma, H.R., Specht, J.E. eds. Soybeans: Improvement, production, and uses, Third Edition. ASA, CSSA, SSSA, Madison, WI, USA, 97-136.

Hymowitz, T. (2008). The history of the soybean. AOCS Press, Soybeans, 1-31.

Jangra, S., Chaudhary, V., Yadav, R. C., Yadav, N. R. (2021). High-throughput phenotyping: a platform to accelerate crop improvement. *Phenomics* 1, 31-53.

Jarquin, D., Howard, R., Xavier, A., Das Choudhury, S. (2020). Predicting yield by modeling interactions between canopy coverage image data, genotypic and environmental information for soybeans. In: Samal, A., Das Choudhury, S. eds. Intelligent image analysis for plant phenotyping. CRC Press, 267-286.

Jarquin, D., Howard, R., Xavier, A., Das Choudhury, S. (2018). Increasing predictive ability by modeling interactions between environments, genotype and canopy coverage image data for soybeans. *Agronomy*, 8(4), 51.

Jarquin, D., Specht, J., Lorenz, A. (2016). Prospects of genomic prediction in the USDA soybean germplasm collection: historical data creates robust models for enhancing selection of accessions. *G3: Genes, Genomes, Genetics*, 6(8), 2329-2341.

Jeong, J., Resop, J.P., Mueller, N.D., Fleisher, D.H., Kyungdahm, Y., Butler, E.E., Timlin, D., Kyo-Moon, S., Gerber, J., Vangimalla Ramakrishna, R., Kim, S.H. (2016). Random forests for global and regional crop yield predictions. *PLoS ONE*, 11, e0156571.

Jeziorska, J. (2018). UAS for wetland mapping and hydrological modeling. *Remote Sensing*, 11(17), 1997.

Jiang J., Nguyen T. (2007). Linear and generalized linear mixed models and their applications. New York, Springer.

Jocković, Đ., Belić, B., Hrustić, M. (1986). Genetička analiza kvantitativnih svojstava soje. *Genetika*, 18(2), 121-130.

Johansen, K., Morton, M.J.L., Malbeteau, Y., Aragon, B., Al-Mashharawi, S., Ziliani, M.G., Angel, Y., Fiene, G., Negrão, S., Mousa, M.A.A., Tester, M.A., McCabe, M.F. (2020). Predicting biomass and yield in a tomato phenotyping experiment using uav imagery and random forest. *Frontiers in Artificial Intelligence*, 3, 28.

- Johnson, K., Nissen, E., Saripalli, S., Arrowsmith, J.R., McGarey, P., Scharer, K., Williams, P., Blisniuk, K. (2014). Rapid mapping of ultrafine fault zone topography with structure from motion. *Geosphere*, 10, 969-986.
- Jovanović, B., Perović, D., Prodanović, S., Petrović, S. (1992). Uticaj interakcije genotipa i ekoloških uslova na sadržaj ulja u zrnu soje. *Poljoprivreda i šumarstvo*, 38, 89-93.
- Kane, V.R., McGaughey, R.J., Bakker, J.D., Gersonde, R.F., Lutz, J.A., Franklin, J.F. (2010). Comparisons between field- and LiDAR-based measures of stand structural complexity. *Canadian Journal of Forest Research*, 40, 761-773.
- Kaur, B., Sandhu, K.S., Kamal, R., Kaur, K., Singh, J., Röder, M.S., Muqaddasi, Q.H. (2021). Omics for the Improvement of Abiotic, Biotic, and Agronomic Traits in Major Cereal Crops: Applications, Challenges, and Prospects. *Plants*, 10, 1989.
- Khan, Z., Rahimi-Eichi, V., Haefele, S., Garnett, T., Miklavcic, S. J. (2018). Estimation of vegetation indices for high-throughput phenotyping of wheat using aerial imaging. *Plant Methods*, 14(1).
- Khanal, S., KC, K., Fulton, J.P., Shearer, S., Ozkan, E. (2020). Remote sensing in agriculture-accomplishments, limitations, and opportunities. *Remote Sensing*, 12, 3783.
- Khun, S., Neumann, S., Egert, B., Steinbeck, C. (2008). Building blocks for automated elucidation of metabolites: Machine learning methods for NMR prediction. *BMC Bioinformatics*, 9, 400.
- Kim, S., Dale, B.E. (2009). Regional variations in greenhouse gas emissions of biobased products in the United States-corn-based ethanol and soybean oil. *The International Journal of Life Cycle Assessment*, 14, 540-546.
- Kipp, S., Mistele, B., Baresel, P., Schmidhalter, U. (2014). High-throughput phenotyping early plant vigour of winter wheat. *European Journal of Agronomy*, 52, 271-278.
- Kitano, B. T., Mendes, C. C. T., Geus, A. R., Oliveira, H. C., Souza, J. R. (2019). Corn plant counting using deep learning and uav images. *IEEE Geoscience and Remote Sensing Letters*, 1-5.
- Koh, C.O.J., Hayden, M., Daetwyler, H., Kant, S. (2019). Estimation of crop plant density at early mixed growth stages using UAV imagery. *Plant Methods*, 15, 64.
- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5), 1-26.
- Kumar, S., Bhagat, V. (2018). Remote sensing satellites for land applications: A review. *Remote Sensing Land*, 2(2), 96-104.
- Latchininsky, A.V., Sivanpillai, R. (2010). Locust habitat monitoring and risk assessment using remote sensing and GIS technologies. Springer, Netherlands.
- Lati, R.N., Filin, S., Eizenberg, H. (2013). Estimating plant growth parameters using an energy minimization-based stereovision model. *Computers and Electronics in Agriculture*, 98, 260-71.
- Lee, C. D. (2006). Reducing row widths to increase yield: Why it does not always work. *Crop Management*, 5(1), 1-7.
- Lee, C.D., Egli, D.B., TeKrony, D.M. (2008). Soybean response to plant population at early and late planting dates in the Mid-South. *Agronomy Journal*, 100, 971-976.
- Lewthwaite, S. L., Triggs, C. M. (2012). Sweetpotato cultivar response to prolonged drought. *Agronomy New Zealand*, 42, 1-10.

Li L., Zhang Q., Huang D. (2014). A review of imaging techniques for plant phenotyping. *Sensors* (Basel), 14(11), 20078-111

Li, B., Xu, X., Zhang, L., Han, J., Bian, C., Li, G., Li, G., Liu, J., Jin, L. (2020). Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 161-172.

Li, H., Li, Y., Yang, Z., Liu, J. (2024). Soybean LAI and plant height monitoring based on UAV spectral information and texture fusion. *Proceedings of Fifth International Conference on Geoscience and Remote Sensing Mapping*, 19 January.

Liang, H., Zhou, Y., Lu, Y., Pei, S., Xu, D., Lu, Z., Yao, W., Liu, Q., Yu, L., Li, H. (2024). Evaluation of soybean drought tolerance using multimodal data from an unmanned aerial vehicle and machine learning. *Remote Sensing*, 16, 2043.

Liaw, A., M. Wiener. (2018). Breiman and Cutler's random forests for classification and regression.

Lobos, G.A., Camargo, A.V., del Pozo, A., Araus, J.L., Ortiz, R., Doonan, J.H. (2017). Plant phenotyping and phenomics for plant breeding. *Frontiers in Plant Science*, 8, 313980.

Lozada, D.N., Godoy, J.V., Ward, B.P., Carter, A.H. (2020) Genomic prediction and indirect selection for grain yield in US pacific northwest winter wheat using spectral reflectance indices from high-throughput phenotyping. *International Journal of Molecular Sciences*, 21,165.

Lu, H., Fan, T., Ghimire, P., Deng, L. (2020). Experimental evaluation and consistency comparison of UAV multispectral minisensors. *Remote Sensing*, 12, 2542.

Luo, S., Liu, W., Zhang, Y., Wang, C., Xi, X., Nie, S., Ma, D., Lin, Y., Zhou, G. (2021). Maize and soybean heights estimation from unmanned aerial vehicle (UAV) LiDAR data. *Computers and Electronics in Agriculture*, 182, 106005.

Lussem, U., Bolten, A., Gnyp, M.L., Jasper, J., Bareth, G. (2018). Evaluation of RGB-based vegetation indices from UAV imagery to estimate forage yield in Grassland. *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1215-1219. Beijing, China, 7-10 May.

Ly, B. C. K., Dyer, E. B., Feig, J. L., Chien, A. L., Del Bino, S. (2020). Research techniques made simple: cutaneous colorimetry: a reliable technique for objective skin color measurement. *Journal of Investigative Dermatology*, 140(1), 3-12.

Ma, B., Dwyer, L.M., Costa, C., Cober, E.R., Morrison, M.J. (2001). Early prediction of soybean yield from canopy reflectance measurements. *Agronomy Journal*, 93, 1227-1234.

Ma, Z., Rayhana, R., Feng, K., Liu, Z., Xiao, G., Ruan, Y., Sangha, J.S. (2022). A review on sensing technologies for high-throughput plant phenotyping. *IEEE Open Journal of Instrumentation and Measurement*, 1, 1-21.

MacMillan, K. P., Gulden, R. H. (2020). Effect of seeding date, environment and cultivar on soybean seed yield, yield components, and seed quality in the Northern Great Plains. *Agronomy Journal*, 112(3), 1666-1678.

Madec, S., Baret, F., de Solan, B., Thomas, S., Dutartre, D., Jezequel, S., Hemmerlé, M., Colombeau, G., Comar, A. (2017). High-throughput phenotyping of plant height: Comparing unmanned aerial vehicles and ground LiDAR estimates. *Frontiers in Plant Science*, 8, 2002.

Maes, W.H., Steppe, K. (2019). Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in Plant Science*, 24, 152-164.

Maimaitijiang, M., Ghulam, A., Sidike, P., Hartling, S., Maimaitiyiming, M., Peterson, K., Shavers, E., Fishman, J., Peterson, J., Kadam, S., Burken, J., Fritshi, F. (2017). Unmanned aerial system (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine. *ISPRS Journal of Photogrammetry and Remote Sensing*, 134, 43-58.

