

EVALUACIJA METODE PREDIKCIJE POGODNOSTI POLJOPRIVREDNOG ZEMLJIŠTA ZA UZGOJ SOJE KORIŠTENJEM K-NEAREST NEIGHBORS METODE STROJNOG UČENJA

Dorijan RADOČAJ

Fakultet agrobiotehničkih znanosti Osijek, Vladimira Preloga 1, Osijek, Hrvatska
dradocaj@fazos.hr

Mladen JURIŠIĆ

Fakultet agrobiotehničkih znanosti Osijek, Vladimira Preloga 1, Osijek, Hrvatska
mjurisic@fazos.hr

<https://dx.doi.org/10.21857/m16wjcw8r9>

Sažetak

Utvrđivanje pogodnosti poljoprivrednog zemljišta za uzgoj poljoprivrednih kultura glavni je korak u prilagodbi povećanih zahtjeva za hranom uzrokovanim rastom stanovništva, klimatskim promjenama i onečišćenjem okoliša. Najsuvremenije metode određivanja pogodnosti zemljišta za uzgoj poljoprivrednih kultura najčešće se temelje na višekriterijskoj analizi temeljenoj na geografskom informacijskom sustavu (GIS), u kombinaciji s naprednim postupcima ponderiranja kriterija. Međutim, ta metoda ima neke izrazite nedostatke, od kojih je najočitiji pretjerano oslanjanje na korisnikovu subjektivnu procjenu odabira i ponderiranja kriterija. Cilj je studije evaluirati predloženi novi pristup predviđanja pogodnosti poljoprivrednog zemljišta za uzgoj soje primjenom metode K-nearest neighbors (KNN). Takav pristup potencijalno nadilazi ograničenja konvencionalne višekriterijske analize GIS povećanjem računalne učinkovitosti, točnosti i objektivnosti predikcije. Metoda predikcije pogodnosti poljoprivrednog zemljišta validirana je za uzgoj soje unutar dva podskupa 50×50 km lociranih u kontinentalnoj biogeoregiji Hrvatske u četverogodišnjem razdoblju tijekom 2017. – 2020. Dva biofizička svojstva vegetacije – indeks lisne površine (LAI) i udio apsorbiranog fotosintetski aktivnog zračenja (FAPAR) – upotrebljavana su za trening i testiranje KNN modela strojnog učenja. Ti podatci, izvedeni iz satelitske misije srednje rezolucije PROBA-V, bili su glavni pokazatelji pogodnosti poljoprivrednog zemljišta za uzgoj soje, s visokom korelacijom sa zdravljem usjeva, prinosom i biomasom u prethodnim studijama. Različite kovarijate klime, tla, topografije i vegetacije upotrebljavane su za uspostavljanje odnosa s uzorcima za obuku, s ukupno 119 kovarijati koje su upotrebljavane po godišnjem predviđanju prikladnosti. KNN je omogućio visoku razinu točnosti predikcije za sve klase pogodnosti po standardu Organizacije za hranu i poljoprivredu Ujedinjenih naroda (FAO). Visoko pogodna klasa pogodnosti za uzgoj soje S1 FAO određena je na rijetko uporabljenom



podskupu A, dok je intenzivno kultivirano poljoprivredno zemljište proizvelo samo manji dio iste klase pogodnosti u podskupu B. Analiza osjetljivosti pokazala je snažan odnos vrijednosti prikladnosti zemljišta za usjeve za soju uzgoja u blizini šuma, što bi moglo ukazivati na koncept agrošumarstva kao novog pristupa gospodarenju poljoprivrednim zemljištem u Hrvatskoj.

Ključne riječi: FAO, okolišne kovarijate, geografski informacijski sustav

Ključna poruka rada: Utvrđivanje pogodnosti poljoprivrednog zemljišta za uzgoj poljoprivrednih kultura glavni je korak u prilagodbi povećanih zahtjeva za hranom. Evaluirani pristup temeljen na strojnom učenju i podatcima daljinskih istraživanja nadilazi ograničenja konvencionalne višekriterijske analize GIS povećanjem računalne učinkovitosti, točnosti i objektivnosti predikcije.

1. Uvod

Odabirom neoptimalnih lokacija za uzgoj usjeva, poljoprivrednici se često okreću upotrebi prekomjernih mineralnih gnojiva i pesticida kako bi postigli željene prinose, oštećujući pritom ekosustav. Utvrđivanje pogodnosti poljoprivrednog zemljišta za glavne vrste usjeva obavezan je proces za učinkovito planiranje gospodarenja poljoprivrednim zemljištem (Sathiyamurthi i sur., 2022). Ovaj je postupak ključna osnova globalno održive poljoprivrede i sigurnosti hrane, ispunjavajući Razvojne ciljeve održivosti Ujedinjenih naroda (Lal i sur., 2021). Održivost sadašnje poljoprivredne proizvodnje suočava se s ozbiljnim globalnim izazovima u obliku brzog rasta stanovništva, klimatskih promjena i sve većeg onečišćenja okoliša. Predviđa se da će ti čimbenici uzrokovati ozbiljan globalni nedostatak hranjivih tvari u hrani do 2050., što će zahtijevati učinkovitije korištenje sadašnjeg poljoprivrednog zemljišta (Serraj i sur., 2018). Sadašnji planovi gospodarenja poljoprivrednim zemljištem često se temelje na zastarjelim okolišnim uvjetima i monetarnim prioritetima, stoga bi njihova nadogradnja trebala biti prvi korak u poboljšanju sustava poljoprivredne proizvodnje. Soja ima posebno rastuću važnost u sustavima plodoreda na globalnoj razini, sa stalnim povećanjem prinosa i površina pod uzgojem u svim regijama svijeta (Galić Subašić, 2018). To ukazuje na visoki prioritet rješavanja problematike ograničenja u određivanju pogodnosti usjeva i učinkovitijih sustava uzgoja soje na globalnoj razini. Osim toga, uzgoj soje ima ključnu ulogu u održavanju biološke raznolikosti i očuvanju zemljišnih resursa. Sustavno razmatranje različitih varijabli poput klimatskih uvjeta, tipova tla i dostupnosti vode ključno je za optimizaciju uzgoja soje i maksimiziranje prinosa uz minimalan utjecaj na okoliš (Wannasek i sur., 2017).

Kako bi se osigurala dugoročna održivost poljoprivrede, nužno je kontinuirano ulagati u istraživanje i razvoj novih tehnologija i pristupa koji će podržati efikasno korištenje resursa,



smanjiti emisije stakleničkih plinova te očuvati biološku raznolikost i zemljишne resurse (Khan i sur., 2021). Sadašnje najsvremenije metode određivanja pogodnosti zemljišta za uzgoj poljoprivrednih kultura najčešće se temelje na višekriterijskoj analizi temeljenoj na geografskom informacijskom sustavu (GIS), u kombinaciji s naprednim postupcima ponderiranja kriterija, poput Analitičkog hierarhijskog procesa (AHP) (Radočaj i Jurišić, 2022). Uspješno su provedena brojna istraživanja pogodnosti zemljišta za uzgoj poljoprivrednih kultura temeljena na višekriterijskoj analizi temeljenoj na GIS-u na temu predikcije pogodnosti poljoprivrednog zemljišta za uzgoj različitih kultura (Dedeođlu i Dengiz, 2019; Han i sur., 2021; Jurišić i sur., 2020). Podaci daljinskog istraživanja iz globalnih satelitskih misija otvorenih podataka bili su među temeljnim izvorima podataka u ovim analizama. Visok stupanj fleksibilnosti u procesu utvrđivanja pogodnosti jedna je od glavnih prednosti višekriterijske analize temeljene na GIS-u koja se globalno široko primjenjuje. Međutim, ova metoda ima neke izrazite nedostatke, koji su do sada samo djelomično riješeni. Najočitiji je pretjerano oslanjanje na korisnikovu subjektivnu procjenu odabira i važnosti kriterija, posebice unutar AHP procesa (Radočaj i sur., 2021). AHP je ograničen na pet do devet kriterija ili skupina kriterija prema preporukama autora Saaty i Ozdemir (2003), tako da uključivanje dodatnih važnih kovarijata rezultira složenijom obradom. Poslijedno, cijela je metoda podložnija pogreškama u usporedbi parova kriterija i određivanju težine kriterija. Istovremeno, uključivanje ograničenog broja okolišnih čimbenika rezultira nepotpunim prikazom pogodnosti zemljišta za uzgoj poljoprivrednih kultura. Validacija točnosti konvencionalnih rezultata višekriterijskih analiza temeljenih na GIS-u često ne postoji, s nekim uspješno izvedenim pristupima koji koriste podatke o prinosu temeljene na tlu (Dedeođlu i Dengiz, 2019) ili indeks vegetacije dobivene putem satelita (Frampton i sur., 2013), koji uključuju samo segment pogodnost poljoprivrednog zemljišta u procesu validacije. Mogućnost objektivnog i lako dostupnog postupka validacije za rezultate pogodnosti poljoprivrednog zemljišta osigurala bi izravnu usporedbu između modela predikcije i rezultata pogodnosti više vrsta usjeva. Ovo bi također osiguralo integraciju različitih rezultata pogodnosti zemljišta za uzgoj poljoprivrednih kultura u jedinstveni temelj upravljanja poljoprivrednim zemljištem.

