



REPUBLIKA SLOVENIJA
MINISTRSTVO ZA OKOLJE IN PROSTOR



Ime projekta: LIFE integrirani projekt za okrepljeno upravljanje Nature 2000 v Sloveniji (LIFE-IP NATURA.SI, LIFE17 IPE SI 011)

Akronim projekta: LIFE-IP NATURA.SI

Šifra projekta, številka pogodbe in identifikacijska številka: LIFE17 IPE/SI/000011

Project title: LIFE integrated project for enhanced management of Natura 2000 in Slovenia

Project acronym: LIFE-IP NATURA.SI

Agreement number, identification number: LIFE17 IPE/SI/000011

Naslov naloge: TESTIRANJE MOŽNOSTI IN IZVEDBA KARTIRANJA TRAVIŠČNIH HABITATNIH TIPOV Z DALJINSKIM ZAZNAVANJEM S POUDARKOM NA LOČEVANJU INTENZIVNIH IN EKSTENZIVNIH TRAVNIKOV*

Št. pogodbe: 8-IX-266/12-O-19/DE

* LIFE integrirani projekt za okrepljeno upravljanje Nature 2000 v Sloveniji (LIFE17 IPE/SI/000011) sofinancirajo Evropska unija preko programa LIFE, Ministrstvo za okolje in prostor ter partnerji. Ta vsebina ne odraža nujno mnenja Evropske unije.

© ZRC SAZU in UL FGG [2020]. Avtorske pravice za ta dokument so dodeljene ustanovama ZRC SAZU in UL FGG. Ta dokument se lahko reproducira samo v celoti ali delno ali pa se shrani v sistem za iskanje, ali v kakršni koli obliki ali na kakršen koli način elektronsko, mehansko, fotokopiranje ali kako drugače, s predhodnim dovoljenjem ZRC SAZU ali UL FGG ali v skladu s pogoji pogodbe št. 8-IX-266/12-O-19/DE.

Delovna skupina za izvedbo naloge

Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo

Jamova cesta 2, SI-1000 Ljubljana

prof. dr. Krištof Oštir

Ana Potočnik Buhvald

Matej Račič

izr. prof. dr. Anka Lisec

Znanstvenoraziskovalni center SAZU

Novi trg 2, SI-1000 Ljubljana

dr. Tatjana Veljanovski – vodja projekta

Peter Pehani

Liza Stančič

doc. dr. Žiga Kokalj

Priprava poročila

Tatjana Veljanovski

Ana Potočnik Buhvald

Matej Račič

Pregled poročila

Krištof Oštir

Anka Lisec



Univerza v Ljubljani
Fakulteta za *gradbeništvo in geodezijo*



TESTIRANJE MOŽNOSTI IN IZVEDBA KARTIRANJA TRAVIŠČNIH HABITATNIH TIPOV Z DALJINSKIM ZAZNAVANJEM S POUDARKOM NA LOČEVANJU INTENZIVNIH IN EKSTENZIVNIH TRAVNIKOV*

Končno poročilo

Datum dokumenta: oktober 2020

* LIFE integrirani projekt za okrepljeno upravljanje Nature 2000 v Sloveniji (LIFE17 IPE/SI/000011) sofinancirajo Evropska unija preko programa LIFE, Ministrstvo za okolje in prostor ter partnerji. Vsebine ne odražajo nujno mnenja Evropske unije.

© ZRC SAZU in UL FGG [2020]. Avtorske pravice za ta dokument so dodeljene ustanovama ZRC SAZU in UL FGG. Ta dokument se lahko reproducira samo v celoti ali delno ali pa se shrani v sistem za iskanje, ali v kakršni koli obliki ali na kakršen koli način elektronsko, mehansko, fotokopiranje ali kako drugače, s predhodnim dovoljenjem ZRC SAZU ali UL FGG ali v skladu s pogoji pogodbe št. 8-IX-266/12-O-19/DE.

Izvleček

Poročilo podaja rezultate študije uporabnosti prosto dostopnih podatkov satelitov Sentinel-1 in Sentinel-2 za kartiranje traviščnih habitatnih tipov, s poudarkom na ločevanju med intenzivnimi in ekstenzivnimi travniki. Podatki satelitov Sentinel-1 in Sentinel-2 so na voljo v okviru evropskega programa Copernicus. Vsakega izmed sistemov sestavljata dva satelita, kar omogoča visoko časovno ločljivost. Sentinela-1 snemata z radarjem s prostorsko ločljivostjo 10 m in časovno ločljivostjo dvanajst dni od aprila 2014 oziroma šest dni od aprila 2016. Satelita Sentinel-2 snemata z večspektralnim senzorjem v trinajstih spektralnih pasovih s prostorsko ločljivostjo do 10 m. Posnetki so na voljo vsakih deset dni od junija 2015 in na pet dni od marca 2017.

V nalogi smo testirali in predlagali časovne vrste satelitskih podatkov in strojno učenje za ugotavljanje lastnosti in stanja travišč ter za razvrščanje travišč glede na razlike v rabi (intenzivnost košenja). Za strojno učenje smo poleg satelitskih podatkov uporabljali tudi razpoložljiva kartiranja habitatnih tipov ZRSVN, za določitev območja študije pa državne podatke Evidenca dejanske rabe kmetijskih in gozdnih zemljišč (RABA) in evidenco Grafična enota rabe kmetijskega gospodarstva (GERK).

Rezultat študije je zasnova pristopa, ki je primeren za vsakoletno pridobivanje aktualnih informacij o stanju travišč na območju celotne Slovenije, kar vključuje tudi primerjave trenutnega stanja s preteklimi leti. Z razvitim postopkom smo klasificirali intenzivne in ekstenzivne travnike ter datume košnje za leta 2017, 2018 in 2019.

Priporočeni način citiranja:

Veljanovski, T., Potočnik Buhvald, A., Račič, M., Oštir, K., 2020. Testiranje možnosti in izvedba kartiranja traviščnih habitatnih tipov z daljinskim zaznavanjem s poudarkom na ločevanju intenzivnih in ekstenzivnih travnikov. Končno poročilo. ZRC SAZU in UL FGG, Ljubljana.

Uporabljene kratice in okrajšave

ARSO	Agencija Republike Slovenije za okolje
EVI	poudarjen indeks vegetacije
GERK	grafična enota rabe kmetijskega gospodarstva
HT, HTS	habitatni tip, habitatni tipi Slovenije
KOPOP	kmetijsko-okoljska-podnebna plačila
MKGP	Ministrstvo za kmetijstvo, gozdarstvo in prehrano
MSAVI2	modificiran vegetacijski indeks, prilagojen tlom
NDVI	normirana razlika indeksa vegetacije
RABA MKGP	Evidenca dejanske rabe kmetijskih in gozdnih zemljišč pri MKGP
Rajonizacija HAB	Rajonizacija za sloj HAB (Sloj rajonizacija rabe v okviru operacije/ukrepa HAB)
S-1	Sentinel-1
S-2	Sentinel-2
S2REP	Indeks položaja robne rdeče
SNAP	Platforma Evropske vesoljske agencije Sentinel Application Platform
UL FGG	Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo
ZRC SAZU	Znanstvenoraziskovalni center Slovenske akademije znanosti in umetnosti
ZRSVN	Zavod Republike Slovenije za varstvo narave

Vsebina

1.	Uvod	1
1.1	Namen in cilji	1
1.2	Izhodišča za delo	1
1.3	Izvedba dela	2
2.	Pregled in priprava podatkov	4
2.1	Travišča	4
2.2	Določitev maske travnikov.....	4
2.3	Priprava referenčnih podatkov	5
2.3.1	Podatki kartiranj habitatnih tipov.....	5
2.3.2	Statistični pregled referenčnih podatkov	10
2.3.3	Čiščenje in priprava referenčnih podatkov.....	12
2.4	Dopolnilni podatki.....	13
2.5	Satelitski podatki.....	14
2.5.1	Časovne vrste Sentinel-2	15
2.5.2	Časovne vrste Sentinel-1	18
2.5.3	Knjižnica satelitskih posnetkov za izvedbo naloge	21
3	Določitev učnega vzorca.....	22
3.1	Ugotavljanje lastnosti vzorca ekstenzivnih in intenzivnih travišč.....	22
3.2	Napovedovanje razredov in priprava učnega vzorca.....	27
3.3	Priprava poligonov za strojno učenje.....	37
3.3.1	Priprava poligonov na območjih izven GERK-ov.....	37
3.3.2	Učni vzorci travnikov in satelitski podatki	39
4	Strojno učenje modela in ocena točnosti.....	43
4.1	Izbira in gradnja modelov	43
4.2	Evalvacija modelov.....	45
5	Rezultati in ovrednotenje	47
5.1	Rezultati s časovnimi vrstami S-2 NDVI	47
5.1.1	Vrednotenje rezultatov (S-2 NDVI).....	52
5.2	Rezultati s časovnimi vrstami S-1 koherenca.....	53
5.2.1	Vrednotenje rezultatov (S-1 koherenca)	57
5.3	Rezultati z združeno časovno vrsto S-2 NDVI in S-1 koherenco	58
5.3.1	Vrednotenje rezultatov (S-2 NDVI in S-1 koherenca)	60

5.4	Primerjava klasifikacij	61
5.5	Zaznavanje košenj	62
5.6	Rastrska klasifikacija	65
5.7	Vizualna ocena klasifikacije in območja zanesljivosti	69
5.8	Zanesljivost in določljivost postopka ločevanja travnikov	70
6	Predlagan postopek ločevanja intenzivnih in ekstenzivnih travnišč	72
7	Razčlenjena finančna ocena naslednje izvedbe	74
8	Zaključki	75
9	Viri in reference	78
10	Priloge	79

1 Uvod

V poročilu so dokumentirane informacije o poteku dela, predstavljeni so postopki in vmesne odločitve pri izvedbi naloge TESTIRANJE MOŽNOSTI IN IZVEDBA KARTIRANJA TRAVIŠČNIH HABITATNIH TIPOV Z DALJINSKIM ZAZNAVANJEM S POUČENJEM NA LOČEVANJU INTENZIVNIH IN EKSTENZIVNIH TRAVNIKOV. Naloga je izvedena v okviru projekta LIFE integrirani projekt za okrepljeno upravljanje Nature 2000 v Sloveniji (LIFE-IP NATURA.SI), ki je nalogo tudi financiral.

1.1 Namen in cilji

Namen študije je ugotoviti potencial prosto dostopnih satelitskih posnetkov Sentinel-1 in Sentinel-2 za razvrščanje travišč glede na intenzivno ali ekstenzivno rabo ter opredeliti postopek za sprotne letne preglede traviščnih habitatnih tipov na območju Slovenije. Delovni cilji so naslednji:


- Ugotoviti bistvene lastnosti intenzivnih in ekstenzivnih travišč na različnih območjih Slovenije ter kako se njihova rastna dinamika izraža v časovnih vrstah optičnih in radarskih satelitskih posnetkov.
- Povezati izražene lastnosti travišč ter možnosti modeliranja s strojnimi učenjem.
- Opredeliti območja oziroma travišča, ki jih lahko spremljamo (obdelujemo) s podatki Sentinel-1 in Sentinel-2 (in tista, ki jih ni mogoče obravnavati).
- Opredeliti potrebne vhodne podatke, algoritme in pogoje za kakovostno razvrščanje obeh tipov travišč.
- Ovrednotiti postopek ter rezultate postopka.
- Predlagati postopek za vsakoletno kartiranje.
- Predati izročke (rezultati kartiranja) za leta 2017, 2018 in 2019.

1.2 Izhodišča za delo

Ključni pogoji in usmeritve za izvedbo dela, ki so bili usklajeni z naročnikom naloge, to je Zavodom RS za varstvo narave (ZRSVN), na sestanku julija 2019, so:

- Opredelitev območja travišč v Sloveniji (maska se pridobi iz podatkov o dejanski rabi Ministrstva za kmetijstvo gozdarstvo in prehrano – v nadaljevanju: RABA MKGP).
- Ključni dejavnik razločevanja med intenzivnimi in ekstenzivnimi travišči je število košenj v rastni sezoni.
- Za učenje uporabimo vsa razpoložljiva kartiranja habitatnih tipov ZRSVN (HT ZRSVN) in druge evidence, v katerih se beleži podatek o košnji – to so referenčni podatki.
- Enota kartiranja so poligoni oziroma grafične enote rabe kmetijskega gospodarstva (v nadaljevanju: GERK), ki jih vzdržuje MKGP. Za travniške površine, ki niso vključene v GERK, se grafične (prostorske) enote generirajo v kombinaciji z obstoječimi parcelami ali segmentacijo satelitskih posnetkov.
- Naloga se izvede v dveh fazah: najprej analize na testnih območjih, nato opredelitev in izvedba postopka za vsa travišča.

Izhajali smo iz zasnove postopka letnega kartiranja travišč (Slika 1), kjer predvidimo kombinirano uporabo optičnih in radarskih satelitskih podatkov, podatke s terenskih kartiranj ZRSVN in drugih obstoječih prostorskih evidenc za izpeljavo postopka ločevanja s strojnim učenjem in za ovrednotenje.



Slika 1: Izhodiščna zasnova postopka ločevanja intenzivnih in ekstenzivnih travišč na satelitskih podatkih Sentinel-1 in Sentinel-2.

1.3 Izvedba dela

Potek dela v študiji je temeljil na naslednjih korakih:

- Opredelitev območja opazovanja za pripravo postopka ločevanja intenzivnih in ekstenzivnih travišč (maska območja).
- Priprava in obdelava radarskih podatkov Sentinel-1 (v nadaljevanju: S-1): koherenca, sigma; ter optičnih podatkov Sentinel-2 (v nadaljevanju: S-2): spektralni kanali in maska oblakov, vegetacijski indeksi.
- Analiza primernosti referenčnih podatkov kartiranj ZRSVN in drugih uporabnih podatkov oziroma informacij za strojno učenje.
- Priprava časovnih vrst.
- Opredelitev ključnih dejavnikov (spremenljivk) za ločevanje intenzivnih in ekstenzivnih travišč (izbira testnih območij, priprava časovnih vrst S-1 in S-2, analiza razvojnih krivulj).
- Testiranje metod strojnega učenja, analiza primernosti.
- Ovrednotenje rezultatov (kakovost določitve, računske zahteve).
- Opredelitev postopka za vsakoletno ločevanje intenzivnih in ekstenzivnih travišč (algoritem, podatki, pogoji, zahteve in omejitve).

Priprava podatkov, ki smo jih v študiji uporabili, je opisana v poglavju 2. V poglavju 3 predstavimo razloge za izdelavo novega učnega vzorca in pripravo učnih poligonov travišč. Ločevanje intenzivnih in ekstenzivnih travišč z modeli strojnega učenja ter uspešnost klasifikacij obravnava poglavje 4. V poglavju 5 predstavimo rezultate klasifikacije s strojnimi učenjem ter primerjamo rezultate na podlagi

različnih kombinacij vhodnih časovnih vrst optičnih in/ali radarskih podatkov. Sledi opis predlagane metodologije za izvedbo letnih kartiranj travnišč (poglavje 6) ter razčlenjena finančna ocena za ponovno izvedbo letnega kartiranja (poglavje 7). V zaključkih (poglavje 8) povzamemo glavne ugotovitve, opozorimo na omejitve in podamo predloge za nadaljnje izboljšave.

2 Pregled in priprava podatkov

V poglavju opišemo podrobneje način opredelitve in določitve območij opazovanja travišč (masko), razpoložljive referenčne podatke (kartiranja HT ZRSVN), pripravo podatkovnega sloja referenčnih podatkov, podatkovni sloj GERK ter dopolnitev razčlenbe območij opazovanja s segmentacijo, uporabljene satelitske podatke in njihovo pripravo (predobdelava posnetkov in priprava časovnih vrst).