Maimaitijiang, M., Sagan, V., Sidike, P., Hartling, S., Esposito, F., Fritsch, F. B. (2020). Soybean yield prediction from UAV using multimodal data fusion and deep learning. *Remote Sensing of Environment*, 237, 111599.

Maimaitijiang, M., Sagan, V., Sidike, P., Maimaitiyiming, M., Hartling, S., Peterson, K. T., Maw, M. J., Shakoor, N., Mockler, T., Fritsch, F. B. (2019). Vegetation index weighted canopy volume model (CVMVI) for soybean biomass estimation from unmanned aerial system-based RGB imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151, 27-41.

Makanza, R., Zaman-Allah, M., Cairns, J.E., Magorokosho, C., Tarekegne, A., Olsen, M., Prasanna, B.M. (2018). High-throughput phenotyping of canopy cover and senescence in maize field trials using aerial digital canopy imaging. *Remote Sensing*, 10, 330.

Mandić, V., Đorđević, S., Đorđević, N., Bijelić, Z., Krnjaja, V., Petričević, M., Brankov, M. (2020). Genotype and sowing time effects on soybean yield and quality. *Agriculture*, 10, 502.

Maresma, A., Ariza, M., Martinez, E., Lloveras, J., Martinez-Casanovas, J.A. (2016). Analysis of vegetation indices to determine nitrogen application and yield prediction in maize (*zea mays* L.) from a standard UAV service. *Remote Sensing*, 8, 973.

Masina, M., Lambertini, A., Daprà, I., Mandanici, E., Lamberti, A. (2020). Remote sensing analysis of surface temperature from heterogeneous data in a maize field and related water stress. *Remote Sensing*, 12, 2506.

Matese, A., Toscano, P., Gennaro, S. F. D., Genesio, L., Vaccari, F. P., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R. and Gioli, B. (2015). Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*, 7, 2971-2990.

Mathan, J., Bhattacharya, J., Ranjan, A. (2016). Enhancing crop yield by optimizing plant developmental features. *Development*, 143, 3283-3294.

Mathieu, R., Pouget, M., Cervelle, B., Escadafal, R. (1998). Relationships between satellite-based radiometric indices simulated using laboratory reflectance data and typic soil color of an arid environment. *Remote Sensing of Environment*, 66(1), 17-28.

Matias, F.I., Caraza-Harter, M.V., Endelman, J.B. (2020). FIELDImageR: An R package to analyze orthomosaic images from agricultural field trials. *The Plant Phenome Journal*, 3(1).

Mellendorf, N. E. (2011). Soybean growth and yield response to interplant competition relief in various plant density environments. MSc thesis, University of Illinois at Urbana-Champaign.

Mesas-Carrascosa, F., Torrres-Sánchez, J., Clavero-Rumbao, I., Garcia-Ferrer, A., Pen, J., Borra-Serrano, I., Lopez-Granados, F. (2015). Assessing optimal flight parameters for generating accurate multispectral orthomosaicks by UAV to support site-specific crop management. *Remote Sensing*, 7, 12793-12814.

Meyer, G. E., Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63(2), 282-293.

Miladinović, J. (1999). Genetska dobit kao pokazatelj efikasnosti tri različita metoda selekcije soje *Glycine max* (L.) Merr. Doktorska disertacija, Poljoprivredni fakultet, Univerzitet u Novom Sadu.

Miladinović, J., Burton, J. W., Balešević Tubić, S., Miladinovic, D., Đorđević, V., Đukić, V. (2011). Soybean breeding: comparison of the efficiency of different selection methods. *Turkish Journal Of Agriculture And Forestry*, 35(5), 3.

Miladinović, J., Ćeran, M., Đorđević, V., Petrović, K., Đukić, V., Miladinović, D. (2018). Allelic variation and distribution of the major maturity genes in different soybean collections. *Frontiers in Plant Science*, 9, 316565.

Miladinović, J., Hrustić, M., Vidić, M. (2008). Soja. Institut za ratarstvo i povrtarstvo, Novi Sad i Sojaprotein, Bečej, AMB Grafika, Novi Sad.

Miladinović, J., Hrustić, M., Vidić, M., Balešević Tubić, S., Đorđević, V. (2008). Oplemenjivanje soje u Institutu za ratarstvo i povrtarstvo. *Zbornik radova Instituta za ratarstvo i povrtarstvo*, 45(1), 65-80.

Miladinović, J., Prodanović, S. (2021). Good agricultural practices and technologies to reduce the impact of natural hazards in soybean production in Serbia. Rome, FAO.

Miladinović, J., Vidić, M., Djordjević, V., Balešević-Tubić, S. (2015). New trends in plant breeding - example of soybean. *Genetika*, 47(1), 131-142.

Mir, R.R., Reynolds, M., Pinto, F., Khan, M.A., Bhat, M.A. (2019). High-throughput phenotyping for crop improvement in the genomics era. *Plant Science*, 282, 60-72.

Mirakhori, F., Paknejad, F., Moradi, F., Ardashani, M., Zahedi, H., Nazeri, P. (2009). Effect of drought stress and methanol on yield and yield components of soybean max (L17). *American Journal of Biochemistry and Biotechnology* 5, 162-169.

Mlambo, R., Woodhouse, I.H., Gerard, F., Anderson, K. (2017). Structure from motion (SfM) photogrammetry with drone data: A low cost method for monitoring greenhouse gas emissions from forests in developing countries. *Forests*, 8, 68.

Molnar, C., Casalicchio, G., Bischl, B. (2018). iml: An R package for interpretable machine learning. *Journal of Open Source Software*, 3(26), 786.

Moose, S. P., Mumm, R. H. (2008). Molecular plant breeding as the foundation for 21st century crop improvement. *Plant Physiology*, 147, 969-977.

Moreira, F.F., Hearst, A.A., Cherkauer, K.A., Rainey, K.M. (2019). Improving the efficiency of soybean breeding with high-throughput canopy phenotyping. *Plant Methods*, 15, 139.

Moroni, M., Porti, M., Piro, P. (2019). Design of a remote-controlled platform for green roof plants monitoring via hyperspectral sensors. *Water*, 11, 1368.

Motohka, T., Nasahara, K.N., Oguma, H., Tsuchida, S. (2010). Applicability of green-red vegetation index for remote sensing of vegetation phenology. *Remote Sensing*, 2, 2369-87.

Narayanan, B., Floyd, B., Tu, K., Ries, L., Hausmann, N. (2019). Improving soybean breeding using UAS measurements of physiological maturity. In: Proceedings of the SPIE Defense + Commercial Sensing, Baltimore, MD, USA, 3-7 April.

Naser, M.A., Khosla, R., Longchamps, L., Dahal, S. (2020). Characterizing variation in nitrogen use efficiency in wheat genotypes using proximal canopy sensing for sustainable wheat production. *Agronomy*, 10, 773.

Nenadić, N., Nedić, M., Živanović, Lj., Kolarić, Lj., Simić, A., Jovanović, B., Vuković, Z. (2003). Uticaj oblika vegetacionog prostora na prinos semena i osobine rodnosti sorata soje. *Zbornik naučnih radova Instituta PKB Agroekonomik*, 9(1), 73-80.

Neugschwandtner, R.W., Winkler, J., Bernhart, M., Pucher, M.A., Klug, M., Werni, C., Adam, E., Kaul, H.P. (2019). Effect of row spacing, seeding rate and nitrogen fertilization on yield and yield components of soybean. *Bodenkultur*, 70, 221-236.

Nitsch, B.B., Von Bargen, K., Meyer, G.E., Mortensen, D.A. (1991). Visible and near infrared plant, soil and crop residue reflectivity for weed sensor design. American Society of Agricultural Engineers, 91-3006.

Norsworthy, J. K., Shipe, E. R. (2005). Effect of row spacing and soybean genotype on mainstem and branch yield. *Agronomy Journal*, 97(3), 919.

Nyonje, W. A., Schafleitner, R., Abukutsa-Onyango, M., Yang, R. Y., Makokha, A., Owino, W. (2021). Precision phenotyping and association between morphological traits and nutritional content in Vegetable Amaranth (*Amaranthus* spp.). *Journal of Agriculture and Food Research*, 5, 100165.

Ollinger, S. V. (2010). Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, 189(2), 375-394.

Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66.

Pandey, B.R., Burton, W., Salisbury, M.E. (2016). Non-destructive measurement of canopy cover is an alternative to biomass sampling at anthesis to predict yield of canola-quality *Brassica juncea*. *Australian Journal of Crop Science*, 10, 04, 482-9.

Parmley, K.A., Higgins, R.H., Ganapathysubramanian, B., Sarkar, S., Singh, A.K. (2019). Machine learning approach for prescriptive plant breeding. *Scientific Reports*, 9, 17132.

Pasala, R., Chennamsetti, M., Patil, B., Kadirvel, P., Geethanjali, S., Nagaram, S., Sajja, S., Vennapusa, R.V., Prasad, V., Mathur, R.K. (2024). Revolutionizing crop production: The imperative of speed breeding technology in modern crop improvement. *Crop Breeding, Genetics and Genomics*, 6(2), e240003.

Patrignani, A., Ochsner, T. E. (2015). Canopeo: A powerful new tool for measuring fractional green canopy cover. *Agronomy Journal*, 107(6), 2312-2320.

Payero, J. O., Neale, C. M. U., Wright, J. L. (2004). Comparison of eleven vegetation indices for estimating plant height of alfalfa and grass. *Applied Engineering in Agriculture*, 20(3), 385-393.

Pejić, B., Maksimović, L., Cimpeanu, S., Bucur, D., Milić, S., Ćupina, B. (2011). Response of soybean to water stress at specific growth stages. *Journal of Food, Agriculture and Environment*, 9, 280-4.

Perić, V. (2009). Varijabilnost agronomskih svojstava kod polusrođničkih familija soje (*Glycine max* (L.) Merrill). Magistarska teza, Poljoprivredni fakultet, Univerzitet u Novom Sadu.

Perić, V. (2015). Analiza genetičke divergentnosti genotipova soje na osnovu morfoloških i molekularnih markera. Doktorska disertacija, Poljoprivredni fakultet, Univerzitet u Beogradu.