Algoritmi strojnog učenja predstavljaju moguće rješenje za gore navedena ograničenja višekriterijske analize temeljene na GIS-u u procjeni pogodnosti zemljišta za uzgoj poljoprivrednih kultura (Chlingaryan i sur., 2018). Njihova učinkovitost prvenstveno je uzrokovana sposobnošću integracije složenih čimbenika klime, tla i topografije u model predviđanja, za razliku od konvencionalnih statističkih metoda (Hengl i sur., 2017). Istdobro, od korisnika se ne očekuje da uspostavi odnose između tih podataka. Glavni zadatak korisnika u predviđanju strojnog učenja je određivanje kovarijata koje su relevantne za studiju kako bi se izbjegla redundancija i moguća pristranost zbog netočnog ili irelevantnog odabira kovarijata. Do sada se strojno učenje naširoko koristilo sa satelitski izvedenim indeksima vegetacije za detekciju sustava plodoreda, zdravstvenog stanja usjeva, distribucije vrste usjeva i predikcije prinosa (Radočaj i sur., 2021; Schwalbert i sur., 2020). Tijekom proteklih nekoliko godina, neke inicijative

aplikacije strojnog učenja za procjenu pogodnosti zemljišta za uzgoj poljoprivrednih kultura postigle su obećavajuće, ali ograničene rezultate. Taghizadeh-Mehrjardi i sur. (2020) dokazali su superiornost metoda strojnog učenja u usporedbi s tradicionalnim postupcima određivanja pogodnosti zemljišta za uzgoj poljoprivrednih kultura. Odredili su pogodnost poljoprivrednog zemljišta korištenjem empirijski izračunatog potencijalnog prinosa za pšenicu i ječam, slijedeći specifikacije Organizacije za hranu i poljoprivredu Ujedinjenih naroda (FAO). Primjena FAO standardiziranih klasa pogodnosti široko je priznata kao stabilan postupak procjene pogodnosti poljoprivrednog zemljišta, neovisno o vrsti usjeva i geografskom položaju. Primjena standardiziranih klasa pogodnosti zemljišta za uzgoj poljoprivrednih kultura omogućuje učinkovitu integraciju s postojećim planovima upravljanja poljoprivrednim zemljištem. Također ima prednost usporedbe pogodnosti s drugim vrstama usjeva kako bi se odredile najbolje moguće alternative za optimalnije poljoprivredne subvencije i prilagodbu plodoreda. Međutim, potencijal predikcije strojnog učenja u određivanju pogodnosti poljoprivrednog zemljišta još je uvelike neiskorišten. S postojanjem pouzdanih i globalno dostupnih podataka o obuci, strojno učenje moglo bi predstavljati nov i superioran pristup određivanju konvencionalne pogodnosti zemljišta za uzgoj poljoprivrednih kultura korištenjem višekriterijske analize temeljene na GIS-u. Dok strojno učenje omogućuje veću računsku učinkovitost i točnost u usporedbi s konvencionalnim metodama, postoji izazov osigurati pokazatelje koji pouzdano određuju razine pogodnosti zemljišta za uzgoj poljoprivrednih kultura. Indeks lisne površine (LAI) i udio apsorbiranog fotosintetski aktivnog zračenja (FAPAR) smatraju se komplementarnim biofizičkim svojstvima za procjenu prinosa usjeva, često se koriste kao bitne varijable u procjeni produktivnosti usjeva (Frampton i sur., 2013; Radočaj i sur., 2021). Ova biofizička svojstva vegetacije također su pokazala značajan potencijal kada su se pojedinačno koristila u studijama pogodnosti usjeva. LAI izведен iz proizvoda daljinskog očitavanja bio je u visokoj korelaciji s biomasom usjeva, prinosom i ukupnim statusom usjeva, posebno u ranim fazama rasta (Liu i sur., 2005). FAPAR je pokazao jaku korelaciju s ukupnom proizvodnjom biomase usjeva, njegovim prediktivnim modeliranjem, kao i njegovom vremenskom varijacijom tijekom vegetativnog razdoblja usjeva (Fuster i sur., 2020). Ova biofizička svojstva vegetacije imaju dugoročnu dostupnost u prostornoj rezoluciji od 300 m iz misije PROBA-V, neprimjetno nadograđena na proizvode Sentinel-3 za globalnu i stabilnu upotrebu u budućnosti. Implementacijom indikatora pogodnosti zemljišta za uzgoj poljoprivrednih kultura koji se temelji na multitemporalnim podacima LAI i FAPAR u algoritmima strojnog učenja, postoji značajan potencijal u formiranju računalno učinkovite i globalno dostupne metode procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura. Integracija takvih podataka u sustave upravljanja poljoprivrednom proizvodnjom omogućuje poljoprivrednicima da donose informirane odluke o izboru kultura, optimiziraju upotrebu resursa poput vode i gnojiva te povećaju produktivnost uz istovremeno smanjenje ekološkog otiska poljoprivrede. Osim toga, ovi podaci mogu biti od ključne važnosti za razvoj politika i strategija na razini država ili regija kako bi se osigurala održiva upotreba zemljišta i postizanje ciljeva u pogledu prehrambene sigurnosti i zaštite okoliša. Stoga, istraživanje i implementacija naprednih tehnologija



poput satelitskog promatranja i strojnog učenja imaju ključnu ulogu u transformaciji poljoprivrednog sektora prema održivoj i učinkovitoj budućnosti.

Cilj ove studije bio je evaluirati metodu procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura koju su predložili Radočaj i suradnici (2021) na temelju neovisnog odabira metode strojnog učenja. Ovaj pristup osmišljen je da pojednostavi izračun pogodnosti poljoprivrednog zemljišta na globalnoj razini i da poveća objektivnost predikcije u usporedbi s konvencionalnim pristupom višekriterijskim analizama temeljenim na GIS-u.

2. Materijal i metode

Procjena pogodnosti zemljišta za uzgoj poljoprivrednih kultura provedena je korištenjem GIS softvera otvorenog koda SAGA GIS v7.9.0. Svi ulazni prostorni podaci i procjene pogodnosti georeferencirani su u odnosu na Hrvatski terestrički referentni sustav (HTRS96/TM). Tijek rada predložene metode procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura temelji se na metodologiji predloženoj od strane Radočaja i suradnici (2021) te sadrži dva primarna koraka: 1) prikupljanje i pretprocesiranje prostornih podataka; i 2) strojno učenje predikcije pogodnosti poljoprivrednog zemljišta. Određene su klase pogodnosti zemljišta za uzgoj soje, uz potencijalnu potporu njezine univerzalne primjenjivosti prilagodbama vezanim uz vegetacijsko razdoblje odabrane vrste usjeva.

Područje istraživanja obuhvaća dva podskupa veličine 50 x 50 km koji se nalaze u kontinentalnoj biogeoregiji Hrvatske na području Slavonije i Baranje. Poljoprivreda je jedna od glavnih djelatnosti u kontinentalnoj Hrvatskoj, s poljoprivrednim površinama koje pokrivaju 52,9% njezine ukupne površine prema podacima CORINE 2018 Land Cover. Podskup A karakteriziraju brdoviti tereni i rijetko raspoređene poljoprivredne parcele, često u blizini šuma. Podskup B nalazi se u nizinskom području istočne Hrvatske, tradicionalno se koristi za intenzivnu poljoprivrednu proizvodnju. Soju konzervativno uzgajaju određeni vlasnici zemljišta u oba podskupa, pri čemu je ujedinjenje parcela soje tijekom 2017. – 2020. pokrivalo samo 11,9% odnosno 19,0% poljoprivrednih površina u podskupu A i B (Radočaj i sur., 2021). Najzastupljenija sorta soje na istraživanom području je srednje rana grupa zrelosti 0, s prosječnim vegetacijskim razdobljem od 115-125 dana (Galić Subašić, 2018). Grupa rane zrelosti 00 u podskupu A i srednje kasna grupa zrelosti I u podskupu B periodički se uzgajaju. Uobičajeno vegetativno razdoblje ovih skupina zrelosti soje kreće se od kraja travnja do sredine rujna, pokrivajući dane u godini (DOY) od 120 do 245. Trajanje vegetativnih faza rasta je u rasponu od 35 do 45 dana nakon sjetve. Prema uobičajenim godišnjim anomalijama rasta soje određeno je razdoblje istraživanja od 1. travnja do 31. listopada. Ovim pristupom obuhvaćena su vegetacijska razdoblja svih parcela soje u istraživanom području, neovisno o njihovoj skupini zrelosti i agrotehničkim zahvatima koje su izvršili poljoprivrednici.