2.1 Travišča

Po definiciji ZRSVN zajemajo *travišča* ekosistem, ki predstavlja eno najbolj pestrih in raznolikih območij, kjer lahko na samo kvadratnem metru najdemo več kot 80 različnih rastlinskih in živalskih vrst. Gre torej za biotsko pestra in raznovrstna območja v kmetijski kulturni krajini. Zaradi različnih vplivov, kot so na primer opuščanje kmetijske dejavnosti, pretirano vnašanje hranil, intenzifikacija rabe itn., traviščem upada biotska pestrost. Biotsko pestra travišča spadajo med bolj ogrožene habitate (Life to Grassland, 2020).

Med najbolj ogrožene ekosisteme v Evropi sodijo *ekstenzivna travišča*, saj je njihov obstoj odvisen od sonaravne, zmerne rabe, ki v tržnem gospodarstvu lastnikom navadno ne zagotavlja dovolj dohodka. Zato se travniške površine bodisi intenzivirajo z gnojenjem, zgodnjo košnjo in večjo obremenitvijo s pašo, ali pa se opuščajo in postopoma zaraščajo. V obeh primerih se število travniških rastlin in živali močno zmanjša, spremeni se tudi podoba krajine.

Kot *trajno travinje* se po definiciji MKGP, ki jo uporabljajo v namene izvajanje kmetijske politike, šteje zemljišče, ki se uporablja za gojenje trave ali drugih zelenih krmnih rastlin naravno zasajenih ali posejanih, in tako, ki najmanj pet let ni bilo preorano in vključeno v kolobarjenje kmetijskega gospodarstva. Po tej definiciji se njiva, ki je bila zasejana s travo, še naslednja tri leta šteje kot njiva, peto leto pa preide v kategorijo trajni travnik. Po interpretacijskem ključu za zajem podatkov RABA MKGP (Ministrstvo za kmetijstvo, gozdarstvo in prehrano, 2013) je *trajni travnik* površina, velika vsaj 1000 m², porasla s travo, deteljami in drugimi krmnimi rastlinami, ki se jo redno kosi oziroma pase. Takšna površina ni v kolobarju in se ne orje. Kot trajni travnik se šteje tudi površina, porasla s posameznimi drevesi, kjer gostota dreves ne presega 50 dreves/hektar (npr. travniški sadovnjak).

Ekstenzivne in intenzivne travnike najlažje ločimo po biotski pestrosti. Na ekstenzivnih travnikih raste številčno več rastlinskih vrst kot na intenzivnih travnikih. Gre za biotsko pestro rušo, ki zahteva manjše antropogene posege, torej manjše število košenj in datumsko kasnejšo prvo košnjo. Za intenzivne travnike pa je značilno več košenj, večji hektarski vnos hranil (dušika) in hitra oziroma zgodnja prva košnja (Kolečka et al., 2018).

Travnike, vključene v izvajanje ukrepa kmetijsko-okoljska-podnebna plačila (v nadaljevanju: KOPOP), lahko zavezujejo določene časovne in številčne omejitve košnje kot tudi dopustnost uporabe gnojil ali paše ter način košnje in spravila (Kmetijsko-okoljska-podnebna plačila 2015-2020, 2019). Časovno omejena košnja je predvidena različno za posebne traviščne habitate, traviščne habitate metuljev, habitate ptic vlažnih ekstenzivnih travnikov, steljnike, strme in grbinaste travnike.

2.2 Določitev maske travnikov

Maska predstavlja skupno območje travišč v Sloveniji, ki jih v nalogi obravnavamo, in na katerem je mogoče izvesti postopek dogovorjenega kartiranja. Zaradi enotnosti razporeditve za izdelavo maske v

vseh analiziranih letih uporabimo podatke evidence dejanske rabe kmetijskih in gozdnih zemljišč (podatkovni sloj RABA).

V začetni fazi smo se z naročnikom naloge uskladili, katere kategorije rabe zemljišč iz podatkovnega sloja RABA uporabimo za pripravo maske območja opazovanja in katere ne. Sprva smo uporabili kategorije: 1222 (ekstenzivni travniški sadovnjak), 1300 (trajni travnik), 1321 (barjanski travnik), 1800 (kmetijsko zemljišče, poraslo z gozdnim drevjem) in potencialno še 4100 (barje). Kasneje smo se omejili zgolj na območja kategorije 1300 – trajni travniki, ker so preliminarne analize s strojnim učenjem pokazale, da so v primeru opazovanja razmeroma subtilnih sprememb (travniki se zgolj kosijo) rezultati manj zanesljivi v kombinaciji z drugimi kategorijami rabe, ki so že po naravi bolj heterogene sestave (vsako območje v naravi namreč predstavlja specifičen odboj elektro-magnetnega valovanja, ki ga zaznajo senzorji satelita).

2.3 Priprava referenčnih podatkov


Začetne referenčne podatke predstavljajo terenski podatki LIFE-IP NATURA.SI in ostalih popisov habitatnih tipov (HT) ZRSVN – kartiranja HT. Ti podatki med drugim vsebujejo datum košnje. Nekatere druge evidence, ki smo jih prejeli s strani naročnika, beležijo datum košnje samo opisno (npr. sveže košen, pokošen, ne-košen, pred kratkim košen), tj. v obliki, ki ni primerna za načrtovani postopek s strojnim učenjem.

2.3.1 Podatki kartiranj habitatnih tipov

Kartiranje habitatnih tipov je hitra in natančna metoda, ki v razmeroma kratkem času omogoča pridobiti največ informacij o stanju in strukturi habitatnih tipov v nekem prostoru. Naravovarstvena stroka izvaja kartiranje negozdnih habitatnih tipov od leta 2000 naprej. Gre za terenski popis poligonov, ki se uporablja v večini evropskih držav in vključuje tudi kodo (Physis) Palearktične klasifikacije (*A classification of Palearctic habitats, Nature and environment, No. 78*). Opredelitev večine habitatnih tipov temelji na vegetaciji (rastlinskih združbah), le nekateri so definirani po rabi ali fiziognomskih značilnostih. Enotna tipologija habitatnih tipov Slovenije (v nadaljevanju: HTS) je usklajena z evropsko tipologijo. Zgradba je hierarhična, in sicer so HTS razvrščeni v sedem osnovnih kategorij (Tipologija HT, 2013):

- obalni in priobalni habitatni tipi,
- sladke celinske vode,
- grmišča in travišča,
- gozdovi,
- barja in močvirja,
- goličave (skalovje, melišča in peščine),
- kmetijska in kulturna krajina.

Grmišča in travišča se nadalje razvrščajo še v 180 podrazredov, od tega jih skoraj 80 pripada raznovrstnim HT travišč. Celotna HTS je dostopna na spletnem naslovu https://zrsvn-varstvonarave.si/wp-content/uploads/2019/07/Tipologija_HT_2013.xls, podatki kartiranj so javno dostopni in prevzeti iz spletne strani Izvedena kartiranja habitatnih tipov (<https://zrsvn-varstvonarave.si/informacije-za-uporabnike/katalog-informacij-javnega-znacaja/habitatni-tipi/izvedena-kartiranja-habitatnih-tipov/>, Slika 2).




Slika 2: Območja kartiranja habitatnih tipov ZRSVN (Vir: Izvedena kartiranja habitatnih tipov).

Po letu 2000 so bili kartirani habitatni tipi na 126 različnih območjih po Sloveniji. Pri ločevanju ekstenzivnih in intenzivnih travnin z daljinskim zaznavanjem v letih 2017, 2018 in 2019 smo uporabili le naslednje podatke kartiranja po letu 2016¹ (glej Slika 3):

- Pohorje LIFE travišča (2016),
- Haloze LIFE travišča (2016),
- Kum LIFE travišča (2016),
- Polhograjsko hribovje (2016),
- Gorjanci LIFE travišča (2016),
- Dolina Branice (2017),
- Dolina Vipave (2017),
- Mura (2017),
- Goriška krajina (2018),
- Dobličica (2018),
- Volčke (2019),
- Slovenska Istra (2019),
- Dravinjska dolina (2019) in
- Ličenica (2019).

¹ Glede na to, da se lahko ekstenzivni travnik zaradi prekomernega poseganja (gnojenja, mulčenja itn.) prej kot v letu dni spremeni v intenzivni travnik, ni smiselno upoštevati območij kartiranja starejših od leta 2016.



Slika 3: Območja kartiranj ZRSVN po letu 2016 z dodatnimi poligoni.

Skupna površina zgoraj navedenih kartiranih poligonov znaša 291 km² (~8 % površine vseh trajnih travnikov iz evidence RABA).

Na podlagi priporočil naročnika smo za izbrana kartiranja izvedli grobo ločevanje intenzivnih in ekstenzivnih travišč po kodi Physis. Med ekstenzivne travnike se uvršča mnogo podrazredov HT travišč, med intenzivne pa le štirje podrazredi (glej Priloga 1, 0), pri tem vsi HT niso zastopani tudi v evidencah kartiranj (Preglednica 1). Vsa izbrana travišča predstavljajo 60 km² površin kartiranih območij (21 % kartiranih poligonov in le 2 % površin trajnih travnikov iz evidence RABA).

Preglednica 1: Postopek proizvodbe in ločevanja intenzivnih in ekstenzivnih travišč po kodi Physis glede na zastopanost HT v izbranih kartiranjih 2016-2019. Znak % pomeni, da izbor vključuje tudi nižje oziroma podkategorije.

<i>Intenzivni [koda Physis]</i>	<i>Ekstenzivni [koda Physis]</i>
38.1% OR 38.11% OR 38.13% OR	34.11% OR 34.2% OR 34.32% OR 34.7% OR
81% OR 81.1% OR 81.2%	35% OR 36% OR 37.2% OR 37.3% OR 38.2%

Kartirani podatki so bili podani v koordinatnem sistemu D48/GK (EPSG: 3912), zato smo jih transformirali v nov državni referenčni koordinatni sistem D96/TM (EPSG: 3974), ki ga uporabljamo v študiji.


Vse obstoječe podatkovne sloje kartiranj smo združili v en referenčni sloj. Ker so imeli vhodni podatki kartiranj ZRSVN neurejene atributne tabele (atributi se med posameznimi območji niso ujemali), smo vse podatkovne tipe in imena spremenljivk poenotili in podatke združili v enoten sloj (Slika 4).

	Kartiral	Opombe	Datum	Physis	ID_ZRSVN	Stanje
1	Igor Paušič	NULL	2017-04-27	38.2221S1	1_Vipava	NULL
2	Igor Paušič	NULL	2017-04-27	31.8	2_Vipava	NULL
3	Igor Paušič	NULL	2017-04-27	38.2221S1	3_Vipava	NULL
4	Igor Paušič	NULL	2017-04-27	38.2221S1	4_Vipava	NULL
5	Igor Paušič	NULL	2017-04-27	38.2221S1	5_Vipava	NULL
6	Igor Paušič	NULL	2017-04-27	31.8D	6_Vipava	NULL
7	Igor Paušič	NULL	2017-04-27	31.8D	7_Vipava	NULL

Slika 4: Urejena atributna tabela referenčnih podatkov.


Pri nadaljnjem delu so najbolj pomembni atributi koda Physis, datum kartiranja, stanje in opombe. Koda Physis določi posamezne tipe traviščnih habitatnih tipov, ki jih lahko uvrstimo v kategoriji intenzivnih oziroma ekstenzivnih travišč. Datum kartiranja je pomemben, ker se navezuje na čas, ki je lahko odločilen pri uporabi časovne vrste satelitskih posnetkov, stanje in opombe pa dopolnjujejo podatke z informacijami ali je podatek še vedno verodostojen in se uporabi kot referenca pri strojnem učenju (med neugodno stanje štejemo: zaraščanje, opuščanje rabe, neustrezno upravljanje – neustrezna paša in košnja), opuščanje rabe visokodebelnih travniških sadovnjakov, nizka raven zavesti o pomenu in ohranjanju ekstenzivnih travišč, razdrobljena lastniška struktura in majhne parcele).

Podatkovne sloje posameznih območij z urejenimi atributnimi tabelami smo združili v skupen sloj (ZRSVN_2016_2019.shp). Ta zajema 72 931 kartiranih enot, od tega 19 214 (26 %) ekstenzivnih travnikov in 2852 (4 %) intenzivnih travnikov (Slika 5).




Slika 5: Struktura in porazdelitev referenčnih podatkov ZRSVN (2016–2019) na intenzivne, ekstenzivne travnike in druge negozdne habitatne tipe.

Neenakomerno in bistveno višjo zastopanost ekstenzivnih travnikov v kartiranjih ZRSVN je treba ustrezno upoštevati pri nadaljnjem modeliranju (Slika 6). Razmerja so različna tudi med posamičnimi območji (Slika 7).



Slika 6: Delež ekstenzivnih travnikov v vzorcu kartiranih travnikov ZRSVN je bistveno večji od deleža intenzivnih travnikov.



Slika 7: Razmerje med obsegom intenzivnih in ekstenzivnih travnikov v kartiranih HT ZRSVN (referenčni podatki) po območjih. Z rdečimi okvirji so poudarjena območja, kjer je razmerje bolj poenoteno.

Pripravljeni sloj poligonov travnikov zajema naslednje atribute:

- physis (physis koda),
- datum (datum kartiranja),
- kartiral (ime in priimek tistega, ki je travnik kartiral),
- opombe (opombe kartiranja – največkrat kaj raste, stanje travnika, itn.),
- ID_ZRSVN (ID poligona primarne, referenčne datoteke kartiranja),
- stanje (ugodno, manj ugodno, neugodno itn.),


- layer (primarni podatkovni sloj, ki se je združil v skupno datoteko),
- path (lokalna pot do primarnih podatkov),
- razred (intenzivni, ekstenzivni),
- mean (kolikšen delež kartiranega poligona pokriva raba 1300 na dan 21. 5. 2019),
- raba (ID_RABA – 1300),
- NMV_ave (povprečna nadmorska višina poligona preračunana iz digitalnega modela reliefa prostorske ločljivosti 25 m),
- Naklon_ave (povprečni naklon poligona preračunan iz digitalnega modela reliefa prostorske ločljivosti 25 m),
- Smer_ave (povprečne usmerjenost poligona preračunana iz digitalnega modela reliefa prostorske ločljivosti 25 m),
- Površina (površina poligona) in
- ID_travnik (unikaten identifikator, na katerega se vežejo vsi ostali podatki, ki so preračunani iz satelitskih posnetkov).

Izračun povprečnih vrednosti naklonov, nadmorske višine in usmerjenosti za vsak poligon smo izvedli v programskem okolju QGIS (ver 3.10.4).

2.3.2 Statistični pregled referenčnih podatkov


Da odkrijemo potencialno pomembne spremenljivke, ki pripomorejo k ločevanju intenzivnosti rabe travnikov (v fazi strojnega učenja), smo pregledali lastnosti vzorca referenčnih podatkov (združena kartiranja ZRSVN) po več dejavnikih.

Najbolj značilni vrednosti, ki ločita kartirane intenzivne in ekstenzivne travnike, sta naklon in nadmorska višina (Slika 8). Skupno povprečje naklona intenzivnih travnikov je pričakovano značilno nižje (6 %) od skupnega povprečja ekstenzivnih travnikov (13 %). Podobno se izraža tudi razlika v nadmorski višini, intenzivni travniki zavzemajo nižje ležeče lege (v povprečju 297 m), ekstenzivni pa v povprečju nekoliko višje (v povprečju 334 m).