Perić, V., Srebrić, M., Mikić, A., Mikić, A., Mladenović-Drinić, S. (2013). Uticaj agrometeoroloških uslova na prinos i komponente prinosa soje. *Zbornik Naučnih Radova*, 19(1/2), 141-147.

Persa, R., Ribeiro, P. C. de O., Jarquin, D. (2021). The use of high-throughput phenotyping in genomic selection context. *Crop Breeding and Applied Biotechnology*, 21, e385921S6.

Pierozan Junior, C., Kawakami, J., Bridi, M., Muller, M. M. L., Conte, M. V. D., Michalovicz, L. (2015). Phenological and quantitative plant development changes in soybean cultivars caused by sowing date and their relation to yield. *African Journal of Agricultural Research*, 10515(6), 515-523.

Pieruschka, R., Schurr, U. (2019). Plant Phenotyping: Past, Present, and Future. *Plant Phenomics*, 2019, 7507131.

Pinto, F., Zaman-Allah, M., Reynolds, M., Schulthess, U. (2023) Satellite imagery for high-throughput phenotyping in breeding plots. *Frontiers in Plant Science*, 14, 1114670.

Pourali, S., Arrowsmith, C., Chrisman, N., Matkan, A., (2014). Vertical accuracy assessment of LiDAR ground points using minimum distance approach. *Proceedings of the Research Locate* 14, Canberra, Australia, 7-9 April.

Pratama, M. T., Kim, S., Ozawa, S., Ohkawa, T., Chona, Y., Tsuji, H., Murakami, N. (2020). Deep learning-based object detection for crop monitoring in soybean fields. *International Joint Conference on Neural Networks (IJCNN)*, Glasgow, IEEE.

Purcell, L. C. (2000). Soybean canopy coverage and light interception measurements using digital imagery. *Crop Science*, 40(3), 834-837.

Purcell, L.C., Specht, J.E. (2004). Physiological traits for ameliorating drought stress. In: Boerma, H.R., Specht, J.E. eds. *Soybeans: improvement, production, and uses*, Third Edition. Madison: American Society of Agronomy, Crop Science Society of America, and Soil Science Society of America, 569-620.

Puri, V., Nayyar, A., Raja, L. (2017). Agriculture drones: A modern breakthrough in precision agriculture. *Journal of Statistics and Management Systems*, 20, 507-18.

Quirós Rosado, E. (2018). Introduction to applied photogrammetry and cartography for civil engineering.

Rahman, M.M., Hossain, M.M. (2011). Plant density effects on growth, yield and yield components of two soybean varieties under equidistant planting arrangement. *Asian Journal of Plant Sciences*, 10, 278-286.

Ranđelović, V., Prodanović, S., Tomić, Z., Bijelić, Z. (2010). Genotypic response of two soybean varieties with reduced content of KTI to application of different nitrogen level. *Biotechnology in Animal Husbandry*, 26(5-6), 403-410.

Reddy, A.R., Chaitanya, K.V., Vivekanandan, M. (2004). A review: Drought induced responses of photosynthesis and antioxidant metabolism in higher plants. *Journal of Plant Physiology*, 161, 1189-1202.

Richard, C., Hickey, L., Fletcher, S., Chenu, K., Borrell, A., Christopher, J. (2015). High-throughput phenotyping of wheat seminal root traits in a breeding context. *Procedia Environmental Sciences*, 29, 102-103.

Rigsby, B., Board, J.E. (2003). Identification of soybean cultivars that yield well at low plant populations. *Crop Science*, 43, 234-239.

Rincker, K., Nelson, R.L., Specht, J., Sleper, D., Cary, T., Cianzio, S., Casteel, S., Conley, S., Chen, P., Davis, V., Fox, C., Graef, G., Godsey, C., Holshouser, D., Jiang, G.L., Kantartzzi, S.K., Kenworthy, W., Lee, C., Mian, R., McHale, L., Naeve, S., Orf, J., Poysa V., Schapaugh, W., Shannon, G., Uniatowski, R., Wang, D., Diers, B. (2014). Genetic improvement of U.S. soybean in maturity groups II, III, and IV. *Crop Science*, 54, 1419-32.

Ritchie, G. L., Sullivan, D. G., Vencill, W. K., Bednarz, C. W. Hook, J. E. (2010). Sensitivities of normalized difference vegetation index and a green/red ratio index to cotton ground cover fraction. *Crop Science*, 50, 1000-1010.

Rodríguez-Álvarez, M.X., Boer, M.P., van Eeuwijk, F.A., Eilers, P.H.C. (2018). Correcting for spatial heterogeneity in plant breeding experiments with p-splines. *Spatial Statistics*, 23, 52-71.

Roman, A., Ursu, T.M. (2016). Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks. In: Opreanu, C.H., Lăzărescu, V.A. eds. *Landscape archaeology on the northern frontier of the Roman Empire at porolissum*. Mega Publishing House, Cluj-Napoca, Romania, 141-152.

Romeo, J., Pajares, G., Montalvo, M., Guerrero, J.M., Guijaro, M., de la Cruz, J.M. (2013). A new expert system for greenness identification in agricultural images. *Expert Systems with Applications*, 40, 2275-2286.

Roth, L., Barendregt, C., Bétrix, C.A., Hund, A., Walter, A. (2022). High-throughput field phenotyping of soybean: Spotting an ideotype. *Remote Sensing of Environment*, 269, 112797.

Rotundo, J. L., Miller-Garvin, J. E., Naeve, S. L. (2016). Regional and temporal variation in soybean seed protein and oil across the United States. *Crop Science*, 56(2), 797.

RStudio Team (2018). RStudio: Integrated Development for R. RStudio, PBC, Boston, MA. <http://www.rstudio.com/>.

Ruiz, J.J., Diaz-Mas, L., Perez, F., Viguria, A. (2013). Evaluating the accuracy of DEM generation algorithms from UAV imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40, 333-337.

Sadeghi-Tehran, P., Virlet, N., Sabermanesh, K., Hawkesford, M. J. (2017). Multi-feature machine learning model for automatic segmentation of green fractional vegetation cover for high-throughput field phenotyping. *Plant Methods*, 13(1).

Sagan, V., Maimaitijiang, M., Paheding, S., Bhadra, S., Gosselin, N., Burnette, M., Demieville, J., Hartling, S., Lebauer, D., Newcomb, M., Pauli, D., Peterson, K. T., Shakoor, N., Stylianou, A., Zender, C. S., Mockler, T. C. (2022). Data-driven artificial intelligence for calibration of hyperspectral big data. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 5510320.

Sánchez-Sastre, L.F., Alte da Veiga, N.M.S., Ruiz-Potosme, N.M., Carrión-Prieto, P., Marcos-Robles, J.L., Navas-Gracia, L.M., Martín-Ramos, P. (2020). Assessment of RGB vegetation indices to estimate chlorophyll content in sugar beet leaves in the final cultivation stage. *AgriEngineering*, 2, 128-149.

Sangjan, W., Carter, A.H., Pumphrey, M.O., Jitkov, V., Sankaran, S. (2021). Development of a raspberry pi-based sensor system for automated in-field monitoring to support crop breeding programs. *Inventions*, 6, 42.

Sarkar, S., Zhou, J., Scaboo, A., Zhou, J., Aloysius, N., Lim, T.T. (2023). Assessment of soybean lodging using UAV imagery and machine learning. *Plants*, 12, 2893.

Sassu, A., Gambella, F., Ghiani, L., Mercenaro, L., Caria, M., Pazzona, A.L. (2021). Advances in unmanned aerial system remote sensing for precision viticulture. *Sensors (Basel)*, 21(3), 956.

Schindelin, J., Arganda-Carreras, I., Frise, E., Kaynig, V., Longair, M., Pietzsch, T., Preibisch, S., Rueden, C., Saalfeld, S., Schmid, B., Tinevez, J.Y., White, D.J., Hartenstein, V., Eliceiri, K., Tomancak, P., Cardona, A. (2012). Fiji: An open-source platform for biological-image analysis. *Nature Methods*, 9(7), 676-682.

Schloerke, B., Crowley, J., Cook, D., Briatte, F., Marbach, M., Thoen, E., Elberg, A., Larmarange, J. (2018). GGally: Extension to 'ggplot2'.