Predikcija strojnog učenja i validacija točnosti pogodnosti poljoprivrednog zemljišta za uzgoj soje provedeni su pomoću satelitskih snimki u otvorenom pristupu (Radočaj i sur., 2020). Biofizička svojstva LAI i FAPAR korištена su za obuku modela strojnog učenja pod nadzorom klasifikacije, kao komplementarni i pouzdani pokazatelji prinosa usjeva. Korišteni podaci uključuju 10-dnevne LAI i FAPAR proizvode iz satelitske misije PROBA-V, prostorne razlučivosti 300 m, s web stranice Copernicus Global Land Service za razdoblje od travnja do listopada 2017. – 2020. PROBA-V omogućuje vrlo precizno i dosljedno određivanje biofizičkih svojstava vegetacije, na razini sličnih misija i promatranja sa zemlje (Fuster i sur., 2020). Podaci za obuku i testiranje za procjenu pogodnosti kreirani su prema regularnoj mreži 300 m x 300 m, koja odgovara rasterskim mrežama LAI i FAPAR izvedenim iz PROBA-V. Prostorna razlučivost od 300 m određena je kao prikladna za različita praćenja i namjene upravljanja zemljištem u poljoprivredi na makro razini, predstavljajući srednje i veće poljoprivredne parcele. Pikseli iz referentnih rastera filtrirani su na temelju pokrivenosti prizemnih parcela soje unutar piksela, označenih zasebno za svaku godinu tijekom razdoblja 2017.–2020.

Referentne parcele soje dobivene su od Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju (APPRRR) Republike Hrvatske, a prijavljene su i kontrolirane za dodjelu poljoprivrednih poticaja. Ti su podaci dodatno vizualno pregledani i verificirani pomoću digitalnog ortofota prostorne razlučivosti 0,5 m Državne geodetske uprave. Najmanje 75% pokrivenosti parcela soje utvrđeno je kao prag filtriranja za smanjenje spektralnog miješanja u blizini granice susjednih klasa zemljišnog pokrova. Trening i test podaci kreirani su zasebno za svaku pojedinačnu godinu u razdoblju 2017. – 2020., koristeći podatke zabilježene tijekom vegetativnog razdoblja soje glavnih sorti soje na području istraživanja. Ovaj pristup osigurava robusnost predikcije uzimajući u obzir cjelokupno vegetacijsko razdoblje svih sorti soje prisutnih na području istraživanja. To se očituje u otpornosti na vremenske varijabilnosti rokova sjetve i trajanja pojedinih faza rasta soje. Na te komponente obično utječu brojni abiotički čimbenici, uključujući godišnje vremenske trendove, sustave obrade zemljišta, sustave gnojidbe i navodnjavanja.

Različite komplementarne okolišne kovarijate korištene su za uspostavljanje odnosa između pogodnosti poljoprivrednog zemljišta soje predstavljenog pomoću LAI i FAPAR s uvjetima okoliša u području istraživanja. Četiri primarna čimbenika okoliša koji uvjetuju pogodnost poljoprivrednog zemljišta su klima, tlo, topografija i vegetacija. Za individualne predikcije godišnjih klasa pogodnosti poljoprivrednog zemljišta za uzgoj soje korišteno je ukupno 119 kovarijata, koje se sastoje od 47 kovarijata klime, 24 kovarijata tla, 6 topografskih kovarijata i 42 kovarijata vegetacije (Tablica 1).

Tablica 1. Okolišne kovarijate korištene za predikciju pogodnosti poljoprivrednog zemljišta za uzgoj soje.

Okolišne kovarijate	Naziv	Mjerna jedinica	Izvor podataka
Klima	Srednja mjeseca temperatura zraka	°C	Karger i sur. (2017)
	Najniža mjeseca temperatura zraka	°C	
	Najviša mjeseca temperatura zraka	°C	
	Ukupne mjesecne padaline	mm	
	Bioklimatske varijable	/	
Tlo	Ukupni dušik	cg kg ⁻¹	Hengl i sur. (2017)
	Organski ugljik	dg kg ⁻¹	
	pH	/	
	Sadržaj gline	g kg ⁻¹	
	Sadržaj praha	g kg ⁻¹	
	Sadržaj pijeska	g kg ⁻¹	
	Kapacitet kationske izmjene	mmol(c) kg ⁻¹	
	Nasipna gustoća	cg cm ⁻³	
Topografija	Digitalni model visina	m	(EU-DEM v1.1 – Copernicus Land Monitoring Service., n.d.)
	Nagib terena	°	
	Smjer nagiba terena	°	
	Ukupna potencijalna solarna radijacija	kWh m ⁻²	
	Topografski indeks vlažnosti	/	
	Indeks izloženosti vjetru	/	
Vegetacija	Proektivnost suhe tvari	kg ha ⁻¹ dan ⁻¹	(PROBA-V Products User Manual v3.01, n.d.)
	Postotak vegetativnog pokrova	/	

Klima ima dominantan učinak na trajanje vegetativnih i reproduktivnih faza rasta soje, učinkovitost nakon sjetve i ukupne potrebe za suncem i vodom (Liu i Dai, 2020). Klimatski podaci predstavljeni su korištenjem skupa podataka CHELSA, koji sadrži najnovije globalne klimatske podatke u prostornoj rezoluciji od 1 km tijekom 1979.–2013. (Karger i sur., 2017). Kovarijate temperature zraka i oborine filtrirane su od travnja do listopada. 19 bioklimatskih varijabli izvedeno je iz povijesnih mjesecnih podataka CHELSA, predstavljajući tromjesečne ekstreme temperature zraka i padalina i njihove raspone vrijednosti za ekološko modeliranje. Kemijkska i fizikalna svojstva tla imaju veliki utjecaj na količinu proteina i ulja u soji, dok je njihova varijabilnost povezana s anomalijama u prinosu soje (Anthony i sur., 2012). Ova svojstva tla predstavljena su SoilGrids podacima na dubinama tla 0–5 cm, 5–15 cm i 15–30 cm (Hengl i sur., 2017), koji dominantno utječe na rast soje i proizvedeni prinos. Topografija ima važnu ulogu u predstavljanju međudjelovanja nadmorske visine i konfiguracije terena s učincima klime i tla na uzgoj soje. Različiti teorijski topografski pokazatelji korišteni su za modeliranje mikrovarijacija klime i uvjeta tla, posebno u pogledu utjecaja sunca, vjetra i odvodnje vode. Vegetacijske kovarijate izvedene iz proizvoda PROBA-V, koje nisu izravno povezane s prinosom usjeva, dodane su kao dodatna biofizička svojstva LAI i FAPAR. Produktivnost suhe tvari (DMP) neizravno je predstavljala učinkovitost sunčevog zračenja i temperature zraka na povećanje suhe biomase, dok je frakcija vegetacijskog pokrova (FCOVER) procjenjivala postotak pokrivenosti tla vegetacijom, bez ovisnosti o optičkim svojstvima usjeva (Fuster i sur., 2020). Ovi podaci proizveli su nisku do umjerenu korelaciju s LAI i FAPAR, sprječavajući pristranost procjene pogodnosti. Provedeno je preuzorkovanje kovarijatnih rastera kako bi se uskladila prostorna razlučivost rastera LAI i FAPAR od 300 m.

Pogodnost poljoprivrednog zemljišta za uzgoj soje procijenjena je prema načelu klasifikacije u dva koraka: 1) određivanje razina pogodnosti u referentnim parcelama soje na temelju K-srednjaka klasifikacije multitemporalnih LAI i FAPAR podataka; i 2) strojno učenje predikcije pogodnosti poljoprivrednog zemljišta za uzgoj soje na cjelokupnom poljoprivrednom zemljištu, korištenjem kovarijata za uspostavljanje odnosa između razina pogodnosti i abiotičkih čimbenika okoliša. Predikcija pogodnosti zemljišta za uzgoj poljoprivrednih kultura provedeno je pojedinačno za svaku godinu u razdoblju 2017.–2020. Primarni razlog za taj postupak bila je prisutnost sustava plodoreda, jer se soja ne bi smjela uzbogati na istom mjestu u uzastopnom razdoblju od dvije ili tri godine (Galić Subašić, 2018). Ovaj pristup spriječio je interferenciju sa spektralnim informacijama drugih vrsta usjeva. Osim toga, međugodišnji vremenski uvjeti i bolesti vrlo su promjenjivi, što značajno utječe na biomasu i prinos soje. Predložena metoda izbjegava pristranost uzrokovana integracijom ovih uvjeta tijekom više godina procjenom pogodnosti poljoprivrednog zemljišta pojedinačno za svaku godinu, sprječavajući utjecaj izuzetno korisnih ili nepovoljnih događaja za određenu godinu. Predložena metoda umjesto toga razmatra relativne vrijednosti pogodnosti u podskupinama područja, na koja su gotovo jednako pogodena vremenskim prilikama ili bolestima u područjima od 50 x 50 km. Stoga je klasifikacija K-srednjaka procijenila relativne razine pogodnosti poljoprivrednog zemljišta po godini, dok su modeli strojnog učenja korišteni za procjenu



apsolutne pogodnosti poljoprivrednog zemljišta, proširujući procjenu na cjelokupnu poljoprivrednu površinu u područjima podskupa osim referentnih parcela soje. Ovaj pristup je osigurao objektivnu procjenu pogodnosti zemljišta za uzgoj poljoprivrednih kultura soje na 88,1% i 81,0% poljoprivrednih površina koje nisu bile korištene za uzgoj soje u razdoblju 2017. – 2020. za podskup A i B (Radočaj i sur., 2021). Procjena pogodnosti na cijeloj raspoloživoj površini omogućuje proširenje i regionalizaciju uzgoja soje na novim lokacijama, podržavajući sve veću potrebu za visokom kvalitetom i količinom proizvedene soje.