Slika 8: Vrednosti, ki najbolj ločita intenzivne in ekstenzivne travnike, sta naklon (zgoraj) in nadmorska višina (spodaj).

Skupno povprečje usmerjenosti ekstenzivnih travnišč je 167° in je skoraj enako povprečni usmerjenosti intenzivnih travnišč (164°). Glede na usmerjenost površja ne zaznamo statistično močnih razlik med obema primeroma (Slika 9 spodaj). Na legah orientiranih južno in zahodno je višji delež ekstenzivnih travnišč, na vzhodno orientiranih legah pa je višji delež intenzivnih zemljišč. Na severno orientiranih legah je najmanj travnišč, je pa delež intenzivnih večji od ekstenzivnih.



Slika 9: Porazdelitev kartiranih poligonov ZRSVN med leti 2016 in 2019 glede na geografske značilnosti: nadmorsko višino (zgoraj), naklon (sredina), usmerjenost (spodaj). Ekstenzivni travniki so na višjih nadmorskih legah in večjih naklonih (povprečni naklon intenzivnih travnikov je opazno nižji). Največji delež kartiranih travnikov je na južno usmerjenih legah ($135 - 225^\circ$), najmanjši pa na severno usmerjenih legah ($305 - 45^\circ$). V povprečju so intenzivni travniki (rdeče) glede na ekstenzivne (modro) bolj prisotni na severno in vzhodno usmerjenih legah, ekstenzivni pa na južno in zahodno usmerjenih legah.

2.3.3 Čiščenje in priprava referenčnih podatkov

Iz podatkovnega sloja referenčnih podatkov (združena kartiranja ZRSVN) smo izločili travnike, ki so po površini manjši od 500 m² (Slika 10), kar pomeni, da je ostalo le še 41 km² površin (1,2 % površin trajnih travnikov iz evidence RABA). Ta korak je za analize s podatki satelitov Sentinel-1 ali Sentinel-2 v 10 m ločljivosti nujen, saj le tako zagotovimo ustrezen zajem informacij za opazovane površine oziroma zemljišča. S podatki v 10 m ločljivosti ne moremo opazovati zelo majhnih ali zelo ozkih zemljišč, saj lahko v vzorec že zajamemo mešane informacije sosednih (drugih) zemljišč.



Slika 10: Primerni poligoni (rumeni) in neprimerni (črni) na kartiranem območju Mure 2017 za modeliranje s podatki Sentinel-1 in Sentinel-2 v 10 metrski prostorski ločljivosti.

Ker nekateri poligoni poleg habitatnih tipov travnikov zajemajo tudi druge vrste rab (Slika 11), smo poligonom sistematično določili vplivni rob v širini 7 m (Sen4CAP, 2020). V zajem informacij iz satelitskih podatkov za dani poligon preberemo le vrednosti tistih mrežnih celic oziroma pikslov, ki ležijo znotraj vplivnega roba (tako zajamemo piksele, ki so večji del v poligonu).


Podatkovni sloj referenčnih podatkov smo dodatno prečistili na podlagi informacij satelitskih podatkov Sentinel-2, in sicer časovne vrste normirane razlike vegetacijskega indeksa (NDVI). Za poligone preračunamo povprečne vrednosti NDVI za celotno obdobje opazovanja, torej med marcem in decembrom, za leta 2016, 2017 in 2018. Dodatno izločimo poligone, ki imajo v posameznem letu zajetih manj kot 5 časovnih vrednosti. Z drugimi besedami to pomeni, da izločimo tiste travnike, za katere nimamo ustreznih satelitskih podatkov (npr. zaradi dolgotrajne prekritosti z oblaki).



Slika 11: Poligoni travnikov lahko vsebujejo tudi druge rabe (npr. gozd), zato za zajem spektralnih informacij iz satelitskih podatkov za vse poligone travnikov vzpostavimo zajem znotraj vplivnega roba 7 m.

2.4 Dopolnilni podatki

V začetnem delu raziskave smo kot vhodne parametre upoštevali tudi podatke glavnih meteoroloških postaj ARSO, in sicer podatke o povprečni dnevni temperaturi, količini padavin, povprečni oblačnosti in trajanju sončnega obsevanja. Ti podatki naj bi pripomogli k lažjemu določanju časa košnje. V kasnejši fazi smo meteorološke parametre opustili, ker smo ugotovili, da kot taki ne pripomorejo k izboljšanju modela za ločevanje intenzivnosti travnikov s strojnim učenjem.



Slika 12: Rajonizacija rabe, izdelane v okviru naravovarstvene operacije HAB ter območja terenskih podatkov popisa habitatnih tipov ZRSVN – kartiranj HT.


Kot dodaten vhodni parameter smo zaradi geografske in klimatske pestrosti Slovenije upoštevali regionalizacijo rabe, izdelane v okviru naravovarstvene operacije HAB (Slika 12). Regionalizacija je bila izdelana na podlagi povprečnega datuma fenoloških faz opazovanih rastlin (1970–2015) ter upoštevanja karte povprečne temperature zraka (1981–2010) in korigirane višine padavin (1981–2010) (Rajonizacija HAB, 2016). Pri ločevanju intenzivnosti travinj s postopkom strojnega učenja na osnovi satelitskih posnetkov, na tako razgibanem in raznolikem ozemlju, je nujno, da ta podatek vključimo v analizo. Razlog je, da se travniki na območju, označenem s svetlo rjavo barvo, zaradi vpliva morja, prej razvijejo (posledično tudi kosijo) kot višje ležeči travniki na območju prikazanim z oranžno barvo.

Kot je že navedeno v poglavju 2.3.1, smo kot dodatne parametre upoštevali tudi povprečno nadmorsko višino, povprečen naklon in usmerjenost, izračunane iz digitalnega modela višin ločljivosti 25 m.

2.5 Satelitski podatki

V projektu testiramo satelitske podatke, in sicer radarske podatke Sentinel-1 in optične podatke Sentinel-2. Podatke zagotavlja evropski program Copernicus v sodelovanju z Evropsko vesoljsko agencijo. Vsi surovi podatki Sentinel so prosto in brezplačno dostopni, stroški nastanejo z dodatno obdelavo, ki je nujna za uporabo, in s shranjevanjem.

Podatki satelita Sentinel-2A so razpoložljivi od junija 2015, pridobivajo se na 10 dni, od marca 2017, ko je uspešno utirjen tudi drugi satelit Sentinel-2B, se skupna časovna pokritost poveča na 5 dni. Na mestih prekrivanja orbit so podatki za Slovenijo lahko razpoložljivi celo na 2–3 dni (Slika 13). Sentinel-2 je optični satelit, nameščen ima senzor MSI. Prostorska ločljivost je 10 m za spektralne kanale vidnega spektra in bližnji infrardeč spektralni kanal, 20 m za kratkovalovne infrardeče ter 60 m za preostale kanale (skupaj je 13 kanalov). Iz podatkov Sentinel-2 lahko izračunamo vrsto vegetacijskih in drugih indeksov, s katerimi poudarimo in analiziramo različne lastnosti površja. Posnetki so zelo občutljivi na vremenske pogoje, saj oblaki preprečijo pridobivanje podatkov, meglice pa podatke pokvarijo.



Slika 13: Pokritost Slovenije s posnetki Sentinel-2. S temno rdečo barvo so prikazana mesta prekrivanja posnetkov.

Podatki satelita Sentinel-1A so razpoložljivi od aprila 2014 v 12-dnevnem obhodnem času, od konca aprila 2016, ko se pridruži še Sentinel-1B, se skupna časovna pokritost poveča na 6 dni. Sateliti Sentinel-1 so radarski sateliti, nameščeni senzor C-SAR pa omogoča zajem podatkov ponoči in podnevi, neodvisno od vremena, v več polarizacijah in zaradi več načinov zajema tudi v več prostorskih ločljivostih. Iz podatkov Sentinel-1 SLC, ki jih uporabljamo v študiji, izračunamo koherenco in sigma, s katerima prav tako lahko spremljamo in proučujemo pojave na površju Zemlje. Sigma je odbojna vrednost posameznega posnetka, koherenca pa je ujemanje med dvema zaporednima posnetkoma. Koherenca se sicer uporablja v radarski interferometriji kot merilo za kakovost interferograma.


Vsi podatki satelitov Sentinel so razpoložljivi za prevzem in uporabo v največ 24 urah po snemanju. Delovanje satelitov Sentinel je načrtovano za deset let, torej prvih satelitov do najmanj leta 2025, v načrtu je vsaj podvojitev trenutnega stanja (Sentinel-1C in 1D, Sentinel-2C in 2D). V projektu smo podatke prevzeli iz repozitorija Copernicus Open Access Hub (<https://scihub.copernicus.eu/>).

2.5.1 Časovne vrste Sentinel-2

Za pripravo časovnih vrst optičnih satelitskih posnetkov smo uporabili verigo STORM (ZRC SAZU & Space-SI), ki posnetke dnevno prenaša s spletnega portala Copernicus Open Access Hub in jih obdela (Oštir et al., 2015; Čož et al., 2020). Za optične posnetke Sentinel-2 se opravi atmosferske popravke, izračuna izboljšano masko oblakov, opsijsko tudi topografske popravke, ter posnetke istih preletov združi (mozaičenje). Časovne vrste satelitskih posnetkov smo pripravili za leta 2017, 2018 in 2019.

Za izvedbo naloge ločevanja travnišč smo pripravili časovne vrste iz spektralnih kanalov 10 m ločljivosti (B2, B3, B4 in B8 oziroma modri, zeleni, rdeči in bližnji infrardeči spektralni kanal) ter izračunali vegetacijske indekse NDVI, MSAVI2 in EVI.

Preliminarni pregledi časovnih vrst vegetacijskih indeksov so pokazali, da so vizualizacije indeksov različne, vendar pri izračunu odstopanj niso bistvene (časovne vrste indeksov so visoko korelirane, saj se za izračun uporabijo isti kanali, zato opazovani pojav – razvoj travinja skozi rastno sezono – opisujejo na zelo podoben način (Slika 14)). Zato smo za nadaljnje analize izbrali zgolj časovne vrste NDVI.



Slika 14: Primerjava časovnih vrst vegetacijskih indeksov NDVI, MSAVI2 in EVI za opis razvoja travinja v rastni sezoni. Primer se nanaša na vzorčni ekstenzivni travnik. Ugotovitve so enake tudi na vzorcu intenzivnih travnikov in na vzorcih, ki vključujejo 200 naključno izbranih travnikov.


Težave pri opazovanju povzročajo oblaki, kritična je maska oblakov. Izrazito nizke vrednosti in kratki skoki v razvojni krivulji NDVI niso povezani z opravili na travniku, temveč prisotnostjo oblaka ali meglice

nad opazovanim poligonom (Slika 15). Zato pri obdelavi maskiramo (brišemo) vrednosti NDVI manjše od 0,25, saj te ne predstavljajo odbojev travnikov.




Slika 15: Primer košenega travnika. Zelo nizke vrednosti v časovni vrsti NDVI so v primeru opazovanja stalno ozelenjenih površin (košnji sta zabeleženi 2019-06-26 in 2019-09-12, označeno v rdečem) najverjetneje posledica neodstranjenih oblačnih posnetkov (modra oznaka).

Letne časovne vrste optičnih satelitskih podatkov smo ovrednotili z vidika zagotavljanja ustrezne gostote in dodatnega prečiščevanja. Pri uporabi satelitskih posnetkov je praktično za vse aplikacije ključnega pomena ravnanje z neuporabnimi podatki (manjkajoče vrednosti, oblaki, sence oblakov). Največji in še vedno nezadovoljivo rešen problem je učinkovita klasifikacija oblakov in njihovih senc. Za namen razpoznavanja košnje mora biti časovna vrsta na danem zemljišču dovolj gosta, da prestrežemo spremembo in jo uspešno ločimo od šuma v podatkih. Tu so maske oblakov v pomoč, vendar niso popolne in se zato nanje ne moremo izključno zanesti. Časovne vrste lahko filtriramo po dodatnih merilih, da izločimo neuporabne ali za analizo travnikov zavajajoče informacije (Slika 16). Ker na ta način časovno vrsto naredimo neenakomerno gosto, smo preizkusili več načinov časovnega glajenja oziroma časovne interpolacije (frekvence 16, 8 in 5 dni). Izkazalo se je, da je najprimernejše zagotavljati 5-dnevno interpolacijo (Slika 17), saj pri 16- in 8-dnevni interpolaciji izgubimo pomembne karakteristike, ki lahko kažejo razlike med posameznimi travniki, ter glajenje s filtrom Savitzky-Golay.




Slika 16: Neprečiščena časovna vrsta NDVI (modro) in prečiščene, uporabne vrednosti NDVI (rdeča obroba) za naključno izbrana travnika na območju Goričke krajine.



Slika 17: 16-dnevna (a), 8-dnevna (b) in 5-dnevna (c) časovna interpolacija ter vpliv interpolacije na neustrezne vrednosti v podatkih (prisotni oblačni posnetki). Barve prikazujejo tri različne travnike (1, 2, 3), ki so prostorsko korelirani (ležijo na istem študijskem območju), zato se vrednosti NDVI na intervalu med -0.1 in 0.6 bistveno ne razlikujejo.

Za opazovanje razvoja travnikov je primerna letna časovna vrsta med 1. marcem in 30. novembrom. Košnja se izraža kot rahla sprememba odbojnih vrednosti in rahel padec vrednosti NDVI (Slika 18). Tipična letna razvojna krivulja travnika zato nima izrazitih prevojev. Izkazuje razmeroma visoke vrednosti NDVI (0,6–0,9), ki nikoli ne padejo pod 0,4. V primeru sušnih meteoroloških razmer ali travišč na plitvih tleh ter tleh, ki vodo slabo zadržujejo, lahko pričakujemo manj izrazite razlike v krivulji NDVI ter v splošnem nižje vrednosti indeksa NDVI.




Slika 18: Časovna vrsta Sentinel-2 in prikaz razvojne krivulje travnika s košnjami (zelena) ter poljščine (oranžna). Vir: Sen4CAP.

2.5.2 Časovne vrste Sentinel-1

Tudi za radarske posnetke smo uporabili lastno procesno verigo (Pehani et al., 2020), ki deloma temelji na sistemu *Sentinel Application Platform* (SNAP) Evropske vesoljske agencije, dodani pa so koraki za pripravo produktov SAR (angl. *Synthetic Aperture Radar*), amplitude in koherence, ter za združevanje delov snemanj (radarskih pulzov).


Iz radarskih posnetkov Sentinel-1 SLC za območje Slovenije izračunamo *sigmo* in *koherenco*. Redni prenos posnetkov SLC v bazo izvaja servis Python. Glavni procesni algoritem poskrbi za štiri med seboj neodvisne sklope. V predobdelavi se pripravijo procesni nizi, ki vsebujejo zgolj tiste dele posnetka, ki so nad Slovenijo (Slika 19). V obdelavi se nizi obdelajo s klicem procesnih verig, ki so implementirane v okolju SNAP. Opravimo posodabljanje podatkov z natančnimi tirnicami ter odstranjevanje šuma. Gre za zaporedje orodij iz orodjarne S1TBX (Sentinel-1 Toolbox), ki je definirano vnaprej, za vsakega od obeh produktov posebej. Sigma oziroma povratno sipanje se računa za vsak procesni niz. Koherenca se računa med dvema zaporednima snemanjema nad istim območjem (običajna razlika med takima zaporednima snemanjema je šest dni). V poobdelavi se izvede preimenovanje produktov v končno obliko ter preveri njihova pravilnost. Časovne vrste radarskih satelitskih podatkov smo pripravili za leta 2017, 2018 in 2019.