- Shafiekhani, A., Kadam, S., Fritschi, F.B., DeSouza, G.N. (2017). Vinobot and vinoculer: Two robotic platforms for high-throughput field phenotyping. *Sensors*, 17, 214.
- Shah, S.H., Angel, Y., Houborg, R., Ali, S., McCabe, M.F. (2019). A random forest machine learning approach for the retrieval of leaf chlorophyll content in wheat. *Remote Sensing*, 11, 920.
- Shammi, S. A., Huang, Y., Feng, G., Tewolde, H., Zhang, X., Jenkins, J., Shankle, M. (2024). Application of UAV multispectral imaging to monitor soybean growth with yield prediction through machine learning. *Agronomy*, 14(4), 672.
- Shepherd, M. J., Lindsey, L. E., Lindsey, A. J. (2018). Soybean canopy cover measured with canopeo compared with light interception. *Agricultural & Environmental Letters*, 3(1), 180031.
- Shi, Y., Thomasson, J. A., Murray, S. C., Pugh, N. A., Rooney, W. L., Shafian, S., Rajan, N., Rouze, G., S. Morgan, C. L., Neely, H. L., Rana, A., Bagavathiannan, M. V., Henrickson, J., Bowden, E., Valasek, J., Olsenholter, J., Bishop, M. P., Sheridan, R., Putman, E. B., Popescu, S., Burks, T., Cope, D., Ibrahim, A., McCutchen, B.F., Baltensperger, D.D., Avant, R.V., Vidrine, M., Yang, C. (2016). Unmanned aerial vehicles for high-throughput phenotyping and agronomic research. *PLoS ONE*, 11(7), e0159781.
- Shu, M., Shen, M., Zuo, J., Yin, P., Wang, M., Xie, Z., Tang, J., Wang, R., Li, B., Yang, X., Ma, Y. (2021). The application of UAV-based hyperspectral imaging to estimate crop traits in maize inbred lines. *Plant Phenomics*, 9890745.
- Sinclair, T.R., R.C. Muchow. (1999). Radiation use efficiency. *Advances in Agronomy*, 65, 215-265.
- Singh, A., Ganapathysubramanian, B., Singh, A.K., Sarkar, S. (2016). Machine learning for high-throughput stress phenotyping in plants. *Trends in Plant Science*, 21(2), 110-124.
- Specht, J. E., Diers, B. W., Nelson, R. L., Francisco, J., de Toledo, F., Torrion, J. A., Grassini, P. (2014). Soybean. In: Smith, S., Diers, B. W., Specht, J. E., Carver, B. eds. *Yield gains in major U.S. field crops*. Madison, WI: American Society of Agronomy, Inc., Crop Science Society of America, Inc., and Soil Science Society of America, Inc. 311-356.
- Srebrić, M. (2013). Oplemanjivanje soje ukrštanjem u punom srodstvu u cilju povećanja prinosa zrna. Univerzitet u Beogradu, Poljoprivredni fakultet. Doktorska disertacija.
- Srebrić, M., Perić, V. (2014). Promene komponenti prinosa zrna sestrinskih linija soje u uslovima suše. *Selekcija i semenarstvo*, 20(1), 37-44.
- Sun, J., Rutkoski, J. E., Poland, J. A., Crossa, J., Jannink, L., Sorrells, M. E. (2017). Multitrait, random regression, or simple repeatability model in high-throughput phenotyping data improve genomic prediction for wheat grain yield. *The Plant Genome*, 10(2).
- Sun, Y., Luan, H., Qi, Z., Shan, D., Liu, C., Hu, G., Chen, Q. (2012). Mapping and meta analysis of height QTLs in soybean. *Legume Genomics and Genetics*, 3(1), 1-7.
- Sun, Z.X., Su, C., Yun, J., Jiang, Q., Wang, L., Wang, Y., Cao, D., Zhao, F., Zhao, Q., Zhang, M., Zhou, B., Zhang, L., Kong, F., Liu, B., Tong, Y., Li, X. (2019). Genetic improvement of the shoot architecture and yield in soya bean plants via the manipulation of GmmiR156b. *Plant Biotechnology Journal*, 17, 50-62.
- Tamagno, S., Sadras, V. O., Ortez, O. A., Ciampitti, I. A. (2020). Allometric analysis reveals enhanced reproductive allocation in historical set of soybean varieties. *Field Crops Research*, 248, 107717.

- Tao, H., Feng, H., Xu, L., Miao, M., Long, H., Yue, J., Li, Z., Yang, G., Yang, X., Fan, L. (2020). Estimation of crop growth parameters using UAV-based hyperspectral remote sensing data. *Sensors*, 20, 1296.
- Taški-Ajduković, K., Đorđević, V., Vidić, M., Vučaković, M. (2010). Subunit composition of seed storage proteins in high protein soybean genotypes. *Pesquisa Agropecuária Brasileira*, 45 (7), 721-729.
- Thompson, C.N., Guo, W., Sharma, B., Ritchie, G.L. (2019). Using normalized difference red edge index to assess maturity in cotton. *Crop Science*, 59(5), 2167-77.
- Tilly, N., Aasen, H., Bareth, G. (2015). Fusion of plant height and vegetation indices for the estimation of barley biomass. *Remote Sensing*, 7, 11449-80.
- Tilly, N., Hoffmeister, D., Cao, Q., Huang, S., Lenz-Wiedemann, V., Miao, Y., Bareth, G. (2014). Multi-temporal crop surface models: Accurate plant height measurement and biomass estimation with terrestrial laser scanning in paddy rice. *Journal of Applied Remote Sensing*, 8, 1-23.
- Trussell, H.J., Vrheil, M.J., Saber, E. (2005). Color image processing. *IEEE Signal Processing Magazine*, 22, 14-22.
- Tsouros, D.C., Bibi, S., Sarigiannidis, P.G. (2019). A review on UAV-based applications for precision agriculture. *Information*, 10, 349.
- Tu, Y.X., Bian, M., Wan, Y.K., Fei, T. (2018). Tea cultivar classification and biochemical parameter estimation from hyperspectral imagery obtained by UAV. *PeerJ*, 6, e4858.
- Turner, D., Lucieer, A., Watson, C. (2012). An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (UAV) imagery, based on structure from motion (SfM) point clouds. *Remote Sensing*, 4, 1392-1410.
- Ustin, S.L., Gamon, J.A. (2010). Remote sensing of plant functional types. *New Phytologist*, 186, 795-816.
- Ustun, A., Allen, F.L., English, B.C. (2001). Genetic progress in soybean of the U.S. Midsouth. *Crop Science*, 41, 993-998.
- Vala, A.G., Tomar, R., Rathod, P.J. (2023). Speed breeding: Accelerating crop improvement through controlled environments, genetics, and high-throughput phenotyping. *International Journal of Advanced Research in Science, Engineering and Technology*, 10(5), 746-9.
- van Eeuwijk, F. A., Bustos-Korts, D., Millet, E. J., Boer, M. P., Kruijer, W., Thompson, A., Malosetti, M., Iwata, H., Quiroz, R., Kuppe, C., Muller, O., Blazakis, K. N., Yu, K., Tardieu, F., Chapman, S. C. (2019). Modelling strategies for assessing and increasing the effectiveness of new phenotyping techniques in plant breeding. *Plant Science*, 282, 23-39.
- Vega, C.R.C., Andrade, F.H., Sadras, V.O., (2001). Reproductive partitioning and seed set efficiency in soybean, sunflower and maize. *Field Crop Research*, 72, 163-175.
- Villareal, M.K., Tongco, A.F., Maja, J.M.J. (2020). Winter wheat crop height estimation using small unmanned aerial system (sUAS). *Agricultural Sciences*, 11, 355-368.
- Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468-3478.
- Virdi, K. S., Sreekanta, S., Dobbels, A., Haaning, A., Jarquin, D., Stupar, R. M., Lorenz, A. J., Muehlbauer, G. J. (2023). Branch angle and leaflet shape are associated with canopy coverage in soybean. *The Plant Genome*, 16(2), e20304.

Virlet, N., Sabermanesh, K., Sadeghi-Tehran, P., Hawkesford, M.J. (2017). Field scanalyzer: An automated robotic field phenotyping platform for detailed crop monitoring. *Functional Plant Biology*, 44, 143-153.

Vogel, J.T., Liu, W., Olhoft, P., Crafts-Brandner, S.J., Pennycooke, J.C., Christiansen, N. (2021) Soybean yield formation physiology-a foundation for precision breeding based improvement. *Frontiers in Plant Science*, 12, 719706.

Wahab, I., Hall, O., Jirström, M. (2018). Remote sensing of yields: Application of UAV imagery-derived NDVI for estimating maize vigor and yields in complex farming systems in Sub-Saharan Africa. *Drones*, 2(3), 28.

Walter, J., Edwards, J., McDonald, G., Kuchel, H. (2018). Photogrammetry for the estimation of wheat biomass and harvest index. *Field Crops Research*. 216, 165-174.

Wang, C., Feng, M.C., Yang, W.D., Ding, G.W., Sun, H., Liang, Z.Y., Xie, J.K., Qiao, X.X. (2016b). Impact of spectral saturation on leaf area index and above-ground biomass estimation of winter wheat. *Spectroscopy Letters*, 49(4), 241-248.

Wang, L., Zhou, X., Zhu, X., Dong, Z., Guo, W. (2016a). Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. *Crop Journal*, 4, 212-219.

WebODM. <https://www.opendronemap.org/webodm/>.

Wei, Y., Jin, J., Jiang, S., Ning, S., Liu, L. (2018). Quantitative response of soybean development and yield to drought stress during different growth stages in the Huabei Plain, China. *Agronomy*, 8(7), 97.

Weiss, M., Jacob, F., Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, 111402.

Wells, R. (1991). Soybean growth response to plant density: Relationships among canopy photosynthesis, leaf area, and light interception. *Crop Science*, 31, 755-761.

Westoby, M.J., Brasington, J., Glasser, N.F., Hambrey, M.J., Reynolds, J.M. (2012). Structure-from-Motion photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300-314.

Wijewardana, C., Firas A., Alsajri, J., Irby, T., Krutz, L.J., Golden, B., Henry, W. B., Gao, W., Reddy, K.R. (2019). Physiological assessment of water deficit in soybean using midday leaf water potential and spectral features. *Journal of Plant Interactions*, 14, 1, 533-543.

Wijewardana, C., Henry, W.B., Reddy, K.R. (2017). Evaluation of drought tolerant maize germplasm to induced drought stress. *Journal of the Mississippi Academy of Sciences*, 62, 316-329.

Wilke, N., Siegmann, B., Postma, J. A., Muller, O., Krieger, V., Pude, R., Rascher, U. (2021). Assessment of plant density for barley and wheat using UAV multispectral imagery for high-throughput field phenotyping. *Computers and Electronics in Agriculture*, 189, 106380.

Williams, E., Piepho, H.P., Whitaker, D. (2011). Augmented p-rep designs. *Biometrical Journal*, 53, 19-27.

Wilson, R.F. (2004). Seed composition. In: Boerma, H., Specht, J.E. eds. *Soybeans: improvement, production, and uses*, Third Edition. ASA, CSSA, and SSSA, Madison, 621-668.

Woebbecke, D.M., Meyer, G.E., B.K., V., Mortensen, D.A. (1995). Color indices for weed identification under various soil, residue and lighting conditions. *Transactions of the ASAE*, 38, 259-269.

Xavier, A., Hall, B., Hearst, A.A., Cherkauer, K.A., Rainey, K.M. (2017). Genetic architecture of phenomic-enabled canopy coverage in *Glycine max*. *Genetics*, 206(2), 1081-1089.

Xavier, A., Thapa, R., Muir, W.M., Rainey, K.M. (2018). Population and quantitative genomic properties of the USDA soybean germplasm collection. *Plant Genetic Resources: Characterization and Utilization*, 16(6), 513-523.

Xie, T., Li, J., Yang, C., Jiang, Z., Chen, Y., Guo, L., Zhang, J. (2021). Crop height estimation based on UAV images: Methods, errors, and strategies. *Computers and Electronics in Agriculture*, 185, 106155.