Godišnja biofizička svojstva LAI i FAPAR u mreži 300 x 300 m klasificirana su u pet vrijednosti pogodnosti korištenjem metode nenadzirane klasifikacije K-srednjaka za njihovo određivanje prije obuke modela strojnog učenja. Vrijednosti pogodnosti u rasponu od 1 do 5 rangirane su prema srednjoj vrijednosti LAI i FAPAR, gdje više vrijednosti LAI i FAPAR ukazuju na veću pogodnost poljoprivrednog zemljišta za uzgoj soje (Radočaj i sur., 2021). Relativan pristup kreiranju podataka o obuci i testiranju korištenjem LAI i FAPAR korištenjem nenadzirane klasifikacije osigurao je mogućnost višegodišnje usporedbe pogodnosti, unatoč godišnjoj varijabilnosti vremena i ekstremima.

Trening i test podaci odvojeni su od jedinstvenog klasificiranog skupa podataka korištenjem stratificiranog slučajnog dijeljenja u omjeru 50:50. Metoda k-najbližih susjeda (KNN) primijenjena je za procjenu pogodnosti zemljišta za uzgoj poljoprivrednih kultura soje. Određivanje parametara za KNN predikciju temeljilo se na iterativnom postupku, koristeći parametre koji su osiguravali najveću točnost predikcije. Procjena pogodnosti zemljišta za uzgoj poljoprivrednih kultura soje provedena je pojedinačno za svaku godinu u razdoblju 2017.–2020. Godišnje klase pogodnosti procijenjene su zasebno kako bi se smanjila pristranost predikcije uzrokovana godišnjim vremenskim ekstremnim događajima, koji predstavljaju rijetke pojave u perspektivi upravljanja poljoprivrednim zemljištem. Ovi rasteri su reducirani na klasu poljoprivrednih površina iz CORINE 2018, izdvajajući moguću površinu za uzgoj soje.

Točnost predikcije strojnog učenja procijenjena je pomoću Figure of merit (F) metrike (1), koju su razvili Pontius i Millones (2011) kao nadogradnju kappa koeficijenata u studijama na temu daljinskih istraživanja. Ukupna točnost (engl. overall accuracy, OA) procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura soje izračunata je kao omjer ukupnih slaganja i ukupnih klasificiranih vrijednosti:

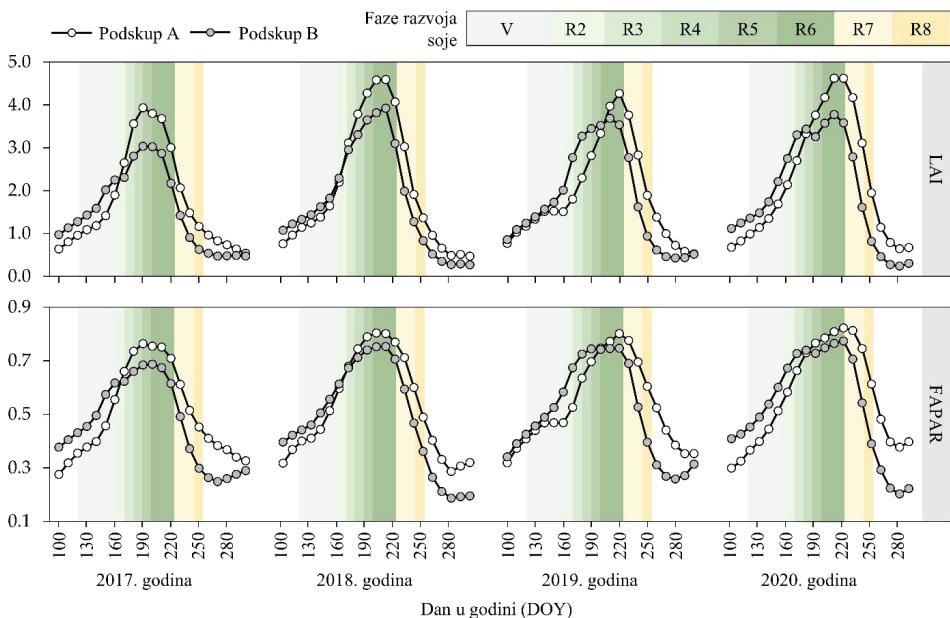
$$F = \frac{a}{o + a + c} \cdot 100 \%, \quad (1)$$

pri čemu a (engl. agreement) predstavlja točno predviđene vrijednosti pogodnosti, o (engl. omission) predstavlja pogrešno predviđene vrijednosti pogodnosti u drugim klasama prikladnosti i c (engl. comission) predstavlja pogrešno predviđene vrijednosti pogodnosti određene klase pogodnosti. Četiri godišnja rastera pogodnosti su agregirana na temelju FAO metodologije za procjenu pogodnosti zemljišta u pet klasa (Radočaj i sur., 2021). Rangiranje vrijednosti pogodnosti zemljišta za uzgoj poljoprivrednih kultura soje provedeno je prema FAO-ovim klasama pogodnosti koje su uključivale vrlo prikladne (S1), umjereno prikladne (S2), rubno prikladne (S3), trenutno neprikladne (N1) i trajno neprikladne (N2) klase. Trajno neprikladne površine u klasi N2 sadržavale su sve nepoljoprivredne površine iz CORINE 2018, koje nisu podržavale uzgoj soje bez većeg poremećaja ekosustava.

3. Rezultati i rasprava

Sezonski trendovi srednjih vrijednosti LAI i FAPAR na poljoprivrednim česticama soje tijekom vegetativnog razdoblja između travnja i listopada od 2017. do 2020. prikazani su na slici 1. I LAI i FAPAR općenito su dosegli svoj vrhunac krajem srpnja ili početkom kolovoza, što odgovara uobičajenom razdoblju početka faze rasta R6 sorti soje u istraživanom području. Te su vrijednosti dosegle više vrhove u podskupu A nego u podskupu B u svim promatranim godinama. Uočeno je i nešto kasnije vegetativno razdoblje soje u podskupu A u odnosu na podskupinu B, što je karakteristično za rane skupine zrelosti soje koje su uobičajeno prisutne na ovom području. U međuvremenu, vegetativno razdoblje soje u podskupu B odgovaralo je trajanju srednje rane i srednje kasne skupine zrelosti, što potvrđuje njihovu prisutnost u istraživanom području iz prethodnih istraživanja. Manje iznenadne promjene u trendovima LAI i FAPAR za godinu 2017. u podskupu A i 2020. godinu u podskupu B implicirale su osjetljivost LAI i FAPAR na godišnje ekstremne vremenske uvjete tijekom ranih reproduktivnih faza rasta soje. Ove su anomalije česta pojava uzrokovana sušom na istraživanom području, a gotovo su se potpuno izjednačile u kasnijim fazama rasta soje (Galić Subašić, 2018).

Slika 1. Sezonski trendovi srednjih vrijednosti LAI i FAPAR na poljoprivrednim česticama soje tijekom vegetativnog razdoblja između travnja i listopada od 2017. do 2020. godine