Sigmo (SAR amplituda) si lahko predstavljamo kot intenziteto radarskega zajema, koherenca pa temelji na razlikah faz zajema in poudarjajo raznovrstne časovne razlike med radarskimi zajemi. Tovrstne časovne značilke lahko računamo za poljubne časovne intervale in/ali polarizacije (VV, VH, HV, HH). Prav tako je pri radarskih časovnih vrstah mogoče izbrati opazovanja iz naraščajoče (ASC) in/ali iz padajoče (DESC) tirnice. Smer pogleda radarskega pulza je pomembna, saj vpliva na interakcijo s površjem.



Slika 19: Prekrivanje štirih sosednjih in zaporednih posnetkov S-1A in S-1B, pridobljenih z $dt = 6$ dni, z relativne orbite 022-DESC. Prikazani so vsi trije snemalni pod-pasovi. Prekrivajoča se območja so razporejena med različne kombinacije parov, kar ima za posledico več (v tem primeru osem) skladnih produktov.


Indikator košnje na časovnih vrstah radarskih podatkov Sentinel-1 je mogoče pridobiti iz koherence. Koherenca je korelacija med dvema poravnanimi kompleksnima radarskima posnetkoma (SLC). Visoka koherenca pomeni visoko ujemanje para posnetkov, kar pomeni, da je vsebina med primerjanima datumoma zelo podobna, nizka koherenca pa kaže na spremembe med obema datumoma zajema. Nizka koherenca nakazuje na visoko vegetacijo, visoka koherenca na nizko vegetacijo, zelo visoke vrednosti koherence pa na gola tla (Slika 20). Košnjo zaznamo ob nenadnem naraščanju koherence.



Slika 20: Časovna vrsta koherence Sentinel-1 in prikaz razvojne krivulje travnika z več košnjami. Visoke vrednosti koherence nakazujejo stabilno stanje oziroma stanje nizke vegetacije, nizke vrednosti pa na razlike med dvema datumoma zajema oziroma bujno ali visoko vegetacijo. Vir: Sen4CAP.


Načini oddajanja elektromagnetnih valov Sentinela-1, ki zagotavljajo različno polarizirane meritve, so prikazani v preglednici (Preglednica 2).

Preglednica 2: Seznam polariziranih meritev senzorja Sentinel-1 SAR, razpoložljivih v načinu snemanja SLC (Single Look Complex).



HH	Horizontalno oddajanje, horizontalno sprejemanje signala
VV	Vertikalno oddajanje, vertikalno sprejemanje signala
HV	Horizontalno oddajanje, vertikalno sprejemanje signala
VH	Vertikalno oddajanje, horizontalno sprejemanje signala

Časovne vrste koherence smo ločeno izračunali za naraščajočo in padajočo tirnico (Slika 21a) ter ločeno za polarizaciji VV in VH (Slika 21b). Izkazalo se je, da najboljše rezultate (detekcije košenj) dobimo s časovnimi vrstami obeh tirnic in polarizacijo VV. Razpon vrednosti VV je večji od razpona polarizacije VH, zato lažje razpoznamo posamezne spuste oziroma dvige v koherence, ki kažejo košnjo. Zadnji korak priprave časovnih vrst je prav tako kot pri posnetkih Sentinel-2 glajenje časovnih vrst s filtrom Savitzky-Golay (Slika 21c) ter prevzorčenjem na 5 dnevni interval (enoten interval vseh posnetkov).



Slika 21: Časovna vrsta koherence ločena za naraščajočo (rdeča) in padajočo tirnico (modra) (a), časovna vrsta glede na polarizacijo VV (rjava) in VH (zelena) (b) ter zglajena časovna vrsta (oranžna) (c).

2.5.3 Knjižnica satelitskih posnetkov za izvedbo naloge

V okviru naloge smo obdelali veliko količino podatkov in vzpostavili obsežno knjižnico satelitskih posnetkov Sentinel-1 in Sentinel-2 za območje Slovenije (Preglednica 3). Povprečen čas obdelave posnetka Sentinel-1 je ura in pol, povprečen čas obdelave posnetka Sentinel-2 pa štiri ure. Sama priprava satelitskih podatkov je terjala 38 človek/mesecev časa, izvajali smo jo na več zmogljivih računalnikih hkrati.

Preglednica 3: V okviru naloge smo vzpostavili obsežno knjižnico satelitskih posnetkov za območje Slovenije.

Posnetki	Število			GB			Človek/Mesec
	2017	2018	2019	2017	2018	2019	Skupaj
Sentinel-1 SLC	806	846	869	3700	3900	4000	23,6
Sentinel-2	161	209	216	500	650	670	14,7

3 Določitev učnega vzorca

V tem poglavju podrobneje opisujemo način določevanja učnega vzorca, kar smo v naslednjem koraku uporabili za strojno učenje. Najprej smo preučili lastnosti vzorca ekstenzivnih in intenzivnih travnikov, sledi predstavitev priprave učnih vzorcev in nato predstavitev podatkov za strojno učenje.


3.1 Ugotavljanje lastnosti vzorca ekstenzivnih in intenzivnih travišč

Ekstenzivni in intenzivni travniki se razlikujejo v načinu rabe zemljišč. Kasnejša prva košnja in manjše število košenj nakazuje ekstenzivni travnik. Zato želimo s časovnimi vrstami ugotoviti:


- značilne biofizikalne lastnosti (vsebnost klorofila, višina trave),
- čas prve košnje in
- število vseh košenj na travniku.

Analizirali smo letni razvoj vegetacije intenzivnih in ekstenzivnih travnikov, kot ga izkazujejo satelitski podatki, z namenom prepoznati, ali so dovolj razvidne razlike med obema vrstama travišč (intenzivni, ekstenzivni travniki). Prvo analizo smo izvedli na testnem območju Branice in Vipavske doline za leto 2017, nato pa še na 100 naključno izbranih travnikih iz vzorca pripravljenih referenčnih podatkov. Dodatno smo preverili tudi meteorološke dejavnike v tem obdobju ter povezanost košenj z razvojno krivuljo travnika. Pokazalo se je, da:


- so v časovni vrsti navkljub uporabi maske oblačnosti še vedno prisotni oblaki, zato je nujno vpeljati dodatne pogoje kontrole ustreznosti podatka satelitskih podob (Slika 22);
- vsi obravnavani vegetacijski indeksi (NDVI, EVI2, MSAVI2, NDWI) podajajo podoben odziv, zato se v nadaljnjih analizah osredotočimo zgolj na NDVI (glej Slika 14), ki je tudi splošno najbolj uporabljen in stabilen kazalnik stanja vegetacije;
- ob pregledu v kakšnem razmerju so razvojne krivulje travnikov do meteoroloških dejavnikov (oblačnost, temperatura, padavine), ne moremo zagotoviti enostavnih, analitično opisljivih zvez za izločanje slabih podatkov (Slika 23) zato meteorološke parametre iz analize izpustimo;
- je za opazovanje travnikov primerna koherenca obeh orbit satelita S-1 in polarizacija VV;
- je spektralni podpis intenzivnih in ekstenzivnih travnikov zelo podoben (Slika 24), porazdelitev vzorca ekstenzivnih travnikov leži v območju intenzivnih travnikov (kar za strojno učenje ni primerno);
- je mogoče dokazati povezanost znanih datumov košenj s padci v razvojni krivulji NDVI in naraščanju koherence (primer KP Goričko, Slika 23).




Slika 22: Naključnih 100 ekstenzivnih travnikov: časovna vrsta NDVI pokaže, da so v vzorcu travnikov prisotne košnje, na nekaterih poligonih travnikov pa tudi oblaki (rdeči krogi).



Slika 23: Pregled in primerjanje izbranih meteoroloških dejavnikov z razvojnimi krivuljami intenzivnih in ekstenzivnih travnikov. Rjave črte prikazujejo meteorološki podatek o oblačnosti, ki najbolj vpliva na število uporabnih vrednosti na posnetku Sentinel-2, medtem ko ostale črte prikazujejo vrednosti NDVI oz. razvoj obravnavanih travnikov.




Slika 24: Primerjava skupnega spektralnega podpisa intenzivnih in ekstenzivnih travnikov iz referenčnih podatkov: razlika je majhna, značilen pa je preobrat krivulj okrog 15. avgusta.




Slika 25: Razvidna je povezanost razvojnih krivulj travnika z znanimi datumi košenj. Datume košenj smo pridobili od Uprave KP Goričko in so natančni na nekaj dni.

Preliminarne analize podatkov s strojnim učenjem za testno območje Vipava in Goričko so pokazale na omejitve in težave referenčnih podatkov, to so podatki kartiranja ZRSVN, za uporabo le-teh v strojnem učenju. Zaradi neenakomernega vzorca glede obsega ekstenzivnih in intenzivnih travnikov (ekstenzivni 96 % in intenzivni 4 %) postopek ne loči intenzivnih in ekstenzivnih travnikov (Slika 26).



Slika 26: Klasifikacija intenzivnih (modre vrednosti) in ekstenzivnih (rdeče vrednosti) travnikov na neenakomerno zastopanem vzorcu učnih podatkov ni uspešna. Tudi kazalniki ovrednotenja so razmeroma slabi: ocenjena natančnost klasifikacije znaša 41 %.

Preverili smo različne klasifikatorje ter uporabo izbranega učnega vzorca na drugih območjih. Klasifikacija ni dosegala želenih rezultatov. Zato smo se iskanja in računanja značilnih razlik odbojnih vrednosti med ekstenzivnimi in intenzivnimi travniki (Slika 27) lotili ročno.




Slika 27: Odbojne vrednosti rdečega, zelenega, modrega in infrardečega 10 m kanala na ekstenzivnem (zgornji graf) in intenzivnem travniku (spodnji graf) na dan 2020-03-12 na območju kartiranja Vipave.

Glede na izračune časovnih vrednosti NDVI med marcem in julijem 2017 (za prikazane travnike) smo ugotovili, da travnike (ekstenzivne in intenzivne) najbolj ločijo podatki, ki jih beleži bližnje infrardeč kanal (Slika 28).




Slika 28: Analiza povprečnih vrednosti odbojev vseh kanalov (10 m) med 2017-03-12 in 2017-07-05.

Slika 29 prikazuje razvoj vegetacije na primeru intenzivnih in ekstenzivnih travnikov v barvni kombinaciji bližnje infrardečega, rdečega in zelenega spektralnega kanala. Intenzivna vijolična barva kaže na to, da travnik vsebuje bolj gosto in intenzivno vegetacijo z več klorofila. Vizualno lahko opazimo, da je razvoj vegetacije ekstenzivnih travnikov (vijoličen obod) v začetku rastne sezone (marec, april, maj) počasnejši kot razvoj vegetacije intenzivnih travnikov (moder obod).



Slika 29: Razvoj ekstenzivnih (vijoličen obod) in intenzivnih (moder obod) travnikov (območje Slika 27) v bližnjem infrardečem, rdečem in zelenem kanalu je različen.

Ugotovitev je še bolj poudarjena s prikazom razvoja vegetacije travnikov na podlagi vrednosti NDVI (Slika 30). Ugotovili smo, da to velja za večino kartiranih območij (referenčni podatki), ampak ne za vse, zato je tak vzorec za strojno učenje neprimeren.



Slika 30: Vegetacijske razvojne trende istih travnikov opazimo tudi s časovnim razvojem vrednosti NDVI.

Vse navedene ugotovitve kažejo, da bi v primeru zelo kompleksnega modela z logičnimi pogoji in nadzorovanjem uporabnosti vhodnih (satelitskih) podatkov težko zagotovili vsa izhodišča in pogoje za nameravano ločevanje travnikov. Poleg tega je za strojno učenje treba zagotoviti zanesljiv in sorazmeren ter številčen učni vzorec intenzivnih in ekstenzivnih travnikov. Zaželeno je tudi, da je vzorec prostorsko enakomerno porazdeljen. Vsega tega *referenčni vzorec*, pripravljen iz podatkov kartiranj HT ZRSVN, ne dosega. Zato smo se odločili, da pripravimo nov vzorec *učnih podatkov*, ki bo zanesljiv, pregledan in sorazmeren in kot tak primeren za postopke strojnega učenja.

3.2 Napovedovanje razredov in priprava učnega vzorca

Za postopek strojnega učenja je najprimernejše izhodišče zadostno število učnih vzorcev ter njihova enakomerna zastopanost in porazdelitev. Če bi izdelali napovedi na podlagi vzorca (Preglednica 4) bi bili rezultati slabi, saj je delež ekstenzivnih travnikov za 68 % višji od deleža intenzivnih travnikov. Zato smo učni vzorec ekstenzivnih travnikov z naključnim izbiranjem (angl. *random sampling*) enakomerno prilagodili številu intenzivnih travnikov (Preglednica 5).


Preglednica 4: Število vseh primernih poligonov ekstenzivnih in intenzivnih travnikov na posameznem kartiranem območju.

Območja – časovna vrsta 2017	Število ekstenzivnih travnikov	Število intenzivnih travnikov	Število travnikov
Dolina Vipave in dolina Branice	2250	364	2614
Gorjanci	93	5	98
Mura	741	364	1105
Haloze	3535	170	3705
Kum	909	3	912
Pohorje	0	0	0
Gorička krajina	0	0	0
Polhograjsko hribovje	829	529	1358
Dobličica	208	86	294
Dravinja	383	240	623
Istra	931	79	1010
Volčke	64	6	70
SKUPAJ	9943	1846	11789

Preglednica 5: Uravnoteženo število primernih poligonov na podlagi manjšega vzorca (intenzivnih travnikov).


Območja – časovna vrsta 2017	Število ekstenzivnih travnikov	Število intenzivnih travnikov	Število travnikov
Dolina Vipave in dolina Branice	364	364	728
Gorjanci	5	5	10
Mura	364	364	728
Haloze	170	170	340
Kum	3	3	6
Pohorje	0	0	0
Goriška krajina	0	0	0
Polhograjsko hribovje	528	528	1056
Dobličica	86	86	172
Dravinja	240	240	480
Istra	79	79	158
Volčke	6	6	12
SKUPAJ	1845	1845	3690

Razliko med obema vzorcema jasno kaže porazdelitev podatkov časovne vrste NDVI (Slika 31) na dan 31. 3. 2017, ki po analizah najbolj loči intenzivne in ekstenzivne travnike (v nadaljevanju).



Slika 31: Porazdelitev NDVI vrednosti na dan 2017-03-31 za vse primerne poligone ekstenzivnih (modra) in intenzivnih (rdeča) travnikov (a) in porazdelitev številčno uravnoteženih primerov (b).

Učne poligone pripravimo na uravnoteženem vzorcu. V programskem okolju Orange (ver 3.23) smo na podlagi identifikatorja ID_travnik združili kartirane intenzivne/ekstenzivne travnike in attribute NDVI (za vsak posamezni datum), povprečni naklon, povprečno nadmorsko višino in delež pokritosti poligona z rabo 1300. Časovna vrsta zajema v vsakem poligonu 55 vrednosti NDVI. Pri napovedovanju smo si kot ciljni (*target*) atribut izbrali razred, ki kaže, ali gre za intenzivni oziroma ekstenzivni travnik in je bil prej določen na podlagi izbrane kode Physis (glej preglednico 1). Osnovno statistiko vzorca izvedemo z orodji za izris grafov in diagramov (*Scatter Plot*, *Sieve Diagram*, *Distribution* in *Box Plot*). Z orodjem za izračun oddaljenosti (*Distance*) smo izračunali razdalje med atributi. Razdalje prikazujejo »gručenje« razredov intenzivnih in ekstenzivnih travnikov (Slika 32).