Xu, C., Li, R., Song, W., Wu, T., Sun, S., Hu, S., Han, T., Wu, C. (2021). Responses of branch number and yield component of soybean cultivars tested in different planting densities. *Agriculture*, 11, 69.

Xu, K., Ye, H. (2023). Light scattering in stacked mesophyll cells results in similarity characteristic of solar spectral reflectance and transmittance of natural leaves. *Scientific Reports*, 13.

Xu, Y., Li, P., Zou, C., Lu, Y., Xie, C., Zhang, X., Prasanna, B.M., Olsen, M.S. (2017). Enhancing genetic gain in the era of molecular breeding. *Journal of Experimental Botany*, 68(11), 2641-2666.

Yang, C., Greenberg, S.M., Everitt, J.H., Fernandez, C.J. (2011). Assessing cotton defoliation, regrowth control and root rot infection using remote sensing technology. *International Journal of Agricultural and Biological Engineering*, 4, 1-11.

Yang, F., Fan, Y., Wu, X., Cheng, Y., Liu, Q., Feng, L., Chen, J., Wang, Z., Wang, X., Yong, T., Liu, W., Liu, J., Du, J., Shu, K., Yang, W. (2018). Auxin-to-gibberellin ratio as a signal for light intensity and quality in regulating soybean growth and matter partitioning. *Frontiers in Plant Science*, 9, 56.

Yang, G., Liu, J., Zhao, C., Li, Z., Huang, Y., Yu, H., Xu, B., Yang, X., Zhu, D., Zhang, X., Zhang, R., Feng, H., Zhao, H., Li, Z., Li, H., Yang, H. (2017). Unmanned aerial vehicle remote sensing for field-based crop phenotyping: Current status and perspectives. *Frontiers in Plant Science*, 8, 26.

Yang, Q., Lin, G., Lv, H., Wang, C., Yang, Y., Liao, H. (2021). Environmental and genetic regulation of plant height in soybean. *BMC Plant Biology*, 21(1), 63.

Ying, X. (2019). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168, 022022.

Young, S.N., Kayacan, E., Peschel, J.M. (2019). Design and field evaluation of a ground robot for high-throughput phenotyping of energy sorghum. *Precision Agriculture*, 20, 697-722.

Yu, N., Li, L., Schmitz, N., Tian, L. F., Greenberg, J. A., Diers, B. W. (2016). Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. *Remote Sensing of Environment*, 187, 91-101.

Yu, H., Weng, L., Wu, S., He, J., Yuan, Y., Wang, J., Xu, X., Feng, X. (2024). Time-series field phenotyping of soybean growth analysis by combining multimodal deep learning and dynamic modeling. *Plant Phenomics*, 6, 0158.

Yuan, W., Wijewardane, N.K., Jenkins, S., Bai, G., Ge, Y., Graef, L.G. (2019). Early prediction of soybean traits through color and texture features of canopy RGB imagery. *Scientific Reports*, 9, 14089.

Yuzugullu, O., Marelli, S., Erten, E., Sudret, B., Hajnsek, I. (2017). Determining rice growth stage with X-band SAR: A metamodel based inversion. *Remote Sensing*, 9.

Zhang, C., Kovacs, J.M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. *Precision Agriculture*, 13(6), 693-712.

Zhang, K., Ge, X., Shen, P., Li, W., Liu, X., Cao, Q., Zhu, Y., Cao, W., Tian Y. (2019a). Predicting rice grain yield based on dynamic changes in vegetation indexes during early to mid-growth stages. *Remote Sensing*, 11(4), 387.

Zhang, L. X., Kyei-Boahen, S., Zhang, J., Zhang, M. H., Freeland, T. B., Watson, C. E., Xingmei, L. (2007). Modifications of optimum adaptation zones for soybean maturity groups in the USA. *Crop Management*, 6(1).

Zhang, X., Zhao, J., Yang, G., Liu, J., Cao, J., Li, C., Zhao, X., Gai, J. (2019b). Establishment of plot-yield prediction models in soybean breeding programs using UAV-based hyperspectral remote sensing. *Remote Sensing*, 11(23), 2752.

Zhao, B., Zhang, J., Yang, C., Zhou, G., Ding, Y., Shi, Y., Zhang, D., Xie, J., Liao Q. (2018). Rapeseed seedling stand counting and seeding performance evaluation at two early growth stages based on unmanned aerial vehicle imagery. *Frontiers in Plant Science*, 9, 1362.

Zhaopeng, F., Jiang, J., Gao, Y., Krienke, B., Wang, M., Zhong, K., Cao, Q., Tian, Y., Zhu, Y., Cao, W., Liu, X. (2020). Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle. *Remote Sensing*, 12(3), 508.

Zheng, H., Cheng, T., Zhou, M., Li, D., Yao, X., Tian, Y., Cao, W., Zhu, Y. (2019). Improved estimation of rice aboveground biomass combining textural and spectral analysis of uav imagery. *Precision Agriculture*, 20, 611-29.

Zhou, C., Ye, H., Xu, Z., Hu, J., Shi, X., Hua, S., Yue, J., Yang, G. (2019a). Estimating maize-leaf coverage in field conditions by applying a machine learning algorithm to UAV remote sensing images. *Applied Sciences*, 9, 2389.

Zhou, J. (2023). High-Throughput Plant Phenotyping. In: Zhang, Q. eds. *Encyclopedia of smart agriculture technologies*. Springer, Cham.

Zhou, J., Beche, E., Vieira, C.C., Yungbluth, D., Zhou, J., Scaboo, A., Chen, P. (2022). Improve soybean variety selection accuracy using UAV-based high-throughput phenotyping technology. *Frontiers in Plant Science*, 12, 768742.

Zhou, J., Yungbluth, D., Vong, C. N., Scaboo, A., Zhou, J. (2019b). Estimation of the maturity date of soybean breeding lines using UAV-based multispectral imagery. *Remote Sensing*, 11, 2075.

Zhou, J., Zhou, J., Ye, H., Ali, M. L., Chen, P., Nguyen, H. T. (2021). Yield estimation of soybean breeding lines under drought stress using unmanned aerial vehicle-based imagery and convolutional neural network. *Biosystems Engineering*, 204, 90-103

Zhou, J., Zhou, J., Ye, H., Ali, M. L., Nguyen, H. T., Chen, P. (2020). Classification of soybean leaf wilting due to drought stress using UAV-based imagery. *Computers and Electronics in Agriculture*, 175, 105576.