KNN je omogućio visoku točnost točnost klasifikacije za pogodnost poljoprivrednog zemljišta soje u svih osam godišnjih vrijednosti pogodnosti za pogodne (Tablica 2) i nepogodne klase pogodnosti (Tablica 3). Točnost procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura bila je nešto niža u podskupu B, a za tri pogodnije vrijednosti za uzgoj soje uočen je opći trend veće točnosti predikcije predstavljene vrijednošću u odnosu na manje pogodne vrijednosti. Godišnji trendovi točnosti predikcije impliciraju da bi uključivanje većeg broja uzoraka na većem području rezultiralo većom točnošću predviđanja. Takav bi pristup također osigurao primjenjivost predložene metode procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura za manje zastupljene vrste usjeva. Optimalan broj uzoraka za obuku u ograničenim područjima unutar kontinentalne Hrvatske mogao bi se osigurati za glavne vrste usjeva kao što su soja, pšenica, kukuruz, suncokret i uljana repica (Radočaj i sur., 2021). Dodatno, uključivanje dodatnih kovarijata u predloženu metodu procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura moglo bi doprinijeti točnosti predikcije (Hengl i sur., 2014). Zapažanja iz analize osjetljivosti s obzirom na blizinu glavnih klasa zemljišnog pokrova i tipova tla pokazuju da bi ove kovarijate bile važan dodatak budućim studijama (Radočaj i sur., 2022). Heterogenost vrijednosti pogodnosti zona u blizini urbanih područja ukazuje na mogući značajan utjecaj socioekonomskih kovarijata u procjeni pogodnosti zemljišta za uzgoj poljoprivrednih kultura, poput gustoće naseljenosti. Potencijalna i stvarna evapotranspiracija i stvarna sunčeva radijacija uspješno su izvedene korištenjem besplatnih izvora podataka daljinskog istraživanja (Girolimetto i Venturini, 2013). Te bi

kovarijate također vjerojatno poboljšale trenutno korištene teorijske vrijednosti izračunate iz DEM za većinu vrsta usjeva osim soje. Implementacija metoda dubokog učenja mogla bi predstavljati održivu opciju za poboljšanje točnosti procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura u budućnosti (Jin i sur., 2020; Radočaj i sur., 2024). Trenutno ovim metodama općenito nedostaje računalno učinkovita predikcija zbog prisutnosti velikog i složenog treninga i kovarijantnih podataka. Budući da ovaj pristup zahtijeva značajne i skupe hardverske resurse, trenutno narušava globalni i jeftini karakter predložene metode. S dalnjim poboljšanjem dubokog učenja, očekuje se da će omogućiti nadogradnju na konvencionalno strojno učenje, predstavljajući još učinkovitiju osnovu procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura.

Tablica 2. Rezultati validacije točnosti predikcije pogodnosti poljoprivrednog zemljišta za uzgoj soje za pogodne klase prema FAO standardu

Podskup	Godina	S1			S2			S3			OA
		F	o	c	F	o	c	F	o	c	
A	2020	46.7	4.2	2.5	36.7	8.4	7.6	50.0	6.7	8.4	68.1
	2019	63.2	3.8	2.9	57.7	8.7	1.9	63.2	2.9	10.6	72.1
	2018	51.0	7.8	7.8	65.0	3.9	0.7	48.7	9.2	3.9	69.9
	2017	50.0	3.3	1.3	55.2	4.7	4.0	47.1	8.7	3.3	73.3
B	2020	72.0	2.5	0.0	49.5	10.1	6.9	36.6	7.6	1.8	65.3
	2019	63.0	2.3	1.0	80.6	1.9	0.3	56.3	6.8	7.8	66.2
	2018	92.1	0.9	0.0	51.7	8.4	4.5	52.1	7.5	13.0	73.8
	2017	55.4	5.2	6.1	52.2	4.2	2.4	49.3	10.9	9.7	70.9

Tablica 3. Rezultati validacije točnosti predikcije pogodnosti poljoprivrednog zemljišta za uzgoj soje za nepogodne klase prema FAO standardu

Podskup	Godina	N1			N2			OA
		F	o	c	F	o	c	
A	2020	46.3	8.4	10.1	74.3	4.2	3.4	68.1
	2019	48.1	6.7	6.7	47.8	5.8	5.8	72.1
	2018	48.8	7.2	7.2	60.4	2.0	10.5	69.9
	2017	66.0	6.0	5.3	60.3	4.0	12.7	73.3
B	2020	48.0	8.3	15.5	47.1	6.1	10.5	65.3
	2019	33.1	15.9	12.3	49.1	6.8	12.3	66.2
	2018	58.2	6.9	6.9	65.0	2.4	1.8	73.8
	2017	59.0	4.5	0.3	60.5	4.2	10.6	70.9

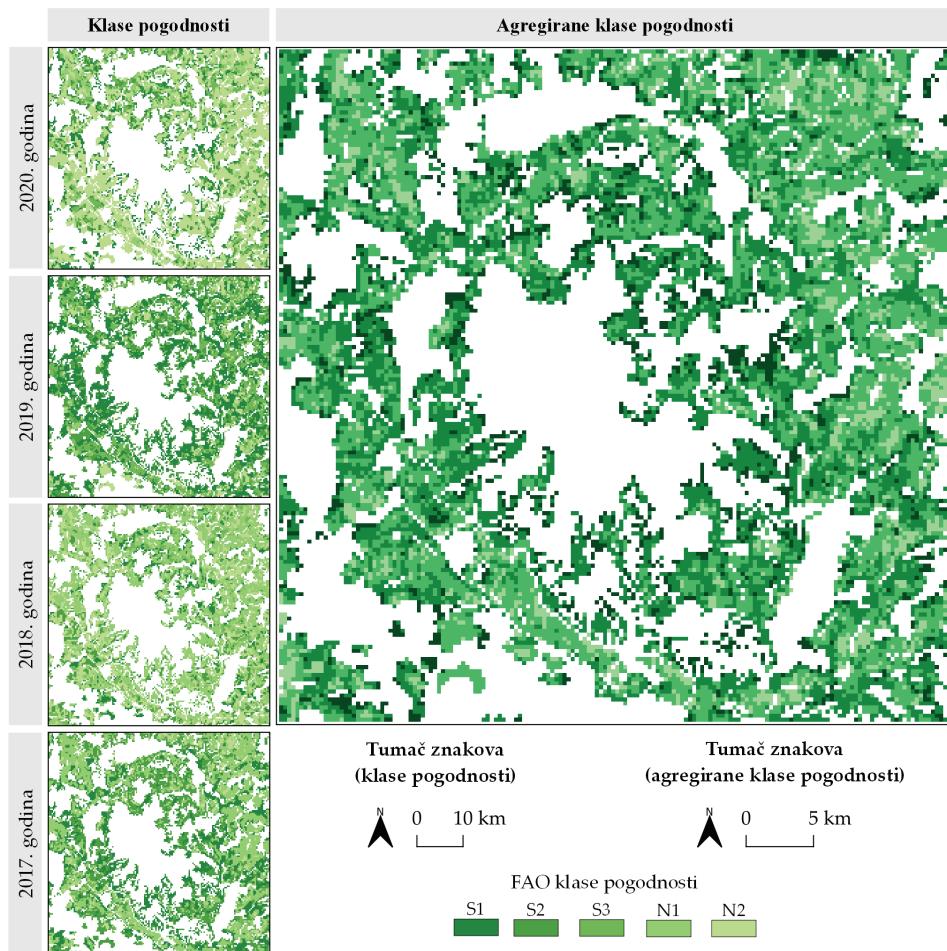


Vegetacijske kovarijate proizvele su veće pojedinačne vrijednosti relativne važnosti kovarijata u usporedbi s abiotičkim kovarijatama iz istog razdoblja predviđanja. Međutim, njihov ukupni broj od 42 u usporedbi sa 77 abiotičkih kovarijata po predviđanju ukazuje na sličnu ukupnu važnost ovih grupa kovarijata. Postotak vegetativnog pokrova i produktivnost suhe tvari zabilježeni tijekom lipnja i srpnja imali su dominantnu važnost od pet najvažnijih kovarijati vegetacije po predviđanju. Ove su kovarijate sadržavale 74,1% najutjecajnijih kovarijata vegetacije uzimajući u obzir oba podskupa. Kovarijate SoilGrids bile su najzastupljenije u prvih pet najutjecajnijih abiotičkih kovarijata u podskupu A, dok ga prate klimatski podaci CHELSA-e među prvih pet najvažnijih abiotičkih kovarijata. Vrijednosti oborina tijekom cijelog vegetativnog razdoblja soje bili su najzastupljeniji klimatski podaci. Podaci SoilGridsa bili su dominantno uključeni unutar najutjecajnijih kovarijata u podskupu B, pri čemu je dušik u tlu bio najčešća kovarijata tla, osobito na dubini od 5-15 cm. Topografske kovarijate izvedene iz digitalnog modela visina manjim su dijelom sadržane u skupu najutjecajnijih abiotičkih kovarijati u podskupu B.