Slika 32: Gručenje v razrede na podlagi preračunanih kosinusnih razdalj med atributi.

Z orodjem za rangiranje (*Rank*) izračunamo in predstavimo najbolj informativne vrednosti, ki v vzorcu ločijo intenzivne in ekstenzivne travnike (Slika 33). Najbolj informativne vrednosti, ki ločijo travnike na podlagi razreda, so časovne vrednosti NDVI na začetku rastne sezone (marec-junij) in naklon. To potrjuje tudi opažanja iz preliminarne pregledov referenčnih podatkov.

Nato smo izvedli napovedovanje razredov na podlagi metod naivnega Bayesovega klasifikatorja, logistične regresije in naključnih gozdov. Te tri metode se pogosto uporabljajo v nalogah strojnega učenja. Za vse tri metode smo pregledali pomembnost posameznih spremenljivk za klasifikacijo. Na določanje razredov intenzivnih in ekstenzivnih travnikov močnejše vpliva 10 atributov. Pri vseh metodah se pokaže, da imajo na ločevanje največji vpliv povprečne vrednosti naklonov, vrednosti NDVI na dan 31. 3. 2017 (ter za druge bližnje datume) ter število primerov na posameznem območju. Iz tega lahko sklepamo, da bi morali imeti za idealno analizo in napovedovanje izbrane naključne vzorce intenzivnih in ekstenzivnih travnikov, ki bi bili enakomerno zastopani po celi Sloveniji, hkrati pa bi morali biti ti vzorci uravnoteženi glede na nadmorsko višino. Rezultati klasifikacije treh metod so razmeroma podobni (Slika 34).

Scoring Methods		#	Info. gain	Gain ratio	Gini	ANOVA	χ^2	ReliefF	FCBF
☒ Information Gain		N 2017-03-31 00:00:00	0.005	0.013	0.034	NA	249.642	0.000	NA
☒ Information Gain Ratio		N 2017-03-26 00:00:00	0.007	0.018	0.036	NA	63.525	0.003	NA
☒ Gini Decrease		N 2017-04-05 00:00:00	0.003	0.017	0.036	NA	6.000	0.010	NA
☒ ANOVA		N 2017-03-21 00:00:00	0.040	0.020	0.027	NA	25.590	0.000	NA
☒ χ^2		N 2017-03-16 00:00:00	0.008	0.019	0.026	NA	31.452	0.000	NA
☒ ReliefF		N 2017-04-20 00:00:00	0.005	0.017	0.024	NA	102.150	0.000	NA
☒ FCBF		N NAKLON_ave	0.028	0.014	0.019	NA	52.673	0.039	NA
		N 2017-04-25 00:00:00	0.027	0.013	0.018	NA	66.336	0.009	NA
		N 2017-03-11 00:00:00	0.026	0.013	0.017	NA	84.693	0.012	NA
		N 2017-05-20 00:00:00	0.004	0.012	0.016	NA	31.864	0.006	NA
		N 2017-05-15 00:00:00	0.004	0.012	0.016	NA	18.267	0.008	NA
		N 2017-04-10 00:00:00	0.020	0.010	0.014	NA	53.841	0.021	NA
		N 2017-04-30 00:00:00	0.016	0.008	0.011	NA	14.509	0.007	NA
		N 2017-05-10 00:00:00	0.016	0.008	0.011	NA	4.978	0.008	NA
		N 2017-05-25 00:00:00	0.015	0.007	0.010	NA	29.723	0.008	NA
		N 2017-04-15 00:00:00	0.014	0.007	0.009	NA	44.439	0.011	NA
		N 2017-05-05 00:00:00	0.014	0.007	0.009	NA	6.019	0.009	NA
		N 2017-05-30 00:00:00	0.012	0.006	0.008	NA	24.730	0.005	NA
		N 2017-11-26 00:00:00	0.010	0.005	0.007	NA	24.806	0.024	NA
		N 2017-09-27 00:00:00	0.008	0.004	0.006	NA	0.007	0.000	NA
		N NMV_ave	0.007	0.004	0.005	NA	18.038	0.006	NA
		N 2017-07-19 00:00:00	0.007	0.004	0.005	NA	21.128	0.008	NA
		N 2017-06-04 00:00:00	0.006	0.003	0.004	0.005088150509474865	12.974	0.008	NA
		N 2017-10-02 00:00:00	0.006	0.003	0.004	NA	3.642	0.007	NA
		N 2017-07-24 00:00:00	0.005	0.003	0.004	NA	11.290	0.017	NA
		N 2017-11-16 00:00:00	0.005	0.002	0.003	NA	0.516	0.000	NA
		N Povrsina	0.005	0.002	0.003	NA	16.694	-0.002	NA
		N 2017-10-07 00:00:00	0.005	0.002	0.003	NA	2.431	0.001	NA

Select Attributes


☐ None


☐ All

☐ Manual

☒ Best ranked:

Slika 33: Po lestvici razvrščene vrednosti, ki najbolj vplivajo na ločevanje intenzivnih in ekstenzivnih travnikov.





Slika 34: Časovni profil NDVI ekstenzivnih (modro) in intenzivnih (rdeče) travnikov na podlagi naivnega Bayesovega klasifikatorja (a), logistične regresije (b) in naključnih gozdov (c).

Oceno točnosti klasifikacije lahko podamo:

- na učnih podatkih (training set, learning set),
- na testnih podatkih (testing set, test set), kjer izločimo del učnih podatkov, s katerimi simuliramo nove podatke (preverimo učenje), želimo si, da je testna množica reprezentativna za nove podatke.

Najprej moramo poznati točnost učnih podatkov. Vemo, da potrebujemo čim več podatkov za:

- uspešno učenje,
- za zanesljivo ocenjevanje točnosti (večje število testnih primerov daje ožji interval zaupanja v oceno točnosti).

Številčnost zanesljivih podatkov smo zagotovili z ročnim pregledom testnega vzorca. Pregledali smo vzorec travnikov, ki je na podlagi vseh treh uporabljenih klasifikacij določen v isti razred.

Za izbran vzorec dobimo tabelo z napovedanimi razredi, kjer so podani razredi klasifikacije posamezne funkcije in vrednosti klasifikacije (format CSV). Datoteko v programskem okolju QGIS-u združimo z


vektorskim slojem kartiranih poligonov HT ZRSVN in izdelamo podatkovni sloj, ki ima razrede po kodi Physis enake napovedanim razredom z logistično regresijo, naivnim Bayesovim klasifikatorjem in funkcijo naključnih gozdov.

Na podlagi napovedi smo izdelali vzorec 1133 intenzivnih in 711 ekstenzivnih travnikov oziroma skupaj 1844 (poligonov) travnikov za ročni pregled. Posamezne travnike smo izločali glede na stanje na najnovejšem državnem ortofotu in satelitskih posnetkih *Google Satellite*.


Ročni pregled smo izvedli s programoma QGIS in Orange. V prvem uporabimo vizualno analizo. Glavno vprašanje je bilo, ali travnik še obstaja ali ne (Slika 35). Če je bil preoran, pozidan, zaraščen ali neprimerne lege oziroma oblike smo ga odstranili iz učnih vzorcev. V programu Orange pa smo pregledali časovne profile učnih vzorcev (Slika 36) – torej smo odgovarjali na vprašanje, ali gre za pravilno napovedan razred? Časovne profile NDVI posameznih travnikov smo preverjali tako, da smo primerjali odziv posameznega travnika s povprečjem celotnega vzorca (Slika 37). Iz povprečnih odbojev vidimo, da se časovni profili najbolj razlikujejo med marcem in junijem oziroma v začetni vegetativni fazi. Torej za razlikovanje med ekstenzivnimi in intenzivnimi travniki ocenimo vrednosti, zajete v omenjenem časovnem intervalu.



Slika 35: Vizualni pregled travnikov v programskem okolju QGIS, pri katerem smo ugotavljali stanje travnika.



Slika 36: Postopek in izris pregleda časovnih profilov v programu Orange - izrisani primer časovne vrste se nanaša na ekstenzivni travnik.



Slika 37: Povprečni časovni profili napovedanih travnikov (1844, zelena črta) v učnem vzorcu, ekstenzivnih (711, rjava črta) in intenzivnih (1133, rdeča črta) travnikov.


Učni primeri travnikov oziroma poligonov, ki smo jih izločili iz učnega vzorca, so bili: zelo ozki poligoni, zelo majhni poligoni, poligoni pretežno v senci, poligoni s pretežnim deležem dreves, njive, druge neozelenjene površine – npr. poti, nasutja, poligoni z več različnimi rabami od katerih ena zagotovo ni travnik, poligoni pretežno ob gozdni meji in podobno (Slika 38). Izločili smo torej poligone, ki se jim je raba v obdobju 2017–2020 spremenila (kartiran travnik ni več travnik, se je spremenil v njivo, se je zarastel ipd.) ali se spektralni odboj ni ujemal s povprečnim odbojem travnikov (mešani pikslji v poligonu). Nekatere večje poligone, če je npr. poligon segal v drugo rabo (gozd, sadovnjak, njiva itn.) ali zajemal večje zaraščeno območje, pa smo urejali (preoblikovali).



Slika 38: Primeri travnikov, izločenih iz učnega vzorca.


V nadaljevanju podajamo še nekaj zanimivosti in opisov lastnosti pripravljenega učnega vzorca.

Na dan 31. 10. 2017 je bilo v evidenci RABA MKGP evidentiranih 352 533 ha trajnih travinj, na dan 31. 4. 2020 je bilo evidentiranih 345 722 ha trajnih travinj. To pomeni, da se je površina trajnih travinj v Sloveniji med leti 2020 in 2017 zmanjšala za 6811 ha. Podatke smo zato dopolnili z rastro trajnih travinj, poravnanimi na mrežo Sentinel-2 za leto 2017 in 2020 (Slika 39).




Slika 39: Raba trajnih travinj (ID_raba = 1300) za leto 2017 (rumena) in 2020 (turkizna) ter ujemanje obeh let (zeleno) prevzorčeno v 10 m ločljivost satelitskega posnetka, ozadje je najnovejši državni ortofoto.

Sklepamo, da je večja verjetnost, da območje predstavlja ekstenzivni travnik tam, kjer se podatki med leti ujemajo. To dodatno ponazori porazdelitev na Slika 40. Torej so ekstenzivni travniki pogostejše tam, kjer je v obeh opazovanih letih (2017, 2020) poligon evidentiran kot dejanska raba trajni travnik.




Slika 40: Porazdelitev razredov intenzivnih (rdeča) in ekstenzivnih (modra) travnikov glede na rastrski podatek razlike trajnih travnikov med leti 2017 in 2020.

Distribucija učnih vzorcev po Sloveniji je prostorsko omejena na območja kartiranj HT ZRSVN. Primeri učnih vzorcev so zastopani tudi v večini razredov po rajonizaciji HAB, z izjemo razreda, ki zajema višje ležeče lege. Največ učnih primerov je na območju, kjer je predviden čas košnje na dan 30. 5. (Slika 41, Slika 42).




Slika 41: Karta razporeditve učnih vzorcev glede na območje Slovenije. Podlaga je rajonizacija HAB, ki predstavlja ekološko pomembna območja posebnih travniških habitatov in priporočen čas košnje.




Slika 42: Porazdelitev učnih vzorcev glede na rajonizacijo HAB. V razredu z najkasnejšim priporočenim datumom košnje (na alpskem območju) ni učnih vzorcev, zato histogram prikazuje od leve proti desni razrede rajonizacije (1,2,3,4). 1 pomeni območje, kjer je priporočen čas košnje 20. 5., 2 območje, kjer je priporočen čas košnje 30. 5., itn. (glej sliko 41).


Večkrat smo omenili, da smo ugotovili, da je največja in najbolj očitna razlika v odboju ekstenzivnih in intenzivnih travnikov razvidna v spomladanskih mesecih. Slika 43 prek izbranih datumov ponazarja ta razmerja tudi za učni vzorec za mesec marec, april in maj.



2017-03-21



2017-04-15



2017-05-20

Slika 43: Porazdelitev vrednosti NDVI za intenzivne in ekstenzivne travnike v marcu, aprilu in maju 2017, in sicer na datume 2017-03-21, 2017-04-15, 2017-05-20.

3.3 Priprava poligonov za strojno učenje

3.3.1 Priprava poligonov na območjih izven GERK-ov


Dogovorjena enota kartiranja so GERK-i. Na območjih maske opazovanja (poglavje 2.2), kjer GERK-ov ni, uporabimo lastne poligone, izdelane s postopkom segmentacije na posnetku Sentinel-2. Pri tem gre za razmejevanje posnetka v homogene dele/segmente z združevanjem sosednjih mrežnih celic oziroma pikslov s podobnimi atributnimi vrednostmi (intenziteta, tekstura, barva itd.) na podlagi več kriterijev homogenosti. Tako ustvarjeni segmenti praviloma ne predstavljajo realnih objektov na posnetku oziroma v naravi, ampak njihove dele. Z optimalno izbiro parametrov segmentacije se pričakuje, da se satelitski posnetek razdeli na semantično pomembne segmente. Postopek na podlagi velikega števila izračunanih prostorskih, spektralnih in teksturnih atributov na posnetku določi homogena območja, ki opisujejo naravne elemente površja.

Segmentacijo smo izvedli v programskem okolju za geoprostorsko obdelavo posnetkov Harris ENVI (ver 5.3). Cilj segmentacije je bil pridobiti homogena zemljišča travnikov, ki bi bila glede delitve in podrobnosti primerljiva z GERK-i.

Vhodni podatek je dnevni mozaik Sentinel-2 iz preleta dne 30. 6. 2019. Prekriva celotno Slovenijo, je brezoblačen in povzema stanje sredi rastne sezone. Posnetek smo obrezali na območja maske travnikov (poglavje 2.2) in izvedli segmentacijo z naslednjimi parametri:

- spektralni prostor: B1, B2, B3, B4, NDVI, 3 kanali v pretvorbo HSI (Hue, Saturation, Intensity),
- algoritem segmentacije (Edge),
- parameter segmentacije 20 (deluje na celotnem vhodnem spektralnem prostoru), parameter združevanja 70 (deluje na spektralnem prostoru kanalov B1-B4),
- filter glajenja velikosti 7 x 7.

Nizka vrednost parametra segmentacije ustvarja precej podrobno razdelitev, s tem pa tudi veliko število segmentov, a le tako smo lahko dosegli razmejevanje med travniki. Razmeroma visoka vrednost parametra združevanja poskrbi za združevanje podobnih soležnih segmentov. Rezultat postopka segmentacije je preko 2 milijona segmentov, ki povzemajo dele travnikov kot so razvidni na satelitskem posnetku obravnavanega dne. Sloj segmentov smo nato dodatno prečistili in uredili v okolju QGIS. Tako smo pridobili podatkovni sloj, ki dopolnjuje območja travnikov izven območij evidence GERK (Slika 44).



Slika 44: Združevanje poligonov GERK-ov in segmentov (levo) in izdelava novih poligonov (desno) tam, kjer GERK-i ne obstajajo.

Izdelali smo sloj, ki predstavlja razliko obeh vektorskih slojev in zajema območja travnikov z rabo 1300. Zaradi lažje nadaljnje analize podatkovni sloj prečistimo tako, da:

- izbrišemo območja s površino manjšo od 1000 m² (10 pikslov Sentinel-2),
- ohranimo območja, kjer trajno travinje (beli piksli, Slika 45) prekriva več kot 60 % segmenta,
- izbrišemo poligone, kjer je povprečna nadmorska višina višja od 1600 m, torej območja travnikov nad gozdno mejo.