## PRILOG 1. Lista skraćenica

**ANN** - eng. *artificial neural network*, veštačka neuronska mreža

**B** - eng. *blue*, plavi deo spektra

**BLUP** - eng. *best linear unbiased predictor*, najbolji linearni nepristrasni prediktor

**CGR** - eng. *crop growth rate*, stopa porasta useva

**CHM** - eng. *crop height model*, model visine useva

**CMOS** - eng. *complementary metal-oxide-semiconductor*, komplementarni metal-oksid-poluprovodnik

**CNN** - eng. *convolutional neural networks*, konvolucionna neuronska mreža

**CSM** - eng. *crop surface model*, površinski model useva

**DEM** - digitalni elevacioni model

**DMP** - digitalni model površine

**DMT** - digitalni model terena

**DNN** - eng. *deep neural network*, duboka neuronska mreža

**DPC** - eng. *dense point cloud*, gust oblak tačaka

**G** - eng. *green*, zeleni deo spektra

**GCP** - eng. *ground control point*, kontrolna tačka na zemlji

**GDD** - eng. *growing degree days*, suma aktivnih temperatura

**GPS** - eng. *global positioning system*, globalni pozicioni sistem

**ICE** - eng. *individual conditional expectation*, individualno uslovno očekivanje

**IncNodePurity** - eng. *Increase in Node Purity*, povećanje čistoće čvora

**KK** - kasni genotipovi soje gajeni u kontrolnim uslovima

**KNN** - eng. *k-nearest neighbors*, k-najbliži susedi

**KO** - komparativni ogled

**KS** - kasni genotipovi soje gajeni u sušnim uslovima

**LAI** - eng. *leaf area index*, indeks lisne površine

**LANDSAT** - eng. *Landsat multispectral scanner system*, Landsat multispektralni sistem za skeniranje

**LGOCV** - eng. *leave-group-out cross-validation*, unakrsna validacija sa izostavljanjem grupe

**LiDAR** - eng. *light-detection and ranging system*, sistem detekcije svetlosti i dometa

**LOOCV** - eng. *leave-one-out cross-validation*, izostavi jedan unakrsna validacija

**LUT** - eng. *look up table*, potražite tabelu

**MAC** - eng. *mean absolute correlation*, prosečna apsolutna korelacija

**NIR** - eng. *near-infrared*, blisko-infracrveni deo spektra

**NIRS** - eng. *near-infrared reflectance spectroscopy*, blisko-infracrvena spektroskopija

**PDP** - eng. *partial dependence plot*, grafik delimične zavisnosti

**PLSR** - eng. *partial least square regression*, regresija delimičnih najmanjih kvadrata

**PO** - prethodni ogled

**R** - eng. *red*, crveni deo spektra

**RE** - eng. *red edge*, deo spektra označen kao crvena ivica

**RF** - eng. *random forest*, nasumična šuma

**RK** - rani genotipovi soje gajeni u kontrolnim uslovima

**ROI** - eng. *region of interest*, region od interesa

**RS** - rani genotipovi soje gajeni u sušnim uslovima

**RTK** - eng. *real time kinematics*, kinematika u realnom vremenu

**RUE** - eng. *radiation use efficiency*, iskorišćenost sunčevog zračenja

**SfM** - eng. *structure from motion*, struktura iz pokreta

**SSD** - eng. *single seed descent*, metod potomstva jednog semena

**SVR** - eng. *support vector regression*, regresija vektora podrške

**SWIR** - eng. *shortwave infrared*, kratkotalasno infracrveno zračenje

**PRILOG 2.** Vegetacioni indeksi korišćeni prilikom kreiranja modela za visokopropusnu fenotipizaciju soje

Vegetacioni indeks	Naziv (eng.)	Formula
$g^{\circ\circ}$	<i>Normalized green</i>	$\frac{G}{R + G + B}$
GLI $^{\circ\circ}$	<i>Green leaf index</i>	$\frac{2 * G - R - B}{2 * G + R + B}$
TGI $^{\circ\circ}$	<i>Triangular greenness index</i>	$G - 0.39 * R - 0.61 * B$
ExGR*	<i>Excess green red</i>	$\frac{3 * G - 2.4 * R - B}{R + G + B}$
RGD*	<i>Red green difference</i>	$R - G$
NGRD*	<i>Normalized green red difference</i>	$\frac{G - R}{G + R}$
MNGRD*	<i>Modified normalized green red difference</i>	$\frac{G^2 - R^2}{G^2 + R^2}$
MExG*	<i>Modified excess green</i>	$1.262 * G - 0.884 * R - 0.311 * B$
r $^{\circ\square}$	<i>Normalized red</i>	$\frac{R}{R + G + B}$
b $^{\circ\square}$	<i>Normalized blue</i>	$\frac{B}{R + G + B}$
VARI $^{\circ\square}$	<i>Visible atmospherically resistant index</i>	$\frac{G - R}{G + R - B}$
NGRDI $^{\circ\square}$	<i>Normalized green red difference index</i>	$\frac{G - R}{G + R}$
CIVE $^{\circ\square}$	<i>Color index of vegetation extraction</i>	$0.441 * R - 0.811 * G - 0.385 * B - 18.78745$
ExG $^{\circ\square}$	<i>Excessive green</i>	$2 * g - r - b$
ExR $^{\circ\square}$	<i>Excessive red</i>	$1.4 * r - g$

**PRILOG 2.** (nastavak)

ExG-ExR <sup>□</sup>	<i>Excess green minus excess red index</i>	$ExG - ExR$
DVI <sup>□</sup>	<i>Difference vegetation index</i>	$\frac{NIR}{R}$
GARI <sup>□</sup>	<i>Green atmospherically resistant vegetation index</i>	$\frac{NIR - (G - 1.7 * (B - R))}{NIR + (G + 1.7 * (B - R))}$
GCI <sup>□</sup>	<i>Green chlorophyll index</i>	$\frac{NIR}{G} - 1$
GDVI <sup>□</sup>	<i>Green difference vegetation index</i>	$NIR - G$
GNDVI <sup>□</sup>	<i>Green normalized difference vegetation index</i>	$\frac{NIR - G}{NIR + G}$
GOSAVI <sup>□</sup>	<i>Green optimized soil adjusted vegetation index</i>	$\frac{NIR - G}{NIR + G + 0.16}$
GRVI <sup>□</sup>	<i>Green ratio vegetation index</i>	$\frac{NIR}{G}$
GSAVI <sup>□</sup>	<i>Green soil adjusted vegetation index</i>	$1.5 * \frac{NIR - G}{NIR + G + 0.5}$
IPVI <sup>□</sup>	<i>Infrared percentage vegetation index</i>	$\frac{NIR}{NIR + R}$
MNLI <sup>□</sup>	<i>Modified non-linear vegetation index</i>	$\frac{1.5 * (NIR^2 - R)}{0.5 * (NIR^2 + R)}$
MSAVI <sup>□</sup>	<i>Modified soil adjusted vegetation index</i>	$\frac{2 * NIR + 1 - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - F)}}{2}$
MSR <sup>□</sup>	<i>Modified simple ratio</i>	$\frac{\frac{NIR}{R} - 1}{\sqrt{\frac{NIR}{R}} + 1}$
NLI <sup>□</sup>	<i>Non-linear vegetation index</i>	$\frac{NIR^2 - R}{NIR^2 + R}$

**PRILOG 2.** (nastavak)

NDVI <sup>○□</sup>	<i>Normalized difference vegetation index</i>	$\frac{NIR - R}{NIR + R}$
OSAVI <sup>○□</sup>	<i>Optimized Soil Adjusted vegetation index</i>	$\frac{NIR - R}{NIR + R + 0.16}$
RDVI <sup>○□</sup>	<i>Renormalized Difference vegetation index</i>	$\frac{NIR - R}{\sqrt{NIR + R}}$
SAVI <sup>○□</sup>	<i>Soil adjusted vegetation index</i>	$\frac{1.5 * (NIR - G)}{0.5 * (NIR + G)}$
SR <sup>○□</sup>	<i>Simple ratio index</i>	$\frac{NIR}{R}$
TDVI <sup>○□</sup>	<i>Transformed difference vegetation index</i>	$\frac{1.5 * (NIR - R)}{\sqrt{NIR^2 + R + 0.5}}$
NDRE <sup>○□</sup>	<i>Normalized difference red-edge</i>	$\frac{NIR - RE}{NIR + RE}$
2G-R-B <sup>□</sup>	/	$2 * G - R - B$
NGRVI <sup>□</sup>	<i>new green-red vegetation index</i>	$\frac{G^2 - R^2}{G^2 + R^2}$
BNDVI <sup>□</sup>	<i>Blue normalized difference vegetation index</i>	$\frac{NIR - B}{NIR + B}$
EVI <sup>□</sup>	<i>Enhanced Vegetation Index</i>	$2.5 * \frac{NIR - R}{NIR + 6 * R - 7.5 * B + 1}$
LAI <sup>□</sup>	<i>Leaf area index</i>	$3.618 * EVI - 0.118$

Indeksi korišćeni za kreiranje modela za predikciju: \* broja biljaka; <sup>○</sup> biomase i <sup>□</sup> prinosa soje

**PRILOG 3.** Rana grupa genotipova soje korišćena u drugoj fazi istraživanja

Genotip	Grupa zrenja	Poreklo	Boja cveta	Boja dlačica	Tip stabla
NS Kaća	ooo	Srbija	ljubičasta	bela	semideterminant
Fortuna	oo	Srbija	ljubičasta	smeđa	indeterminant
Panonija 8	oo	#NA	ljubičasta	smeđa	indeterminant
Blackstar	oo	Srbija	bela	smeđa	indeterminant
NS Alfa	oo	Srbija	ljubičasta	bela	indeterminant
Frajla	oo	Srbija	ljubičasta	bela	semideterminant
Lepotica	oo	Srbija	bela	bela	indeterminant
L-200142	oo	Srbija	ljubičasta	bela	indeterminant
L-200192	oo	Srbija	ljubičasta	bela	indeterminant
Maple Arrow	oo	Kanada	ljubičasta	smeđa	indeterminant
CM-048	oo	US	ljubičasta	bela	semideterminant
BS-274	oo	#NA	ljubičasta	bela	indeterminant
Konuso	oo	Japan	ljubičasta	smeđa	indeterminant
Selecta 201	oo	Rusija	ljubičasta	smeđa	semideterminant
Valenta	oo	Rusija	bela	bela	indeterminant
Dana	oo	Srbija	ljubičasta	bela	indeterminant
Biser	oo	Srbija	ljubičasta	smeđa	indeterminant
Gazela	oo	Srbija	ljubičasta	bela	indeterminant
Spartakus	oo	#NA	bela	bela	semideterminant
Black Tokyo	oo	Japan	bela	smeđa	indeterminant
Padua	oo	Severna Amerika	ljubičasta	smeđa	semideterminant
Secca	ooo	Severna Amerika	ljubičasta	smeđa	indeterminant
Proteus	oo	Kanada	ljubičasta	smeđa	semideterminant
Danica	oo	Hrvatska	bela	bela	semideterminant
Korana	oo	Hrvatska	ljubičasta	smeđa	determinant
Krajina	oo	Srbija	ljubičasta	bela	indeterminant
Herb 91	oo	#NA	ljubičasta	smeđa	indeterminant
Kato	ooo	Japan	ljubičasta	smeđa	indeterminant

**PRILOG 3. (nastavak)**

Bydgoska 071	oo	Poljska	ljubičasta	smeđa	semideterminant
Zarja	oo	Bugarska	ljubičasta	smeđa	determinant
Bei Feng No. 3	oo	Kina	ljubičasta	smeđa	indeterminant
Itocista	oo	Poljska	ljubičasta	smeđa	semideterminant
Lada	oo	Rusija	bela	smeđa	indeterminant
Toyokomachi	oo	Japan	ljubičasta	smeđa	indeterminant
Toyomusume	oo	Japan	ljubičasta	smeđa	indeterminant
Caloria	oo	Nemačka	ljubičasta	smeđa	indeterminant
Acme	ooo	Kanada	ljubičasta	smeđa	semideterminant
Giesenska	ooo	#NA	ljubičasta	smeđa	indeterminant
Grignon 37	ooo	Francuska	ljubičasta	smeđa	indeterminant
Grignon 48	ooo	Francuska	ljubičasta	smeđa	indeterminant
OAC Vision	ooo	Kanada	ljubičasta	smeđa	semideterminant
Record North	ooo	Rusija	ljubičasta	smeđa	determinant
Sibniik 315	ooo	Rusija	ljubičasta	smeđa	semideterminant
Timirjazevskaja 144	ooo	Rusija	bela	smeđa	indeterminant
Kamianetz	oo	Francuska	ljubičasta	smeđa	indeterminant
Nen Tsjan Da Doau	oo	Kina	ljubičasta	smeđa	indeterminant
Kamishunbetzu	ooo	Japan	ljubičasta	smeđa	indeterminant
Fiskeby V	ooo	Švedska	ljubičasta	smeđa	indeterminant
Bravalla	ooo	Švedska	ljubičasta	smeđa	indeterminant
Omega Vinnytska	oo	Ukrajina	bela	smeđa	semideterminant
Oriana	oo	Ukrajina	ljubičasta	bela	indeterminant
Princess	oo	Ukrajina	bela	smeđa	indeterminant
Pando	oo	Koreja	ljubičasta	smeđa	indeterminant
I.K.A.R. 278	ooo	#NA	ljubičasta	smeđa	indeterminant
Gracia	ooo	Srbija	bela	smeđa	indeterminant
Jelica	oo	Srbija	ljubičasta	bela	indeterminant
Antonia	ooo	#NA	ljubičasta	smeđa	indeterminant