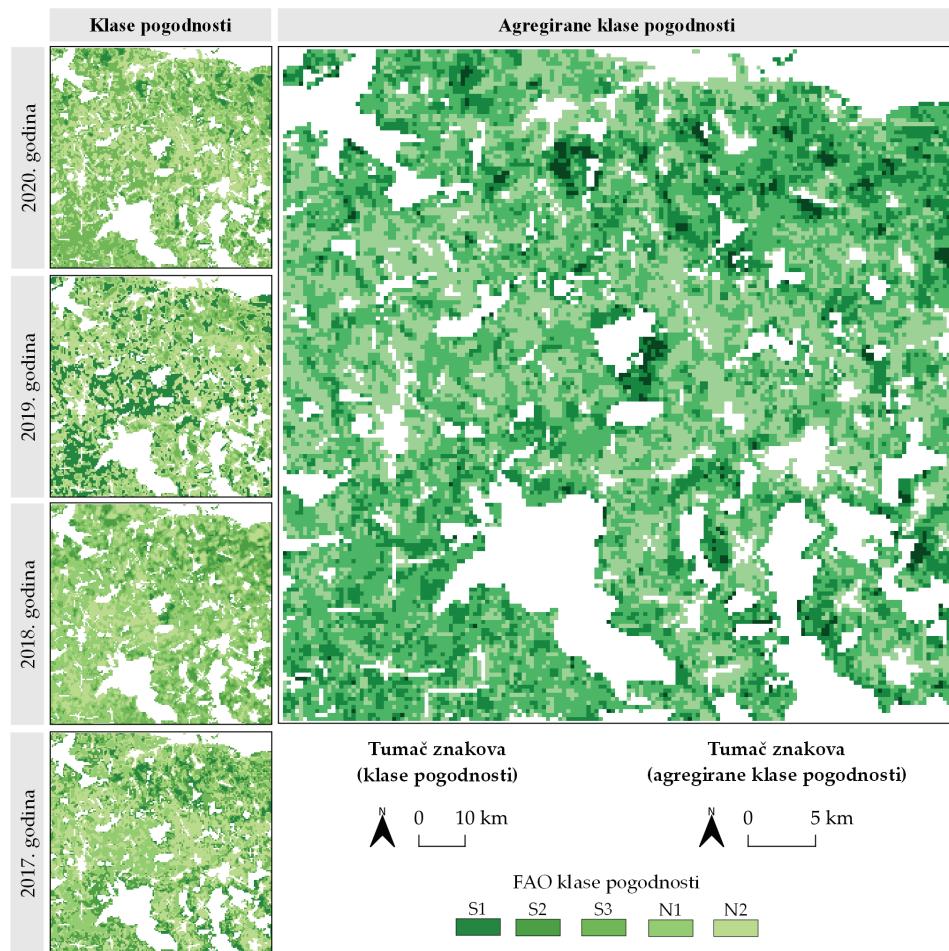
Godišnje i agregirane klase pogodnosti poljoprivrednog zemljišta za uzgoj soje po podskupu prikazane su na slikama 2 i 3. Godišnje vrijednosti pogodnosti u 2018. i 2020. kod oba podskupa proizvele su niže vrijednosti u usporedbi sa srednjim godišnjim vrijednostima pogodnosti tijekom 2017. i 2019. Tradicionalno intenzivno korištene poljoprivredne površine u podskupu B dale su nešto veći postotak prikladnih klasa za uzgoj soje (S1–S3) u usporedbi s podskupom A. Međutim, više lokacija u podskupu A postiglo je viši vrhunac pogodnosti, posebno u pogledu najprikladnije klase S1. Najprikladnije agregirane klase pogodnosti u podskupu A promatrane su u središnjem dijelu podskupa, koji sadrži parcele soje dominantno okružene šumama. Najprikladnija područja za uzgoj soje u podskupu B bila su u velikoj mjeri raspršena po podskupu, dok je trenutno neprikladno zemljište bilo dominantno koncentrirano u većim naseljima. Klase pogodnosti zemljišta za uzgoj poljoprivrednih kultura predviđene pomoću predložene metode prvenstveno odražavaju dosljednost pogodnosti tijekom više godina. Dok prednost relativne nenađirane klasifikacije LAI i FAPAR vrijednosti za stvaranje uzorka za obuku čini otpornim na godišnje ekstreme uzrokovane vremenskim prilikama, u isto vrijeme postoji određena nejasnoća u apsolutnim razinama pogodnosti ovih vrijednosti. Ovo bi se moglo riješiti integracijom podataka o prinosu kao mjeru apsolutne razine pogodnosti s predloženim pristupom koji se temelji na satelitski izvedenim biofizičkim svojstvima usjeva. LAI i FAPAR pokazali su osjetljivost na svojstva vegetacije različitih tipova usjeva u prethodnim studijama, vjerojatno predstavljajući univerzalne pokazatelje pogodnosti usjeva (Frampton i sur., 2013). Gitelson (2019) je primijetio osjetljivost FAPAR-a na strukture krošnje i fotosintetske specifičnosti raznih vrsta usjeva, uključujući soju i kukuruz. Točno određivanje biofizičkih svojstava usjeva održavano je pomoću proizvoda Sentinel-2 visoke prostorne razlučivosti i Sentinel-3 umjerene prostorne razlučivosti (Skakun i sur., 2021). Ovo snažno ukazuje na primjenjivost predložene metode kroz više skala interesa za upravljanje poljoprivrednim zemljištem za glavne vrste usjeva. Štoviše, globalna pokrivenost i dostupnost otvorenih podataka za Sentinel-2 i Sentinel-3 osiguravaju široku

primjenjivost ove metode u budućnosti (Radočaj i sur., 2020). Trenutna metodologija fokusirana je na veće poljoprivredne parcele zbog ograničenja prostorne razlučivosti proizvoda PROBA-V. LAI i FAPAR izvedeni iz Sentinel-2 snimki prostorne razlučivosti od 10 m uspješno su implementirani u studije pogodnosti usjeva, predstavljajući osnovu predložene nadogradnje metode za analizu na mikro skali (Belgiu i Csillik, 2018). Moguće ograničenje tijekom kreiranja uzorka za obuku i ispitivanja koristeći LAI i FAPAR kao referentne vrijednosti može biti dostupnost poljoprivrednih parcela soje ili drugih vrsta usjeva na nacionalnoj razini. Budući da ove podatke obično prikupljaju i distribuiraju nacionalne agencije, ti podaci možda neće biti lako dostupni u nekim manje razvijenim dijelovima svijeta. Međutim, to se može prevladati implementacijom algoritama za klasifikaciju vrsta usjeva koji se temelje na LAI i FAPAR koristeći strojno učenje, što je omogućilo ekstrakciju određene vrste usjeva s 80% ili većom točnošću u nedavnoj studiji autora Waldner i sur. (2015).

Slika 2. Pojedinačne i agregirane klase pogodnosti poljoprivrednog zemljišta za uzgoj soje prema FAO standardu na podskupu A.



Slika 3. Pojedinačne i agregirane klase pogodnosti poljoprivrednog zemljišta za uzgoj soje prema FAO standardu na podskupu B.





Prednosti predložene nove metode procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura sastoje se od jednostavne i računalno učinkovite aplikacije strojnog učenja i globalne dostupnosti otvorenih podataka o klimi, tlu, topografiji i vegetaciji (Radočaj i sur., 2021). Predloženi pristup pruža stabilnu osnovu za određivanje pogodnosti zemljišta za uzgoj poljoprivrednih kultura kao potencijalno superiornu dugoročnu alternativu višekriterijskoj analizi temeljenoj na GIS-u. Ovaj pristup omogućuje korisniku da prevlada dva najutjecajnija nedostatka konvencionalnog višekriterijskog pristupa koji se temelji na GIS-u, dopuštajući uključivanje složenih ulaznih podataka i izbjegavajući subjektivnost u procjeni pogodnosti. Dodatna prednost konvencionalnog pristupa je validacija točnosti lako dostupnih podataka LAI i FAPAR. Ovaj proces omogućuje korak naprijed u objektivnoj procjeni izvedbe modela i usporedbi FAO klase pogodnosti između dva pojedinačna skupa podataka. Predložena metoda je uspješno provedena korištenjem obično dostupnog stolnog osobnog računala, što smanjuje potrebu za skupim hardverom. Međutim, još uvijek postoji nekoliko ograničenja koja tek treba riješiti. Na temelju rezultata dobivenih u ovoj studiji i opsežnog pregleda literature, poboljšanja predloženog pristupa procjene pogodnosti zemljišta za uzgoj poljoprivrednih kultura mogu se izvesti u četiri opća smjera: 1) usvajanjem procjene učinka za više vrsta usjeva s ciljem određivanja višedimenzionalnog skupa podataka o pogodnosti poljoprivrednog zemljišta za određeno područje istraživanja, predstavljajući cijelovito rješenje za upravljanje poljoprivrednim zemljištem; 2) izmjenom pristupa validacije pogodnosti korištenjem satelitskih snimaka Sentinel-2 visoke razlučivosti za ocjenu pogodnosti poljoprivrednog zemljišta na mikro lokacijama; 3) poboljšanje postojeće metode procjene pogodnosti s obzirom na optimizaciju uzoraka obuke i ulaznih kovarijata; 4) provedbom predviđene pogodnosti poljoprivrednog zemljišta soje u praksi s obzirom na postojeću poljoprivrednu praksu u području istraživanja. Još jedno moguće poboljšanje točnosti predikcije metoda strojnog učenja je implementacija najnovijih okolišnih podataka. Vjerovatni razlozi niže točnosti predikcije za godine 2018. i 2020. u usporedbi s prethodnim godinama bila su manja vremenska neslaganja ulaznih kovarijata s razdobljem istraživanja. Niska srednja vrijednost pogodnosti poljoprivrednog zemljišta tijekom sušne i vruće godine 2018. u usporedbi s godinama 2017. i 2019. dodatno pojačava potrebu za točnim nedavnim podacima zbog osjetljivosti vrijednosti pogodnosti na klimatski utjecaj. Nejasnoće koje se odnose na nemogućnost točnog praćenja i modeliranja sustava upravljanja usjevima i tlom od strane poljoprivrednika na lokalnoj razini ukazuju na nužnost uključivanja višestrukih izvora podataka za višegodišnju procjenu pogodnosti zemljišta za uzgoj poljoprivrednih kultura. Moguće rješenje je integracija trenutno korištenih SoilGrids podataka s ažuriranim SoilGrids verzijom 2.0 (Poggio i sur., 2021), koja bi trebala uspostaviti pouzdan globalni skup podataka o tlu za buduće studije. Slična su opažanja napravljena o klimatskim podacima, koji su podložni nedavnom utjecaju klimatskih promjena (Beck i sur., 2018). Čak i uz primjenu najnovijih globalnih klimatskih podataka korištenjem skupa podataka CHELSA (1979. – 2013.), učinci klimatskih promjena u proteklom desetljeću ostaju u velikoj mjeri nepokriveni prethodnim studijama o procjeni pogodnosti zemljišta za uzgoj poljoprivrednih kultura. Stoga bi usporedba rezultata pogodnosti zemljišta za više