Slika 45: Primer urejanja sloja segmentov: brisanje površin manjših od 1000 m² (levo) ter ohranjanje območja, kjer travinje prekriva več kot 60 % segmenta.

Končni rezultat predstavljajo združeni poligoni (Slika 46) GERK-ov in segmentov na območjih trajnih travinj (maska opazovanih travnikov).




Slika 46: Poligoni, kjer se izvaja postopek ločevanja intenzivnih in ekstenzivnih travnikov z daljinskim zaznavanjem, so prevzeti in združeni iz evidence GERK in iz segmentacije posnetka Sentinel-2.

3.3.2 Učni vzorci travnikov in satelitski podatki


Poligonom pripravljenih učnih vzorcev (Slika 41), GERK-om z RABO 1300 in dodatnimi segmenti (za območja izven pokrivanja s slojem GERK), smo v nadaljevanju izračunali časovne vrste povprečnih vrednosti NDVI (Slika 37) in kasneje koherence.

Piksli, ki sestavljajo poligon travnika, lahko zasedejo širok razpon vrednosti NDVI zaradi različnih dejavnikov (spektralni odboj, atmosferski šumi, fizično-geografski pogoji). Vsaka barva na grafu predstavlja en piksel na poligonu travnika (Slika 47).




Slika 47: Časovna vrsta vrednosti NDVI za naključno izbran travnik: sive črte prikazujejo datume posameznih posnetkov. Če na njih ni točk (vrednosti NDVI) je bilo območje zaradi prisotnih atmosferskih шумov (oblakov, meglic itn.) maskirano in odboj na pikslu zato ni prikazan.

Za zagotovitev uporabnosti optičnih satelitskih podatkov moramo izdelati časovni trend vrednosti NDVI posameznega poligona (travnika). Primerjali smo povprečno vrednost, 25 in 75 percentil (Slika 48). Ker nas zanimajo višje vrednosti NDVI, manjše lahko pomenijo tudi meglico ali senco oblaka, smo izbrali 75 percentil. S tem časovno vrsto dodatno prečistimo, zgladimo. Za glajenje uporabimo 75-percentil ter izbrišemo poligone manjše od 5 pikslov, saj lahko le v teh primerih izračunamo trend na poligonu.




Slika 48: Z atmosferskimi šumi (oblaki, meglice itn.) prečiščena (a) in zglajena časovna vrsta NDVI (b) s filtrom Savitzky-Golay in uporabljen 75-percentil vrednosti (c) (modre vrednosti).

Na podlagi tako prečiščenih časovnih vrst izdelamo časovne profile, ki v našem vzorcu predstavljajo trend vseh travnikov ter posebej ekstenzivnih in intenzivnih travnikov (Slika 49). Ugotovimo lahko, da se rezultati pripravljenih časovnih vrst skladajo z napovedmi učnega vzorca (Slika 34). Iz grafa razberemo, da intenzivni travniki dosežejo vrh rastle sezone že v prvi polovici maja, medtem ko ekstenzivni travniki vrh dosežejo šele v sredini junija.



Slika 49: Časovna vrsta vrednosti NDVI na učnih vzorcih travnikov. Povprečni odboj vseh travnikov (oranžno), ekstenzivnih travnikov (modro) in intenzivnih travnikov (vijolično).


Posebno pozornost je treba nameniti tudi strukturi časovne vrste iz optičnih podatkov, saj bi izrazito neenakomerna gostota lahko vplivala na izvedbo klasifikacije s strojnimi učenjem. Preverili smo strukturo časovnih vrst NDVI za vsa aktualna leta kartiranja (Slika 50). Pokaže se, da je za leto 2019 do junija malo podatkov, ti so bili izločeni zaradi oblačnosti. Stanje smo preverili z vzorcem meteoroloških povzetkov in ugotovili, da je meseca maja pokritost neba z oblaki zelo visoka, prav tako količina padavin. Glede na to, da na ločevanje najbolj vplivajo vrednosti NDVI med marcem in junijem, smo ta primer pozorno spremljali.



Slika 50: Delež veljavnih pikselov v časovni vrsti NDVI za leto 2017 (a), 2018 (b) in 2019 (c). Leto 2019 izstopa z majhnim deležem veljavnih podatkov v pomladnem obdobju.

4 Strojno učenje modela in ocena točnosti

V tem poglavju predstavljamo razvoj modela za strojno učenje in njegovo evalvacijo. Metodologijo ločevanja travnikov glede na intenzivnost rabe smo izvedli na območju celotne Slovenije. Zaradi velike količine podatkov in hitrejšega procesiranja smo območje razdelili na manjša podobmočja velikosti 10 km x 10 km (Slika 51).



Slika 51: Območje klasifikacije ekstenzivnih in intenzivnih travnikov obdelujemo po podobmočjih velikosti 10 km x 10 km.

4.1 Izbira in gradnja modelov

Problem ločevanja travnikov smo definirali kot klasifikacijo. S pripravljenimi časovnimi vrstami NDVI in koherence (poglavje 3.3.2) smo za učenje metod, ki jih opisujemo v nadaljevanju, uporabili ročno pregledane poligone (poglavje 3.2). Metode strojnega učenja lahko v splošnem ločimo v nadzorovane in nenadzorovane.

Nadzorovane metode preslikajo vhodne podatke na razrede in s tem določajo parametre modela. Vsak primer je sestavljen iz para vhodnih podatkov (časovna serija, vektor) in izhodne vrednosti, ki se razlikujeta na podlagi naloge. Pogosto imamo vhodni vektor, ki ga preslikamo na eno vrednost. Med učenjem algoritem analizira vhodne podatke in pripravi model s parametri, ki minimizirajo napako napovedanih vrednosti. Model se lahko uporabi za pridobivanje razredov še ne videnih primerov. Za oceno uspešnosti uporabimo natančnost, delež primerov, ki pripadajo razredu in smo jih pravilno klasificirali (intenzivni, ekstenzivni), ter priklic, iz katerega je razviden delež, koliko klasificiranih primerov tudi pripada napovedanemu razredu. V najboljšem primeru se bodo pridobljeni rezultati ujemali s pravimi vrednostmi. Za dobre napovedi modela potrebujemo veliko število učnih primerov, ki dobro zastopajo tudi distribucijo podatkov.


Metode nenadzorovanega učenja analizirajo vzorce v podatkih brez dodatnih informacij o podatkih. Uporabljajo se algoritmi gručenja, ki na podlagi analize vzorcev razdelijo primere v skupine. Pristop uporabljamo, ko nimamo znanih nobenih informacij o primerih in želimo pridobiti informacijo iz njih.

Delno nadzorovano učenje združi oba načina, to je nadzorovano in nenadzorovano učenje. Lahko uporabimo tako označene in neoznačene podatke, ki jih imamo na voljo v veliko večjih količinah. V kombinaciji lahko dosežemo veliko višjo natančnost, kot brez uporabe neoznačenih podatkov. To lahko izkoristimo, ko nimamo na voljo ekspertnega znanja ali pa dovolj informacij.

V našem primeru bi bilo pridobivanje podatkov na terenu za celotno državo zelo kompleksno in dolgotrajno. Tako smo najprej, za seznanjanje s podatki, učili le na označenih podatkih. Kasneje smo to nadgradili z uporabo delno nadzorovanega učenja, kjer vključimo neoznačene podatke za celotno državo. Testirali smo pet pristopov nadzorovanega strojnega učenja (glej tudi Preglednica 6), to so:

- Naključni gozdovi (*Random Forest*),
- SVM (Support Vector Machine),
- Odločitveno drevo (*Decision Tree*),
- kNN (k-Nearest Neighbors),
- Naivni Bayes (*Naive Bayes*).

Najboljše rezultate so dosegli naključni gozdovi, ki temeljijo na odločitvenih drevesih. Na prikazanem drevesu (Slika 52) je odločitveno drevo sestavljeno iz enega vozlišča in dveh listov. V prvem koraku se primeri razdelijo na podlagi datuma 2017-04-05 nad in pod mejo NDVI 0.607 v dva lista.



Slika 52: Primer drevesa z dvema nivojema, korenom in dvema listoma.

Meje odločitev določimo v fazi učenja na podlagi podatkov. Na podlagi mer, kot sta informacijski prispevek ali relief, izberemo najbolj informativen atribut. V vozlišču primere razdelimo na podlagi določene meje, s tem v listih pridobimo dve množici primerov, ki ustrezajo izbranemu pogoju. Postopek ponovimo v obeh listih, dokler v generiranih listih ne ostanejo primeri z enim razredom ali dosežemo vnaprej določeno globino drevesa. Prednost metode sta preprosta interpretacija in razumevanje, z uporabo regularizacije pa je metoda tudi odpornejša na šum v podatkih. Uporabimo jih lahko tudi, ko imamo manjkajoče vrednosti v učnih podatkih. Omejitve metod nastopijo pri obdelavi strukturiranih podatkov, ki jih je potrebno predhodno obdelati, saj ob učenju izgubimo strukturo podatkov. Metoda ni vedno najboljša rešitev in lahko se zgodi, da imajo preprosti problemi zelo kompleksna drevesa. Vzrok za kompleksno drevo je lahko tudi prekomerno prilagajanje učnim podatkom. Temu se lahko izognemo z uporabo regularizacije. Pogosto uporabljena metoda regularizacije je obrezovanje, zgrajena drevesa zmanjšamo (obrežemo) na različne načine. Z obrezovanjem odstranimo liste ali cele veje in zmanjšamo možnost prekomernega prilagajanja učnim podatkom, izberemo lahko globoke veje ali manjše delitve podatkov. Težavo lahko opazimo, ko dosegamo dobre rezultate na učnih primerih in slabe na testnih.

Rezultate lahko izboljšamo s kompleksnejšimi pristopi. V primeru odločitvenih dreves je pogosto naslednji korak uporaba metode naključnih gozdov. Boljše rezultate dosegamo z združitvijo več dreves, tako imenovanim ansamblom. Uporabljajo se lahko za regresijo in klasifikacijo tako kot odločitvena drevesa. Postopek izgradnje posameznega drevesa je enak, proces učenja se razlikuje v tem, da za izgradnjo posameznega drevesa uporabimo naključno podmnožico primerov in drevesa za napoved razreda časovne vrste glasujejo. S tem je pristop tudi bolj odporen na prekomerno prilaganje učnim

podatkom. Naključni gozdovi se razlikujejo tudi v naključnem izboru atributov, ki so uporabljeni za izgradnjo več globokih odločitvenih dreves, s katerimi napovemo ciljne razrede. V izgradnji vsakega drevesa tako izberemo naključen vzorec podatkov in z naključnimi atributi učimo model, s čimer pohitrimo in izboljšamo proces učenja metode.

Zaradi obsežnosti problema in dostopnosti neoznačenih podatkov smo evalvirali tudi metode delno nadzorovanega učenja. S tem lahko izkoristimo veliko količino podatkov, ki so na voljo, in z označenimi podatki na podlagi distribucije neoznačenih bolje zajamemo in optimiziramo metode strojnega učenja. Delno nadzorovano učenje je zasnovano na predpostavki označenih podatkov in vključitvijo distribucije neoznačenih podatkov. Če primeri spadajo v isto gručo, so potem tudi verjetno istega razreda. Če trditev drži, se razredi neoznačenih primerov ujemajo z bližnjimi označenimi primeri in spadajo v iste liste generiranega drevesa.

4.2 Evalvacija modelov

Pripravljene časovne vrste smo razdelili po območjih kartiranj in evalvirali uspešnost metod. S programsko rešitvijo Orange smo evalvirali časovne vrste za leto 2017. Izvedli smo desetkratno prečno preverjanje na pregledanih travnikih (Preglednica 6) in z naključnimi gozdovi dosegli 94,5 % z mero F1, ki z eno številko predstavlja vmesno vrednost med natančnostjo in priklicem. Naključnim gozdom sledijo metode podpornih vektorjev (SVM), odločitveno drevo, k-najbližjih sosedov in naivni Bayes.

Preglednica 6: Evalvacija različnih metod strojnega učenja na pregledanih poligonih, vrednosti so podane v odstotkih.

Model	AUC	CA	F1	Natančnost	Priklic
Naključni gozdovi	98,3	94,5	94,5	94,5	94,5
SVM	96,7	90,3	90,2	90,2	90,3
Odločitveno drevo	87,4	83,2	83,1	83,1	83,2
kNN	87,4	82,9	82,3	83,3	82,9
Naivni Bayes	87,8	75,8	73,2	79,5	75,8
Povprečje	91,5	85,3	84,7	86,1	87,7

Metoda naključnih gozdov se je od vseh najbolj odrezala. Evalvirali smo še generalizacijo te metode z izvzetjem območja iz učne množice (Preglednica 7). To nudi vpogled v uspešnost, ki jo metoda lahko doseže na še ne videnih podatkih. Metoda v povprečju doseže boljše rezultate, ker smo rezultate utežili po območjih, ki imajo različno število travnikov.

Preglednica 7: Evalvacija metode naključnih gozdov z izključitvijo posameznega območja, vrednosti so podane v odstotkih.

Izvzeto območje	F1
Dravinja	97,2
Haloze	94,8
Istra	97,0
Kum	100,0
Mura	92,5
Polhograjsko Hribovje	90,7
Vipava Branica	100,0
Povprečje	96,0

Uspešnost metode naključnih gozdov smo primerjali tudi z učenjem na kartiranih podatkih (Kartiranje HT ZRSVN) in jih primerjali z rezultati na pregledanih podatkih, ki so pripravljeni in ročno pregledani učni vzorci. Rezultate primerjave podaja Preglednica 8. Z učenjem na kartiranih podatkih lahko v povprečju dosežemo 79 % vrednost F1 in 70 % na pregledanih podatkih. Metode v nekaterih primerih generalizirajo zadovoljivo v drugih zelo slabo. Večja težava je, da v primeru pregledanih travnikov ne dosegamo dobrih rezultatov. Iz tega sledi, da se vzorec, ki se ga model nauči na kartiranih travnikih, ne prenese na pregledane travnike.

Preglednica 8: Evalvacija metode naključnih gozdov glede na uporabljene učne podatke, vrednosti mere F1 so podane v odstotkih.

Območje	Kartirani	Pripravljeni in pregledani
Dobličica	68,9	33,4
Dravinja	54,3	48,3
Goričko	99,2	95,7
Gorjanci	91,9	87,6
Haloze	91,4	81,8
Istra	89,5	78,1
Kum	98,7	87,8
Mura	58,9	69,6
Polhograjsko Hribovje	51,1	70,9
Vipava Branica	79,2	51,8
Volčeke	88,6	60,6
Povprečje	79,2	69,6

Zaradi majhnega vzorca so to tudi najboljši rezultati, ki jih lahko dosežemo z uporabo izbrane metode. Boljše rezultate lahko dosežemo z vključitvijo neoznačenih podatkov v proces učenja, vendar je možnost nepristranske evalvacije otežena.

Prej opisani rezultati so pridobljeni na podlagi označenih podatkov. To so časovne serije, za katere imamo informacijo, v katero kategorijo travnik pripada. Vendar imamo na območju Slovenije še veliko travnikov, ki niso zajeti v tem vzorcu. Te lahko izkoristimo z uporabo delno nadzorovanega učenja. Izbrali smo naključne gozdove, ki so v prejšnjih korakih dosegli najboljše rezultate, in v učenje z uporabo orodja *Clus* vključili še neoznačene podatke. Metode delno nadzorovanega učenja zelo pogosto pridejo do izraza v primeru, kot je naš, ko imamo na voljo majhno količino označenih podatkov, saj z vključitvijo neoznačenih podatkov pridobimo informacijo o distribuciji vrednosti.