**PRILOG 3. (nastavak)**

Cristina TD	oo	Rumunija	ljubičasta	bela	indeterminant
Sigalia	oo	Francuska	ljubičasta	smeđa	indeterminant
Nicola TD	oo	Rumunija	ljubičasta	bela	indeterminant
Oana F	oo	Rumunija	ljubičasta	bela	indeterminant
Ovidiu F	oo	Rumunija	bela	smeđa	indeterminant
Carla TD	oo	Rumunija	ljubičasta	smeđa	semideterminant
Eugen	oo	Rumunija	ljubičasta	smeđa	indeterminant
Felix	oo	Rumunija	ljubičasta	smeđa	indeterminant
Perla	ooo	Rumunija	ljubičasta	smeđa	semideterminant
Onix	oo	Rumunija	ljubičasta	smeđa	indeterminant
Larisa	oo	#NA	ljubičasta	smeđa	indeterminant
Ada TD	oo	Rumunija	ljubičasta	smeđa	indeterminant
Bia TD	oo	Rumunija	ljubičasta	smeđa	indeterminant
Vidra	oo	Srbija	bela	bela	indeterminant
Tena	oo	Hrvatska	ljubičasta	bela	semideterminant
GL Melanie	ooo	Austrija	ljubičasta	smeđa	indeterminant
GL Hermine	oo	Austrija	ljubičasta	bela	determinant
Josefine	oo	Austrija	bela	smeđa	indeterminant
Christine	oo	Austrija	ljubičasta	smeđa	indeterminant
Mauthnerov Velkozrun	ooo	#NA	ljubičasta	bela	indeterminant
Mandin Kajon	oo	#NA	ljubičasta	bela	indeterminant
Grignon 14	oo	#NA	ljubičasta	smeđa	semideterminant
Gatersleben 45	ooo	#NA	ljubičasta	smeđa	indeterminant
Soja 804	ooo	#NA	bela	smeđa	semideterminant
Soja 809	ooo	#NA	bela	smeđa	indeterminant
Soja 832	ooo	#NA	bela	smeđa	semideterminant
Zolta Przebedowska	ooo	#NA	ljubičasta	smeđa	indeterminant
Naya	oo	Kanada	ljubičasta	smeđa	indeterminant
Asuka	oo	#NA	ljubičasta	smeđa	semideterminant

**PRILOG 3. (nastavak)**

Moldavskaja 65	oo	Moldavija	ljubičasta	smeđa	indeterminant
Solena	ooo	#NA	ljubičasta	smeđa	indeterminant
Lissabon	ooo	#NA	ljubičasta	smeđa	indeterminant
Holesavska	oo	#NA	ljubičasta	smeđa	indeterminant
S17l2519	oo	#NA	ljubičasta	smeđa	indeterminant
Amadea	oo	#NA	ljubičasta	smeđa	indeterminant
Bosa	oo	#NA	ljubičasta	bela	indeterminant
Brunensis	oo	#NA	ljubičasta	smeđa	indeterminant
Regina	oo	#NA	ljubičasta	smeđa	indeterminant
S17l2515	oo	#NA	ljubičasta	smeđa	semideterminant
Coment	oo	#NA	ljubičasta	smeđa	indeterminant
ES Commandor	ooo	Francuska	ljubičasta	smeđa	semideterminant
Kitty	oo	#NA	ljubičasta	smeđa	semideterminant
Ezra	oo	#NA	ljubičasta	smeđa	indeterminant
Gallec	ooo	Austrija	ljubičasta	smeđa	indeterminant
Galice	ooo	Austrija	ljubičasta	smeđa	indeterminant
Toutatis	ooo	Austrija	ljubičasta	smeđa	semideterminant
Protibus	ooo	Austrija	ljubičasta	smeđa	semideterminant
Naskia	ooo	Austrija	ljubičasta	smeđa	indeterminant
NS Albus	oo	Srbija	ljubičasta	bela	indeterminant
Darina TD	oo	Rumunija	ljubičasta	smeđa	indeterminant
Favorit	ooo	Srbija	ljubičasta	smeđa	determinant
Miruna TD	oo	Rumunija	ljubičasta	bela	semideterminant
Xonia	oo	Italija	ljubičasta	smeđa	semideterminant
Lenka	oo	Kanada	ljubičasta	smeđa	semideterminant
Obélix	ooo	Austrija	ljubičasta	smeđa	semideterminant
NS Virtus	oo	Srbija	ljubičasta	smeđa	semideterminant
Prima	oo	#NA	ljubičasta	smeđa	indeterminant
Danica HR	oo	Hrvatska	bela	bela	indeterminant

**PRILOG 3. (nastavak)**

Dušica	oo	#NA	ljubičasta	smeđa	indeterminant
Bettina	oo	#NA	ljubičasta	smeđa	semideterminant

**PRILOG 4.** Kasna grupa genotipova soje korišćena u drugoj fazi istraživanja

Genotip	Grupa zrenja	Poreklo	Boja cveta	Boja dlačica	Tip stabla
Galina	o	Srbija	ljubičasta	bela	indeterminant
NS Atlas	o	Srbija	ljubičasta	bela	indeterminant
NS Maximus	o+	Srbija	bela	bela	indeterminant
Alisa	o	Srbija	bela	bela	indeterminant
Afrodita	o	Srbija	ljubičasta	bela	indeterminant
Iva	o	Hrvatska	ljubičasta	bela	indeterminant
Krasnodar 2	o	Rusija	bela	bela	indeterminant
Anica	o	Hrvatska	ljubičasta	bela	indeterminant
Eiko	o	Japan	ljubičasta	smeđa	determinant
Aires	o	Italija	ljubičasta	smeđa	determinant
Trzic Rana	o	Rumunija	ljubičasta	smeđa	semideterminant
Noir des Freres Dippe	o	Francuska	bela	smeđa	indeterminant
Jilin 8978-6	o	Kina	ljubičasta	bela	indeterminant
K 93-600	o	Kina	ljubičasta	bela	indeterminant
Sansindunskaja	oo+	Kina	ljubičasta	bela	indeterminant
Kirowogradskaja 5	o	Ukrajina	bela	smeđa	semideterminant
Smolianka	o	Ukrajina	bela	smeđa	semideterminant
ES Inventor	II	Francuska	ljubičasta	smeđa	indeterminant
Pepita	o	Italija	ljubičasta	smeđa	indeterminant
EM Neve	o	#NA	ljubičasta	bela	determinant
EM Sole	I	#NA	ljubičasta	smeđa	semideterminant
ES Mediator	I	Francuska	ljubičasta	smeđa	indeterminant
Kofu	I	Kanada	ljubičasta	smeđa	indeterminant
Steara	I	Francuska	ljubičasta	bela	semideterminant
Richi	II	Bugarska	bela	bela	indeterminant
Eider	o	Kanada	bela	bela	indeterminant
ES Gladiator	o	Francuska	ljubičasta	bela	indeterminant

**PRILOG 4.** (nastavak)

Bećejka	o	Srbija	ljubičasta	bela	indeterminant
NS Zenit	o	Srbija	ljubičasta	bela	indeterminant
Hogar	I	Srbija	ljubičasta	bela	indeterminant
NS Kraljica	I	Srbija	ljubičasta	bela	semideterminant
NS Princeza	o	Srbija	ljubičasta	bela	indeterminant
Ventis	I	Srbija	bela	smeđa	indeterminant
Trijumf	II	Srbija	ljubičasta	bela	indeterminant
Victoria	I	Srbija	ljubičasta	bela	indeterminant
Vojvodanka	II	Srbija	ljubičasta	bela	indeterminant
Zita	II	Srbija	ljubičasta	bela	semideterminant
Regnum	II	Srbija	ljubičasta	bela	semideterminant
NS-L-510016	I	Srbija	ljubičasta	smeđa	semideterminant
NS-L-510017	I	Srbija	ljubičasta	smeđa	indeterminant
Venera	II	Srbija	ljubičasta	bela	semideterminant
NS Vasa	II	Srbija	bela	smeđa	semideterminant
NS-L-520019	II	Srbija	ljubičasta	bela	indeterminant
NS-L-510049	I	Srbija	bela	smeđa	indeterminant
NS Milan	I	Srbija	ljubičasta	bela	indeterminant
Belka	o	Srbija	ljubičasta	bela	indeterminant
Primus	o	#NA	ljubičasta	smeđa	indeterminant
NS-L-201196	o	Srbija	bela	bela	indeterminant
Kolubara	o	Srbija	ljubičasta	bela	semideterminant
Asitka	o	#NA	ljubičasta	smeđa	indeterminant
Cypress	o	#NA	bela	bela	semideterminant
Daciana	o	Rumunija	ljubičasta	bela	determinant
Rubin	II	Srbija	ljubičasta	smeđa	determinant
Fabiana F	I	Rumunija	ljubičasta	bela	semideterminant
Valjevka	o	Srbija	bela	bela	semideterminant

**PRILOG 4.** (nastavak)

ES pallador	I	Francuska	bela	bela	indeterminant
NS Zora	I	Srbija	ljubičasta	bela	semideterminant
ES Mentor	I	Francuska	ljubičasta	smeđa	indeterminant
Kolos	II	Srbija	ljubičasta	smeđa	semideterminant
Tajfun	oo+	Srbija	ljubičasta	smeđa	determinant
NS-L-420073	II	Srbija	ljubičasta	bela	semideterminant
NS Sirius	II	Srbija	ljubičasta	bela	indeterminant
Proteinka	o	Srbija	ljubičasta	bela	indeterminant
Dumbar	o	#NA	ljubičasta	bela	semideterminant
Buenos	I/II	#NA	ljubičasta	smeđa	indeterminant
ZPL 1	o	Srbija	ljubičasta	bela	indeterminant
Korus	I	Kanada	ljubičasta	smeđa	semideterminant
Indicator	I	Francuska	ljubičasta	smeđa	semideterminant
NS Mercury	I	Srbija	ljubičasta	smeđa	semideterminant
Dukat	II	Srbija	ljubičasta	smeđa	indeterminant
Srebina	II	Bugarska	bela	bela	semideterminant
Vigo	II	Rumunija	ljubičasta	bela	indeterminant
Triumf	I	#NA	ljubičasta	smeđa	indeterminant
Danubiana	I	Rumunija	bela	smeđa	indeterminant
Columna	II	Rumunija	ljubičasta	smeđa	indeterminant
Crina F	o	Rumunija	bela	bela	semideterminant
Camelia F	o	Rumunija	ljubičasta	smeđa	indeterminant
Isidor	I	Francuska	ljubičasta	smeđa	indeterminant
NS Aurora	o	Srbija	ljubičasta	bela	indeterminant
Harizma	II	Srbija	ljubičasta	smeđa	semideterminant
Adonai	I/II	#NA	ljubičasta	bela	indeterminant
Novsadska Rana	o	Srbija	ljubičasta	smeđa	semideterminant
NS-L-404266	o	Srbija	ljubičasta	bela	indeterminant
Vera	I/II	Srbija	ljubičasta	bela	indeterminant