usjeva, povremeno ažuriranih novim klimatskim podacima, vjerojatno odražavala učinke klimatskih promjena i omogućila poljoprivrednicima da izvrše potrebne prilagodbe (Liu i Dai, 2020). Moguće rješenje za uključivanje najnovijih klimatskih promjena u Predikcija mogla bi biti integracija trenutnih skupova globalnih klimatskih podataka s povijesnim vremenskim podacima unutar razdoblja istraživanja. Ovaj bi pristup mogao unaprijediti predloženu metodu uključivanjem najnovijih klimatskih trendova korištenjem slobodno dostupnih globalnih vremenskih podataka s raznih internetskih vremenskih portala ili nacionalnih meteoroloških agencija.

4. Zaključak

Predložena metoda predikcije pogodnosti poljoprivrednog zemljišta za uzgoj soje temeljena na strojnom učenju predstavlja potencijalnu alternativu i nadogradnju konvencionalnog određivanja pogodnosti zemljišta za uzgoj poljoprivrednih kultura korištenjem višekriterijske GIS analize. Prednosti te metode prvenstveno se ogledaju u računskoj učinkovitosti, objektivnosti prilikom predikcije i sposobnosti integriranja složenih ulaznih kovarijata. Predložena metoda temelji se na otvorenom daljinskom očitavanju i GIS podacima i softveru, što je čini široko dostupnom u cijelom svijetu. KNN je proizveo precizne rezultate procjene pogodnosti u slučajevima umjerenog broja uzoraka i velike količine složenih ulaznih kovarijata, potvrđujući zaključke iz prethodne studije. Očekuje se da će njegova točnost dodatno rasti s uključivanjem dodatnih kovarijata, uključujući socio-ekonomske kovarijate, evapotranspiraciju i udaljenost do klase zemljišnog pokrova. Također se očekuje da će stvaranje područja istraživanja većeg od 50×50 km povećati točnost procjene pogodnosti, zbog povećanog broja uzoraka za obuku i boljeg prilagođavanja modela. Ovo zapažanje potiče ponovnu procjenu postojećih planova upravljanja poljoprivrednim zemljištem, budući da poljoprivredno zemljište u podskupu A trenutačno nije adekvatno iskorišteno za uzgoj soje, za razliku od intenzivno kultiviranog poljoprivrednog zemljišta u podskupu B.

Točna i jednostavna metoda određivanja pogodnosti zemljišta za uzgoj poljoprivrednih kultura neophodna je kako bi se osiguralo široko dostupno rješenje za učinkovito upravljanje poljoprivrednim zemljištem za održivost poljoprivredne proizvodnje. Predložena metoda nadilazi ograničenja konvencionalno korištene višekriterijske analize temeljene na GIS-u, što bi moglo usmjeriti pozornost na strojno učenje u budućim studijama određivanja pogodnosti zemljišta za uzgoj poljoprivrednih kultura.



Literatura

- Anthony, P., Malzer, G., Sparrow, S., i Zhang, M. (2012). Soybean Yield and Quality in Relation to Soil Properties. *Agronomy Journal*, 104(5), 1443–1458. <https://doi.org/10.2134/agronj2012.0095>
- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., i Wood, E. F. (2018). Present and future Koppen-Geiger climate classification maps at 1-km resolution. *Scientific Data*, 5, 180214. <https://doi.org/10.1038/sdata.2018.214>
- Belgiu, M., i Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, 204, 509–523. <https://doi.org/10.1016/j.rse.2017.10.005>
- Chlingaryan, A., Sukkarieh, S., i Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and Electronics in Agriculture*, 151, 61–69. <https://doi.org/10.1016/j.compag.2018.05.012>
- Dedeoğlu, M., i Dengiz, O. (2019). Generating of land suitability index for wheat with hybrid system approach using AHP and GIS. *Computers and Electronics in Agriculture*, 167, 105062. <https://doi.org/10.1016/j.compag.2019.105062>
- EU-DEM v1.1—Copernicus Land Monitoring Service.* (n.d.). [Land item]. Retrieved April 21, 2021, from <https://land.copernicus.eu/imagery-in-situ/eu-dem/eu-dem-v1.1>
- Frampton, W. J., Dash, J., Watmough, G., i Milton, E. J. (2013). Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 83–92. <https://doi.org/10.1016/j.isprsjprs.2013.04.007>
- Fuster, B., Sánchez-Zapero, J., Camacho, F., García-Santos, V., Verger, A., Lacaze, R., Weiss, M., Baret, F., i Smets, B. (2020). Quality Assessment of PROBA-V LAI, fAPAR and fCOVER Collection 300 m Products of Copernicus Global Land Service. *Remote Sensing*, 12(6), Article 6. <https://doi.org/10.3390/rs12061017>
- Galic Subasic, D. (2018). *Influence of irrigation, nitrogen fertilization and genotype on the yield and quality of soybean (Glycine max (L.) Merr.)* [Ph.D. Thesis, Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek]. <https://urn.nsk.hr/urn:nbn:hr:151:122222>
- Girolimetto, D., i Venturini, V. (2013). Water Stress Estimation from NDVI-Ts Plot and the Wet Environment Evapotranspiration. *Advances in Remote Sensing*, 2(4), Article 4. <https://doi.org/10.4236/ars.2013.24031>

- Gitelson, A. A. (2019). Remote estimation of fraction of radiation absorbed by photosynthetically active vegetation: Generic algorithm for maize and soybean. *Remote Sensing Letters*, 10(3), 283–291. <https://doi.org/10.1080/2150704X.2018.1547445>
- Han, C., Chen, S., Yu, Y., Xu, Z., Zhu, B., Xu, X., i Wang, Z. (2021). Evaluation of Agricultural Land Suitability Based on RS, AHP, and MEA: A Case Study in Jilin Province, China. *Agriculture-Basel*, 11(4), 370. <https://doi.org/10.3390/agriculture11040370>
- Hengl, T., Jesus, J. M. de, Heuvelink, G. B. M., Gonzalez, M. R., Kilibarda, M., Blagotić, A., Shangguan, W., Wright, M. N., Geng, X., Bauer-Marschallinger, B., Guevara, M. A., Vargas, R., MacMillan, R. A., Batjes, N. H., Leenaars, J. G. B., Ribeiro, E., Wheeler, I., Mantel, S., i Kempen, B. (2017). SoilGrids250m: Global gridded soil information based on machine learning. *PLOS ONE*, 12(2), e0169748. <https://doi.org/10.1371/journal.pone.0169748>
- Hengl, T., Jesus, J. M. de, MacMillan, R. A., Batjes, N. H., Heuvelink, G. B. M., Ribeiro, E., Samuel-Rosa, A., Kempen, B., Leenaars, J. G. B., Walsh, M. G., i Gonzalez, M. R. (2014). SoilGrids1km—Global Soil Information Based on Automated Mapping. *PLOS ONE*, 9(8), e105992. <https://doi.org/10.1371/journal.pone.0105992>
- Jin, X., Li, Z., Feng, H., Ren, Z., i Li, S. (2020). Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index. *The Crop Journal*, 8(1), 87–97. <https://doi.org/10.1016/j.cj.2019.06.005>
- Jurišić, M., Plaščak, I., Antonić, O., i Radočaj, D. (2020). Suitability Calculation for Red Spicy Pepper Cultivation (*Capsicum annuum L.*) Using Hybrid GIS-Based Multicriteria Analysis. *Agronomy*, 10(1), Article 1. <https://doi.org/10.3390/agronomy10010003>
- Karger, D. N., Conrad, O., Böhner, J., Kawohl, T., Kreft, H., Soria-Auza, R. W., Zimmermann, N. E., Linder, H. P., i Kessler, M. (2017). Climatologies at high resolution for the earth's land surface areas. *Scientific Data*, 4(1), Article 1. <https://doi.org/10.1038/sdata.2017.122>
- Khan, N., Ray, R. L., Sargani, G. R., Ihtisham, M., Khayyam, M., i Ismail, S. (2021). Current Progress and Future Prospects of Agriculture Technology: Gateway to Sustainable Agriculture. *Sustainability*, 13(9), Article 9. <https://doi.org/10.3390/su13094883>
- Lal, R., Bouma, J., Brevik, E., Dawson, L., Field, D. J., Glaser, B., Hatano, R., Hartemink, A. E., Kosaki, T., Lascelles, B., Monger, C., Muggler, C., Ndzana, G. M., Norra, S., Pan, X., Paradelo, R., Reyes-Sánchez, L. B., Sandén, T., Singh, B. R., ... Zhang, J. (2021). Soils and sustainable development goals of the United Nations: An International Union of Soil Sciences perspective. *Geoderma Regional*, 25, e00398. <https://doi.org/10.1016/j.geodrs.2021.e00398>