Letna kartiranja travnikov, za vse kombinacije satelitskih podatkov (časovne vrste Sentinel-1, Sentinel-2), ki jih podajamo v naslednjem poglavju (poglavje 5), smo pridobili z implementacijo metode naključnih gozdov z delno nadzorovanim učenjem.

5 Rezultati in ovrednotenje

V tem poglavju predstavljamo rezultate strojnega učenja, kjer posebej izpostavimo omejitve in možnosti izboljšav.


Ločevanje območij trajnih travnikov na ciljna razreda intenzivni/ekstenzivni travniki smo izvedli za različne kombinacije vhodnih podatkov, tj. vhodnih časovnih vrst poligonov travnikov, in sicer bodisi samostojne ali kombinirane:

- S-1 (ASC): časovna vrsta koherenc, pridobljenih iz podatkov na dvigajoči se orbiti,
- S-1 (DESC): časovna vrsta koherenc, pridobljenih iz podatkov na padajoči orbiti,
- S-1: združena časovna vrsta iz časovnih vrst S-1 (ASC) in S-1 (DESC),
- S-2: časovna vrsta NDVI,
- S-1 in S-2: združena časovna vrsta iz časovnih vrst S-1 (ASC), S-1 (DESC) in S-2.

Vse rezultate smo pregledali in primerjali glede na delež in območja določenih ciljnih razredov ter njihove lastnosti (nadmorska višina, naklon, usmerjenost, območja rajonizacije HAB). Osredotočili smo se tudi na območja prekrivanja oziroma potrjevanja (enako določane ciljne razrede travnikov) ter na območja, kjer so razhajanja. Pomemben podatek za oceno uspešnosti so tudi območja, ki jih model ne zmore razvrstiti v ciljna razreda ter delež le teh.

5.1 Rezultati s časovnimi vrstami S-2 NDVI

Slika 53 kaže končni rezultat – ločevanje intenzivnih in ekstenzivnih travnikov s podatki S-2 NDVI za leto 2017.




Slika 53: Kartiranje travišnih habitatnih tipov s podatki S-2 NDVI s poudarkom na ločevanju intenzivnih (rdeča) in ekstenzivnih (modra) travnikov za leto 2017.

Vidimo, da delež intenzivnih travnikov (82 % v 2017) presega delež ekstenzivnih travnikov (15 % v 2017) v vseh analiziranih letih (Preglednica 9). Intenzivne in ekstenzivne travnike smo določali skupno na 30.588 ha zemljišč, ki so bili leta 2020 evidentirani kot trajni travnik (RABA 1300). Torej so bili intenzivni travniki v letu 2017 določeni na 25 082 ha, v letu 2018 na 24 776 ha in v letu 2019 na 22 329 ha zemljišč. Ekstenzivni travniki so bili evidentirani na 4588 ha v letu 2017 in 2018 ter na 7341 ha v letu 2019. Ločevanja travnikov s podatki Sentinel-2 nismo mogli izvesti na 920 ha (3 % vseh analiziranih zemljišč) zaradi premajhnih zemljiških parcel kartiranih poligonov oziroma zaradi manjkajočih podatkov (več v poglavju 5.8).

Preglednica 9: Deleži (v odstotkih) ekstenzivnih in intenzivnih travnikov glede na rajonizacijo HAB in podatke časovne vrste S-2 NDVI.

Rajonizacija HAB	2017		2018		2019		Povprečna površina maske travnikov
	Ekstenzivni travnik [%]	Intenzivni travnik [%]	Ekstenzivni travnik [%]	Intenzivni travnik [%]	Ekstenzivni travnik [%]	Intenzivni travnik [%]	
HAB 1 (20. 5.)	23	72	12	83	23	72	262
HAB 2 (30. 5.)	18	78	20	76	25	71	13 048
HAB 3 (10. 6.)	10	87	9	87	19	78	12 409
HAB 4 (20. 6.)	19	79	16	82	33	65	4226
HAB 5 (30. 6.)	10	85	31	65	25	71	643
SKUPAJ [%]	15	82	15	81	24	73	96 ²
Površina [ha]	4588	25 082	4588	24 776	7341	22 329	30 588


Sloj rajonizacije Slovenije za določitev območij HAB nam pomaga vrednotiti kakovost končne klasifikacije. Glede na to, da območje rajonizacije HAB 5 zajema višje ležeče predele Slovenije (Alpsko območje) in območje rajonizacije HAB 1 razgibane kraške predele Goriškega in Slovenske Istre, sklepamo, da je raba travnikov tam bolj ekstenzivna kot intenzivna. Triletna primerjalna analiza (Slika 54) kaže, da se leto 2018 bistveno razlikuje od preostalih analiziranih let. Takrat je na območju rajonizacije HAB 1 zaznanih več intenzivnih (vijolična barva) in manj ekstenzivnih travnikov (zelena barva), na območju rajonizacije HAB 5 se razmerje obrne. Leti 2017 in 2019 sta si po deležih zaznanih travnikov (obeh razredov) bistveno bolj podobni. Razberemo, da je uporabljen model strojnega učenja na območju rajonizacije HAB 5 zaznal višji delež intenzivnih kot ekstenzivnih travnikov, kar kaže na to, da model na Alpskem območju s podatki S-2 slabše klasificira razreda intenzivnih in ekstenzivnih travnikov.



Slika 54: Deleži (v odstotkih) ekstenzivnih in intenzivnih travnikov glede na posamezna leta in rajonizacijo HAB s podatki časovne vrste S-2 NDVI.

² Skupni 96 % zato, ker na 4 % maske trajnih travinj nismo mogli izvesti ločevanja intenzivnih in ekstenzivnih travnikov.

Z grafov (Slika 55) je razvidno, da se povprečne časovne vrednosti NDVI na ekstenzivnih in intenzivnih travnikih v vseh letih najbolj razlikujejo v začetnem in končnem delu rastne sezone. To pomeni, da je indeks NDVI v obdobju med marcem in junijem ter v septembru višji na intenzivnih kot na ekstenzivnih travnikih. Glede na medletno primerjavo najbolj odstopa leto 2018 (Slika 55b), sploh v začetku rastne sezone. Razlog pripisujemo izpadu podatkov zaradi slabih vremenskih pogojev (oblačnost), saj je bil prvi uporabljeni posnetek z nižjo stopnjo oblačnosti zajet na dan 21. aprila 2018.



Slika 55: Časovna vrsta S-2 NDVI (skupno povprečje) intenzivnih (rdeča) in ekstenzivnih (modra) travnikov.

Zanimalo nas je tudi, ali smo z modelom ločevanja zajeli značilne razlike glede na delitve območij po rajonizaciji HAB ter ali so med območji prisotne razlike v kakovosti rezultatov.


Časovni profil (Slika 56a) predstavlja območje rajonizacije HAB 1, kjer je predviden datum 1. košnje 20. maj. Kartiranih je bilo 5276 poligonov, od česar je bilo evidentiranih 1061 poligonov (21 %), ki se razprostirajo na 5,5 km², kot ekstenzivni travniki, ter 4185 (79 %) na 30 km² kot intenzivni travniki. Povprečni naklon ekstenzivnih travnikov znaša 8,7° in intenzivnih 8,1°. Glede na časovni profil NDVI vidimo, da intenzivni travniki vrh rastne sezone dosežejo prej kot ekstenzivni. Intenzivni travniki vrh rastne sezone dosežejo predvidoma že 30. aprila (0,78 NDVI), ekstenzivni 30. maja (0,76 NDVI). Vrh NDVI pomeni vrh priraščanja biomase, ne pomeni pa zaključka razvojnega cikla rastlin, ki pri ekstenzivnih travnikih po priraščanju še zacvetijo in po tem še semenijo. Ravno zaradi slednjega krivulja NDVI na ekstenzivnih travnikih, po doseženem vrhu, počasi upada, na intenzivnih travnikih pa je ta padec, ki obenem kaže na tudi na padec biomase, bistveno hitrejši.

Časovni profil NDVI (Slika 56b) predstavlja območje rajonizacije HAB 2, kjer je previden datum 1. košnje 30. maj. Na tem območju je bilo kariranih 157 144 poligonov, od tega jih je bilo 79 % evidentiranih kot intenzivni travniki (124 519 poligonov) in 21 % kot ekstenzivni travniki (32 625 poligonov). Skupna površina intenzivnih travnikov znaša 927,6 km² in površina ekstenzivnih travnikov 166,4 km². Povprečni naklon intenzivnih travnikov je 7,9°, ekstenzivnih travnikov 8,7°. Glede na časovni profil NDVI intenzivni travniki vrh NDVI dosežejo 30. aprila (0,78 NDVI), ekstenzivni travniki pa 30. maja (0,76 NDVI).

Časovni profil NDVI (Slika 56c) predstavlja območje rajonizacije HAB 3, kjer je previden datum 1. košnje 10. junij. Skupna površina travnikov znaša 783,2 km² (112 127 poligonov), od tega je 662,6 km² (88 686 poligonov) intenzivnih in 120,6 km² (23 441 poligonov) ekstenzivnih travnikov. Povprečni naklon intenzivnih travnikov znaša 7,9° in ekstenzivnih 8,8°. Intenzivni travniki ležijo na povprečni nadmorski višini 402 m, ekstenzivni na 458 m. Glede na časovni profil NDVI lahko vidimo, da intenzivni travniki vrh prirastka biomase dosežejo že 5. maja (0,77 NDVI) in ekstenzivni travniki 30. maja (0,76 NDVI).

Časovni profil NDVI (Slika 56d) predstavlja območje rajonizacije HAB 4, kjer je previden datum 1. košnje 20. junij. Na omenjenem območju je skupno zaznanih 209,1 km² travnikov (29 607 poligonov). Na 79 % površin (178,2 km² oziroma 23 483 poligonov) predstavljajo intenzivni travniki in 21 % (30,9 km² oziroma 6124 poligonov) ekstenzivni travniki. Povprečni naklon intenzivnih travnikov znaša 7,9° in ekstenzivnih travnikov pa 8,9°. Intenzivni travniki so v povprečju na nadmorski višini 407 m, ekstenzivni pa na 457 m. Časovni profil NDVI kaže, da intenzivni travniki vrh prirastka biomase doživijo 30. aprila (0,78 NDVI) in ekstenzivni travniki 30. maja (0,76 NDVI).

Časovni profil NDVI (Slika 56e) predstavlja območje rajonizacije HAB 5, kjer je previden datum 1. košnje 30. junij. Na območju je skupno 44,1 km² trajnih travnikov. 37,2 km² (78 %) površin je bilo evidentiranih kot intenzivni travnik in 6,8 km² (22 %) kot ekstenzivni travnik. Povprečni naklon intenzivnih travnikov znaša 8,0°, ekstenzivnih travnikov pa 8,9°. Časovni profil NDVI kaže, da intenzivni travniki vrh rastne sezone doživijo 14. julija (0,75 NDVI) in ekstenzivni travniki 19. junija (0,76 NDVI). Časovni profil se tudi razlikuje od vseh prejšnjih, kar kaže na to, da je klasifikacija travnikov tu slabša. Razlog je v tem, da za to območje ne razpolagamo s primernim učnim vzorcem, saj gre za alpsko območje in kartiranj habitatnih tipov ZRSVN tukaj ni. Območje od vseh prej opisanih najbolj odstopa in je problematično z vidika dosežene uspešnosti klasifikacije travnikov.



Slika 56: Časovne vrste S-2 NDVI intenzivnih (rdeča) in ekstenzivnih (modra) travnikov glede na rajonizacijo HAB za leto 2017.

5.1.1 Vrednotenje rezultatov (S-2 NDVI)

Rezultate smo pridobili z uporabo delno nadzorovanega učenja. Preglednica 10 prikazuje natančnost modela na pregledanih (učni) in kartiranih (testni) podatkih (kartiranja HT ZRSVN - razširjen vzorec³). Na učnih podatkih v vseh letih dosežemo s podatki S-2 natančnost višjo od 91 %. V primeru testnih podatkov, terenskih kartiranj HT ZRSVN, dosežemo v analiziranem obdobju natančnost med 55,1 in 60,9 %. Medletna odstopanja natančnosti, tako na učnih, kot na testnih podatkih, je lahko posledica kartiranih podatkov, ki izhajajo iz različnih let kartiranj. Odstopanja so lahko tudi posledica šuma v podatkih, kot je oblačnost.

Preglednica 10: Natančnost metode nadzorovanega strojnega učenja (v odstotkih) na podatkih S-2 NDVI.

Leto	Učni podatki	Testni podatki
2017	92,9	58,5
2018	91,1	55,1
2019	92,3	60,9

Za lažje razumevanje, kako delno nadzorovano strojno učenje v posameznem letu loči razrede (intenzivni, ekstenzivni), smo z metodo Genie3 določili 10 najbolj vplivnih atributov (Preglednica 11) za posamezno leto. Največji vpliv na ločevanje travnikov imajo poleg časovnih vrednosti NDVI, ki so zajete na datum naveden v preglednici, tudi usmerjenost površja, regionalizacija in naklon. Glede na vrednosti indeksa NDVI so leta 2017 na klasifikacijo najbolj vplivali meseci april, junij in julij. Leta 2018 junij in avgust. Leta 2019, prav tako kot 2017, vplivajo začetni meseci rastne sezone, torej april in maj. Ti rezultati dodatno potrdijo dejstvo (kar se razbere tudi iz povprečnih časovnih vrednosti NDVI na zgornjih grafih), da se intenzivni in ekstenzivni travniki s podatki satelita Sentinel-2 med sabo najbolj ločijo v začetku rastne sezone (april–maj). Obenem razberemo, da v letu 2018 ti podatki manjkajo, zato model drugače določi končna razreda.

Preglednica 11: Pomembnost atributov za ločevanje razreda na podlagi časovne vrste S-2 NDVI.

pomembnost	atributi 2017	atributi 2018	atributi 2019
1.	usmerjenost	usmerjenost	usmerjenost
2.	14. 7. 2017	naklon	10. 4. 2019
3.	naklon	HAB2	HAB1
4.	10. 4. 2017	14. 6. 2018	HAB2
5.	HAB1	18. 8. 2018	9. 6. 2019
6.	4. 7. 2017	HAB1	4. 6. 2019
7.	3. 8. 2017	4. 6. 2018	15. 4. 2019
8.	HAB2	HAB3	naklon
9.	4. 6. 2017	9. 6. 2018	20. 5. 2019
10.	15. 4. 2017	23. 8. 2018	30. 5. 2019

³ Razširjen vzorec pomeni, da vzorec ekstenzivnih travnikov predstavljajo kartiranja zajeta med 2016 – 2019 ter vzorec intenzivnih travnikov 2010 – 2019, saj se slednji več let ne morejo spremeniti v ekstenzivno rabo.

5.2 Rezultati s časovnimi vrstami S-1 koherenca

Pri radarskih časovnih vrstah je travnike mogoče klasificirati z opazovanji naraščajoče (ASC) in padajoče (DESC) tirnice, s kombinacijo obeh tirnic in v različnih polarizacijah (glej poglavje 2.5.2). Rezultati, ki jih dobimo na podlagi časovne vrste koherence padajoče tirnice oziroma časovne vrste koherence naraščajoče tirnice, niso popolnoma identični. Zato smo se odločili, da končni rezultat kartiranja traviščnih habitatnih tipov s podatki S-1 dobimo s kombinacijo časovne vrste obeh tirnic (ASC + DESC) s polarizacijo VV (Slika 57).