**PRILOG 4. (nastavak)**

Sirena	o	Srbija	ljubičasta	bela	semideterminantan
Bačka	o	Srbija	ljubičasta	bela	indeterminantan
11-0015-B-B-181-002-006-B-008	o	#NA	ljubičasta	smeđa	indeterminantan
Neoplanta	II	Srbija	ljubičasta	bela	indeterminantan
DH 4173	II	Kanada	ljubičasta	smeđa	indeterminantan

**PRILOG 5.** Mehanički sastav, % organske materije i retencija vlage u zemljištima korišćenim u okviru druge faze istraživanja. RS (rana grupa-suša), KS (kasna grupa-suša), RK (rana grupa-kontrola), KK (kasna grupa-kontrola)

		2020				2021			
Ogled		RS	KS	RK	KK	RS	KS	RK	KK
Krupan pesak (%) 2-0,2 mm		1,31	0,77	0,88	0,96	0,7	0,78	0,46	0,41
Sitan pesak (%) 0,2-0,02 mm		72,53	64,87	46,8	42,24	60,82	68,1	44,26	44,91
Prah (%) 0,02-0,002 mm		14,28	19,08	28,16	30,84	19,4	15,96	24,28	27,04
Glina (%) <0,002 mm		11,88	15,28	24,16	25,96	19,08	15,16	31	27,64
Organska materija (%)		0,99	1,34	2,57	2,73	1,93	1,33	2,67	2,45
Retencija vlage (% vol.)	<b>0,33 bar</b>	14,16	16,9	26,32	27,15	21,58	17,97	28,71	28,04
	<b>6,25 bar</b>	7,49	8,92	15,7	16,04	11,1	9,2	17,82	17,1
	<b>15 bar</b>	6,41	7,73	14,54	14,54	9,56	7,74	15,88	15,04

## Biografija autora

Predrag (Dragoslav) Ranđelović, master inženjer poljoprivrede, rođen je 16. 3. 1994. godine u Novom Sadu. Osnovnu školu Miroslav Antić iz Futoga završio je 2009. godine a opšti smer gimnazije Laza Kostić 2013. godine. Iste godine je upisao Poljoprivredni fakultet Univerziteta u Novom Sadu, smer Ratarstvo i povrtarstvo. Diplomski rad pod nazivom „Efekat površinskog i potpovršinskog navodnjavanja kapanjem na prinos, morfološke karakteristike i komponente prinosa crnog luka“ odbranio je 2017. godine sa ocenom 10. Prosek ocena na osnovnim studijama bio je 9,10. Tokom studija bio je stipendista Ministarstva prosvete i sporta Republike Srbije. Master studije je upisao 2017. godine na matičnom fakultetu gde je i odbranio master rad pod nazivom „Indirektne metode u obračunu potreba kukuruza za vodom u klimatskim uslovima Vojvodine“ sa ocenom 10. Prosek ocena na master studijama iznosio je 9,86.

Doktorske studije na modulu Ratarstvo i povrtarstvo, Poljoprivrednog fakulteta, Univerziteta u Beogradu upisao je 2018. godine. Od 06.2.2018 godine je zaposlen u Institutu za ratarstvo i povrtarstvo u Novom Sadu, Institutu od nacionalnog značaja za Republiku Srbiju kao stručni saradnik na poslovima oplemenjivanja soje. U zvanje istraživač pripravnik izabran je 2019. godine a zvanje istraživač saradnik za naučnu oblast Biotehničke nauke, užu naučnu oblast Genetika i oplemenjivanje stekao je 25.11.2021. godine. Do sada je bio angažovan na projektu finansiranom od strane Ministarstva prosvete, nauke i tehnološkog razvoja „Interdisciplinarni pristup stvaranju novih sorti soje i unapređenje tehnologije gajenja i dorade semena“ (TR 31022). Pored toga učestvovao je na dva međunarodna projekta „*Increasing the efficiency and competitiveness of organic crop breeding-ECOBREED*“ (broj projekta: 771367) i „*Breeding forage and grain legumes to increase EU's and China's protein self-sufficiency-EUCLEG*“ (broj projekta: 727312) u okviru programa Evropske unije, Horizon 2020. Trenutno je učesnik nacionalnog projekta „*Soybean yield prediction using multi-omics data integration-SoyPredict*“ (broj projekta: 6788) Fonda za nauku Republike Srbije i tri projekta iz Horizon Europe programa Evropske unije: „*Integrated services supporting a sustainable agroecological transition-AgroServ*“ (broj projekta: 101058020) zatim „*Breeding European legumes for increased sustainability-BELIS*“ (broj projekta: 101081878) i „*Valorization legumes related ecosystem services-VALERECHO*“ (broj projekta: 101135472).

Kao autor ili koautor do sada je objavio preko 60 naučnih radova u celini ili izvodu među kojima je i pet radova koji su publikovani u međunarodnim časopisima koji se nalaze na SCI (Science Citation Index) listi.

Član je Društva genetičara Srbije. Govori, čita i piše engleski jezik.

## **Izjava o autorstvu**

Ime i prezime autora Predrag Randelović

Broj indeksa RA180050

### **Izjavljujem**

da je doktorska disertacija pod naslovom

Razvoj modela za visokopropusnu fenotipizaciju kvantitativnih osobina u oplemenjivačkim kolekcijama soje

- rezultat sopstvenog istraživačkog rada;
- da disertacija u celini ni u delovima nije bila predložena za sticanje druge diplome prema studijskim programima drugih visokoškolskih ustanova;
- da su rezultati korektno navedeni i
- da nisam kršio/la autorska prava i koristio/la intelektualnu svojinu drugih lica.

### **Potpis autora**

U Beogradu, \_\_\_\_\_

\_\_\_\_\_

## **Izjava o istovetnosti štampane i elektronske verzije doktorskog rada**

Ime i prezime autora Predrag Randjelović

Broj indeksa RA180050

Studijski program Ratarstvo i povrtarstvo

Naslov rada Razvoj modela za visokopropusnu fenotipizaciju kvantitativnih osobina u oplemenjivačkim kolekcijama soje

Mentor Prof dr. Slaven Prodanović

Ijavljujem da je štampana verzija mog doktorskog rada istovetna elektronskoj verziji koju sam predao radi pohranjenja u **Digitalnom repozitorijumu Univerziteta u Beogradu**.

Dozvoljavam da se objave moji lični podaci vezani za dobijanje akademskog naziva doktora nauka, kao što su ime i prezime, godina i mesto rođenja i datum odbrane rada.

Ovi lični podaci mogu se objaviti na mrežnim stranicama digitalne biblioteke, u elektronskom katalogu i u publikacijama Univerziteta u Beogradu.

### **Potpis autora**

U Beogradu, \_\_\_\_\_

## Izjava o korišćenju

Ovlašćujem Univerzitetsku biblioteku „Svetozar Marković“ da u Digitalni repozitorijum Univerziteta u Beogradu unese moju doktorsku disertaciju pod naslovom:

Razvoj modela za visokopropusnu fenotipizaciju kvantitativnih osobina u oplemenjivačkim kolekcijama soje

koja je moje autorsko delo.

Disertaciju sa svim prilozima predao sam u elektronskom formatu pogodnom za trajno arhiviranje. Moju doktorsku disertaciju pohranjenu u Digitalnom repozitorijumu Univerziteta u Beogradu i dostupnu u otvorenom pristupu mogu da koriste svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (Creative Commons) za koju sam se odlučio.

1. Autorstvo (CC BY)
2. Autorstvo – nekomercijalno (CC BY-NC)
- 3. Autorstvo – nekomercijalno – bez prerada (CC BY-NC-ND)**
4. Autorstvo – nekomercijalno – deliti pod istim uslovima (CC BY-NC-SA)
5. Autorstvo – bez prerada (CC BY-ND)
6. Autorstvo – deliti pod istim uslovima (CC BY-SA)

(Molimo da zaokružite samo jednu od šest ponuđenih licenci. Kratak opis licenci je sastavni deo ove izjave).

## Potpis autora

U Beogradu, \_\_\_\_\_

1. **Autorstvo.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence, čak i u komercijalne svrhe. Ovo je najslobodnija od svih licenci.
2. **Autorstvo – nekomercijalno.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu upotrebu dela.
3. **Autorstvo – nekomercijalno – bez prerada.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca ne dozvoljava komercijalnu upotrebu dela. U odnosu na sve ostale licence, ovom licencom se ograničava najveći obim prava korišćenja dela.
4. **Autorstvo – nekomercijalno – deliti pod istim uslovima.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca ne dozvoljava komercijalnu upotrebu dela i prerada.
5. **Autorstvo – bez prerada.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, bez promena, preoblikovanja ili upotrebe dela u svom delu, ako se navede ime autora na način određen od strane autora ili davaoca licence. Ova licenca dozvoljava komercijalnu upotrebu dela.
6. **Autorstvo – deliti pod istim uslovima.** Dozvoljavate umnožavanje, distribuciju i javno saopštavanje dela, i prerade, ako se navede ime autora na način određen od strane autora ili davaoca licence i ako se prerada distribuira pod istom ili sličnom licencom. Ova licenca dozvoljava komercijalnu upotrebu dela i prerada. Slična je softverskim licencama, odnosno licencama otvorenog