Laura Poggio, Luis M. de Sousa, Niels H. Batjes, Gerard B. M. Heuvelink, Bas Kempen, Eloi Ribeiro, i David Rossiter. (2021). SoilGrids 2.0: Producing soil information for the globe with quantified spatial uncertainty. *SOIL*, 7(1), 217–240. <https://doi.org/10.5194/soil-7-217-2021>

Liu, X., Jin, J., Herbert, S. J., Zhang, Q., i Wang, G. (2005). Yield components, dry matter, LAI and LAD of soybeans in Northeast China. *Field Crops Research*, 93(1), 85–93. <https://doi.org/10.1016/j.fcr.2004.09.005>

Liu, Y., i Dai, L. (2020). Modelling the impacts of climate change and crop management measures on soybean phenology in China. *Journal of Cleaner Production*, 262, 121271. <https://doi.org/10.1016/j.jclepro.2020.121271>

Pontius, R. G., i Millones, M. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407–4429. <https://doi.org/10.1080/01431161.2011.552923>

PROBA-V Products User Manual v3.01. (n.d.). Retrieved April 21, 2021, from https://proba-v.vgt.vito.be/sites/proba-v.vgt.vito.be/files/products_user_manual.pdf

Radočaj, D., Gašparović, M., Radočaj, P., i Jurišić, M. (2024). Geospatial prediction of total soil carbon in European agricultural land based on deep learning. *Science of The Total Environment*, 912, 169647. <https://doi.org/10.1016/j.scitotenv.2023.169647>

Radočaj, D., i Jurišić, M. (2022). GIS-Based Cropland Suitability Prediction Using Machine Learning: A Novel Approach to Sustainable Agricultural Production. *Agronomy*, 12(9), Article 9. <https://doi.org/10.3390/agronomy12092210>

Radočaj, D., Jurišić, M., Gašparović, M., Plaščak, I., i Antonić, O. (2021). Cropland Suitability Assessment Using Satellite-Based Biophysical Vegetation Properties and Machine Learning. *Agronomy*, 11(8), Article 8. <https://doi.org/10.3390/agronomy11081620>

Radočaj, D., Obhodaš, J., Jurišić, M., i Gašparović, M. (2020). Global Open Data Remote Sensing Satellite Missions for Land Monitoring and Conservation: A Review. *Land*, 9(11), Article 11. <https://doi.org/10.3390/land9110402>

Radočaj, D., Vinković, T., Jurišić, M., i Gašparović, M. (2022). The Relationship of Environmental Factors and the Cropland Suitability Levels for Soybean Cultivation Determined by Machine Learning. *Poljoprivreda*, 28(1), 53–59. <https://doi.org/10.18047/poljo.28.1.8>

Saaty, T. L., i Ozdemir, M. S. (2003). Why the magic number seven plus or minus two. *Mathematical and Computer Modelling*, 38(3), 233–244. [https://doi.org/10.1016/S0895-7177\(03\)90083-5](https://doi.org/10.1016/S0895-7177(03)90083-5)



- Sathiyamurthi, S., Saravanan, S., Sankriti, R., Aluru, M., Sivarajanji, S., i Srivel, R. (2022). Integrated GIS and AHP techniques for land suitability assessment of cotton crop in Perambalur District, South India. *International Journal of System Assurance Engineering and Management*. <https://doi.org/10.1007/s13198-022-01705-2>
- Schwalbert, R. A., Amado, T., Corassa, G., Pott, L. P., Prasad, P. V. V., i Ciampitti, I. A. (2020). Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agricultural and Forest Meteorology*, 284, 107886. <https://doi.org/10.1016/j.agrformet.2019.107886>
- Serraj, R., Krishnan, L., i Pingali, P. (2018). Agriculture and Food Systems to 2050: A Synthesis. In *Agriculture i Food Systems to 2050: Vol. Volume 2* (pp. 3–45). World Scientific. https://doi.org/10.1142/9789813278356_0001
- Skakun, S., Kalecinski, N. I., Brown, M. G. L., Johnson, D. M., Vermote, E. F., Roger, J.-C., i Franch, B. (2021). Assessing within-Field Corn and Soybean Yield Variability from WorldView-3, Planet, Sentinel-2, and Landsat 8 Satellite Imagery. *Remote Sensing*, 13(5), Article 5. <https://doi.org/10.3390/rs13050872>
- Taghizadeh-Mehrjardi, R., Nabiollahi, K., Rasoli, L., Kerry, R., i Scholten, T. (2020). Land Suitability Assessment and Agricultural Production Sustainability Using Machine Learning Models. *Agronomy*, 10(4), Article 4. <https://doi.org/10.3390/agronomy10040573>
- Waldner, F., Lambert, M.-J., Li, W., Weiss, M., Demarez, V., Morin, D., Marais-Sicre, C., Hagolle, O., Baret, F., i Defourny, P. (2015). Land Cover and Crop Type Classification along the Season Based on Biophysical Variables Retrieved from Multi-Sensor High-Resolution Time Series. *Remote Sensing*, 7(8), Article 8. <https://doi.org/10.3390/rs70810400>
- Wannasek, L., Ortner, M., Amon, B., i Amon, T. (2017). Sorghum, a sustainable feedstock for biogas production? Impact of climate, variety and harvesting time on maturity and biomass yield. *Biomass and Bioenergy*, 106, 137–145. <https://doi.org/10.1016/j.biombioe.2017.08.031>

EVALUATION OF THE METHOD FOR CROPLAND SUITABILITY PREDICTION FOR SOYBEAN CULTIVATION USING THE MACHINE LEARNING K-NEAREST NEIGHBORS METHOD

Dorijan RADOČAJ

Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek,
Vladimira Preloga 1, Osijek, Croatia

dradocaj@fazos.hr

Mladen JURIŠIĆ

Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek,
Vladimira Preloga 1, Osijek, Croatia

mjurisic@fazos.hr

Summary

Determining the suitability of agricultural land for cultivating agricultural crops is a major step in adapting to increased food demands caused by population growth, climate change and environmental pollution. Current state-of-the-art methods for determining cropland suitability are most often based on multi-criteria analysis based on a geographic information system (GIS), combined with advanced criteria weighting procedures. However, this method has some distinct drawbacks, the most obvious of which is the excessive reliance on the user's subjective assessment of the selection and weighting of criteria. The aim of this study is to evaluate the proposed new approach for predicting the suitability of agricultural land for soybean cultivation using the K-nearest neighbors (KNN) method. This approach potentially overcomes the limitations of conventional multicriteria GIS analysis by increasing computational efficiency, accuracy and objectivity of predictions. The method of predicting the suitability of agricultural land was validated for soybean cultivation within two subsets of 50 x 50 km located in the continental biogeoregion of Croatia in a four-year period during 2017–2020. Two biophysical vegetation properties, leaf area index (LAI) and fraction of absorbed photosynthetically active radiation (FAPAR), were used to train and test the KNN machine learning model. These data, derived from the PROBA-V medium-resolution satellite mission, were the main indicators of agricultural land suitability for soybean cultivation, with high correlations with crop health, yield and biomass in previous studies. Various climate, soil, topography, and vegetation covariates were used to establish relationships with the training samples, with a total of 119 covariates used per annual suitability prediction. KNN enabled a high level of prediction accuracy for all suitability classes according to



the Food and Agriculture Organization of the United Nations (FAO) standard. A highly suitable S1 FAO suitability class for soybean cultivation was determined on the rarely used subset A, while intensively cultivated agricultural land produced only a minor fraction of the same suitability class in subset B. Sensitivity analysis showed a strong relationship between cropland suitability values with proximity to forests, which could indicate the concept of agroforestry as a new approach to agricultural land management in Croatia.

Keywords: FAO, environmental covariates, geographic information system

Key message of the paper: Determining the suitability of agricultural land for growing agricultural crops is a major step in adapting to increased food demands. The evaluated approach based on machine learning and remote sensing data overcomes the limitations of conventional multi-criteria GIS analysis by increasing computational efficiency, accuracy and objectivity of predictions.