Skupna površina kartiranih območij je vedno ista, torej 30 588 ha trajnih travinj (RABA 1300 po podatkih iz leta 2020). S podatki S-1 so bili v letu 2017 določeni intenzivni travniki na 23 553 ha (77 %) in ekstenzivni na 5812 ha (19 %) zemljišč (Preglednica 12). V letu 2018 so bili intenzivni travniki zaznani na 23 247 ha (-1,3 % glede na 2017) in ekstenzivni travniki na 6118 ha (+1,7 % glede na 2017). Leta 2019 so bili intenzivni travniki zaznani na 24.164 ha (+1 % glede na 2018) in ekstenzivni travniki na 5200 ha (-15 % glede na 2018). Ločevanja travnikov s podatki Sentinel-1 kartiranje nismo izvajali na 1224 ha zemljišč (4 % vseh analiziranih zemljišč) predvsem zaradi premajhnih zemljiških parcel kartiranih enot in izpada podatkov.

Preglednica 12: Deleži (v odstotkih) in površine (v hektarih) kartiranih ekstenzivnih in intenzivnih travnikov glede na rajonizacijo HAB in podatke časovne vrste S-1 koherenca (kombinacija naraščajoče in padajoče tirnice).

Rajonizacija HAB	2017		2018		2019		Povprečna površina maske travnikov
	Ekstenzivni travnik [%]	Intenzivni travnik [%]	Ekstenzivni travnik [%]	Intenzivni travnik [%]	Ekstenzivni travnik [%]	Intenzivni travnik [%]	
HAB 1 (20. 5.)	18	77	6	89	18	76	262
HAB 2 (30. 5.)	14	82	22	74	18	78	13 048
HAB 3 (10. 6.)	18	78	13	84	15	81	12 409
HAB 4 (20. 6.)	32	65	29	69	18	79	4226
HAB 5 (30. 6.)	55	43	72	25	41	57	643
SKUPAJ [%]	19	77	20	76	17	79	96
Površina [ha]	5812	23 553	6118	23 247	5200	24 164	30 558


Glede na rajonizacijo HAB razberemo, da se delež kartiranih intenzivnih travnikov, po posameznih razredih rajonizacije HAB (med 2 in 5), konstantno povečuje, medtem ko velja za delež ekstenzivnih travnikov ravno obratno – delež se manjša (Slika 58). Največ kartiranih intenzivnih travnikov leži na nadmorski višini med 273 in 495 m (HAB 2 in HAB 3), katerih povprečni naklon znaša 6,4° in so usmerjeni proti jugu (180 °). Največ klasificiranih ekstenzivnih travnikov leži na bistveno višji nadmorski višini – med 921 in 1245 m, z večjim povprečnim naklonom 26,9° in jugo-vzhodno usmerjenostjo terena (165°).

Slika 59 kaže, da je povprečna letna koherenca na zaznanih intenzivnih travnikih višja od povprečne koherence na ekstenzivnih travnikih v vseh opazovanih letih. Dodatno lahko potrdimo, da leto 2018 statistično odstopa od drugih analiziranih let (enako smo ugotovili tudi za podatke S-2), predvsem na začetku in koncu opazovanega obdobja, kar lahko znatno vpliva na razlike končnih letnih kartiranj.


Zanimalo nas je tudi, ali smo z modelom ločevanja zajeli značilne razlike glede na delitve območij po rajonizaciji HAB ter ali so med območji prisotne razlike v kakovosti rezultatov.

Iz analize regionalizacije (Slika 60) ugotovimo, da se graf (a) najbolj razlikuje od preostalih štirih območij, obenem pa je najbolj podoben povprečnim časovnim profilom koherence v letih 2017 in 2019 (Slika 59). Po pregledu arhiva meteoroloških podatkov ARSO ugotovimo, da je marca 2018 na vseh


območjih po Sloveniji zapadel sneg, razen na območju rajonizacije HAB 1. Ravno to je posledica, da se graf povprečnih vrednosti koherenc, na območju rajonizacije HAB 1, razlikuje od območji HAB 2-5 oziroma da se podatki in posledično klasifikacija travnikov 2018 razlikuje od klasifikacije 2017 in 2019. Prav tako pa razlike povprečnih vrednosti koherenc opazimo tudi na območju visokogorskih travnikov (Slika 60e), ki jih sneg pokriva dlje časa. Predvidevamo, da slednje prav tako vpliva na manj točne rezultate klasifikacije na območju HAB 5, kjer sicer nimamo referenčnih podatkov.




Slika 57: Kartiranje traviščnih habitatnih tipov s podatki Sentinel-1 koherenca s poudarkom na ločevanju intenzivnih (rdeča) in ekstenzivnih (modra) travnikov za leto 2017.



Slika 58: Deleži (v odstotkih) ekstenzivnih in intenzivnih travnikov glede na posamezna leta in rajonizacijo HAB s podatki časovne vrste S-1 koherenca in polarizacije VV.



Slika 59: Časovna vrsta S-1 koherence intenzivnih (rdeča) in ekstenzivnih (modra) travnikov.



Slika 60: Časovne vrste S-1 koherence intenzivnih (rdeča) in ekstenzivnih (modra) travnikov glede na rajonizacijo HAB za leto 2018.

5.2.1 Vrednotenje rezultatov (S-1 koherenca)

Kot smo omenili že na začetku poglavja 5, smo kartiranja s podatki S-1 analizirali v treh različnih kombinacijah, in sicer ločeno s podatki naraščajoče tirnice (S-1 ASC), s podatki padajoče tirnice (S-1 DESC) in s kombinacijo obeh, vse s polarizacijo VV. Preglednica 13 kaže rezultate ocene natančnosti končnih rezultatov kartiranj, ki jih dobimo z nadzorovanim učenjem z različnimi podatki S-1. Z uporabo časovne vrste koherenc naraščajoče tirnice (ASC) dosežemo 99 % natančnost na učnih podatkih in 58 % na testnih podatkih (kartiranjih HT ZRSVN – razširjen vzorec). V primeru časovne vrste koherenc padajoče tirnice (DESC) so rezultati v vseh analiziranih letih na učnih podatkih primerljivi z rezultati, ki jih dobimo s podatki S-1 (ASC). Če model učimo na kombinirani časovni vrsti S-1 (ASC in DESC), povečamo velikost vhodnega vektorja oziroma število vhodnih parametrov. Natančnost rezultatov je primerljiva z natančnostjo, ki jo dobimo s podatki S-1 (ASC) razen leta 2018.

Preglednica 13: Natančnost metode nadzorovanega strojnega učenja (v odstotkih) na podatkih S-1 (ASC), S-1 (DESC) in S-1 (ASC + DESC).

Leto	S-1 (ASC)		S-1 (DESC)		S-1	
	Učni podatki	Testni podatki	Učni podatki	Testni podatki	Učni podatki	Testni podatki
2017	99,5	58,8	99,4	59,4	99,5	58,3
2018	99,4	57,8	99,4	60,9	99,7	58,1
2019	99,3	59,4	99,5	59,1	99,4	58,8

Rezultati natančnosti metode strojnega učenja kažejo na to, da ne glede na vhodne parametre dosežemo podobne končne rezultate. Zato smo se odločili, da končne rezultate predstavlja kombinacija podatkov S-1.


Da lažje razumemo, kako se model odloči za posamezen razred klasifikacije v posameznem letu, smo z metodo *Genie3* ponovno določili 10 najbolj vplivnih atributov (Preglednica 14). V primerjavi s podatki S-2 lahko rečemo, da v primeru kartiranja z radarskimi posnetki (S-1) fizično-geografske lastnosti, kot so usmerjenost in naklon terena ter regionalizacija, nimajo bistvenega vpliva na končno razvrstitev podatkov v razreda. Tu so v vseh analiziranih letih v ospredju časovne vrednosti koherence zajete na začetku (med aprilom in majem) (glej datume v preglednici) in na koncu rastne sezone (oktobra). To pomeni, da se na podlagi koherence intenzivni travniki najbolj ločijo od ekstenzivnih travnikov prav v omenjenem obdobju.

Preglednica 14: Pomembnost atributov za ločevanje razreda travnikov na podlagi združene časovne vrste S-1.

pomembnost	atributi 2017	atributi 2018	atributi 2019
1.	26. 4. 2017 (ASC)	10. 7. 2017 (ASC)	usmerjenost
2.	21. 4. 2017 (DESC)	18.10. 2018 (DESC)	29. 9. 2019 (ASC)
3.	10. 7. 2017 (ASC)	16. 4. 2018 (ASC)	19. 10. 2019 (DESC)
4.	16. 4. 2017 (DESC)	3. 10. 2018 (DESC)	4. 10. 2019 (ASC)
5.	8. 10. 2017 (ASC)	11. 4. 2018 (ASC)	17. 4. 2019 (DESC)
6.	1. 5. 2018 (ASC)	21. 4. 2018 (ASC)	2. 4. 2019 (ASC)
7.	28. 9. 2017 (DESC)	23. 10. 2018 (DESC)	17. 5. 2019 (ASC)
8.	10. 7. 2017 (DESC)	13. 9. 2018 (ASC)	14. 10. 2019 (DESC)
9.	8. 9. 2017 (ASC)	18. 10. 2018 (ASC)	9. 10. 2019 (DESC)
10.	11. 4. 2017 (ASC)	8. 10. 2018 (ASC)	27. 4. 2019 (ASC)

5.3 Rezultati z združeno časovno vrsto S-2 NDVI in S-1 koherenco

Glede na to, da se rezultati kartiranja traviščnih habitatnih tipov s podatki S-2 in S-1 razlikujejo, smo izdelali še karte na podlagi združitve vseh obstoječih podatkov. Združili smo podatke koherence časovnih vrst S-1 (naraščajoče in padajoče tirnice) in vegetacijskega indeksa NDVI S-2 ter dopolnili attribute, ki so rajonizacija HAB ter naklon, usmerjenost in nadmorska višina terena. Rezultat kartiranja za leto 2017 prikazuje Slika 61. Končni rezultati kartiranja so podani v Prilogah 2-4.




Slika 61: Kartiranje traviščnih habitatnih tipov z združevanjem časovnih vrst Sentinel-1 in Sentinel-2, s poudarkom na ločevanju intenzivnih (rdeča) in ekstenzivnih (modra) travnikov za leto 2017.

Preglednica 15: Deleži (v odstotkih) ekstenzivnih in intenzivnih travnikov glede na rajonizacija HAB in podatke časovne vrste S-1 (kombinacija naraščajoče in padajoče tirnice) v kombinaciji s podatki S-2.

Rajonizacija HAB	2017		2018		2019		Povprečna površina maske travnikov [ha]
	Ekstenzivni travnik [%]	Intenzivni travnik [%]	Ekstenzivni travnik [%]	Intenzivni travnik [%]	Ekstenzivni travnik [%]	Intenzivni travnik [%]	
HAB 1 (20. 5.)	11	85	11	85	17	79	262
HAB 2 (30. 5.)	23	74	21	76	21	76	13 048
HAB 3 (10. 6.)	19	78	16	82	15	82	12 409
HAB 4 (20. 6.)	21	77	25	73	16	82	4226
HAB 5 (30. 6.)	38	59	45	53	29	68	643
SKUPAJ [%]	21	76	20	78	18	79	97
Površina [ha]	6423	23 247	6118	23 859	5506	24 165	30 558

Skupna površina kartiranih območij je enaka, to je 30 588 ha trajnih travinj (RABA 1300 leta 2020). S kombinacijo satelitskih posnetkov S-1 in S-2 model v letu 2017 skupno zazna intenzivne travnike na 23 247 ha in ekstenzivne travnike na 6423 ha zemljišč. Leta 2018 se delež intenzivnih travnikov, glede na prejšnje leto (2017), poveča za 2 % oziroma 612 ha. Delež ekstenzivnih travnikov leta 2018 pade za 1 % oziroma 305 ha. Isti trend naraščanja in padanja se ponovi v letu 2019. V letu 2019 delež intenzivnih travnikov naraste za 1 %, delež ekstenzivnih travnikov pa pade za 2 %. To pomeni, da so bili leta 2019 v Sloveniji na podlagi daljinskih podatkov zaznani intenzivni travniki na 24 165 ha zemljišč trajnih travnikov in ekstenzivnih travnikov le še na 5506 ha zemljišč (Slika 61). Analiza kaže, da se delež intenzivnih travnikov povečuje na račun površin ekstenzivnih travnikov. Ločevanja zaradi premajhnih zemljiških parcel in izpada podatkov nismo izvedli na 920 ha trajnih travnikov (RABA 1300). Območja so na karti (Slika 61) prikazana z zeleno barvo.



Slika 62: Deleži (v odstotkih) ekstenzivnih in intenzivnih travnikov glede na posamezna leta in rajonizacijo HAB s podatki združene časovne vrste S-1 in S-2.

Z analizo deležev (Slika 62) glede na rajonizacijo HAB ugotavljamo:

- na območju rajonizacije HAB 1 se je povečal delež ekstenzivnih travnikov in zmanjšal delež intenzivnih travnikov (v letu 2019), kar je lahko tudi posledica večjega števila razpoložljivih podatkov (2019 je bilo najmanj oblačnih dni v skupnem analiziranem triletnem obdobju);
- na območju rajonizacije HAB 2 se delež intenzivnih travnikov v vseh letih zmanjšuje (glede na območje rajonizacije HAB 1), medtem ko delež ekstenzivnih travnikov naraste;
- na območju regionalizacije HAB 3 delež intenzivnih travnikov (glede na območje rajonizacije HAB 2) ponovno naraste in delež ekstenzivnih travnikov upade;
- na območju rajonizacije HAB 4 in HAB 5 delež intenzivnih travnikov postopno upada, medtem ko delež ekstenzivnih travnikov narašča;
- glede na razmerje je največ intenzivnih travnikov zaznanih na območju rajonizacije HAB 2 in HAB 3;
- glede na razmerje je največ ekstenzivnih travnikov zaznanih na območju rajonizacije HAB 5;
- letna razmerja intenzivnih in ekstenzivnih travnikov so glede na območja rajonizacije HAB podobna, kar kaže na to, da je model v primeru, ko uporabimo vse razpoložljive podatke najbolj stabilen.

Primerjavo povprečne nadmorske višine, naklona in usmerjenosti terena klasificiranih ekstenzivnih in intenzivnih travnikov z združenimi podatki S-1 in S-2 in za vsa leta opazovanja povzema Preglednica 16. Hitro lahko razberemo, da ležijo klasificirani ekstenzivni travniki v vseh letih v povprečju na višji

nadmorski višini in na strmejšem terenu kot intenzivni travniki. Usmerjenost terena pa v poprečju med razredoma ne predstavlja bistvene razlike.

Preglednica 16: Primerjava povprečne nadmorske višine, naklona in usmerjenosti terena klasificiranih ekstenzivnih in intenzivnih travnikov z združenimi podatki S-1 in S-2 za vsa leta opazovanja ter glede na rajonizacijo HAB.

Leto kartiranja	Razredi po območjih rajonizacije HAB	Povprečna nadmorska višina travnikov [n.m.v]		Povprečni naklon travnikov [°]		Povprečna usmerjenost travnikov [°]	
		Ekstenzivni	Intenzivni	Ekstenzivni	Intenzivni	Ekstenzivni	Intenzivni
2017	HAB 1 (20. 5.)	115,1	123,2	7,1	6,4	196,7	195,9
	HAB 2 (30. 5.)	334,6	304,8	8,8	7,1	177,1	173,1
	HAB 3 (10. 6.)	486,6	451,3	12,9	7,9	179,0	174,1
	HAB 4 (20. 6.)	792,1	778,0	14,2	12,0	183,6	178,1
	HAB 5 (30. 6.)	1081,5	1052,1	25,8	26,7	172,8	172,2
	<i>Povprečje</i>	<i>440,9</i>	<i>414,2</i>	<i>11,4</i>	<i>8,2</i>	<i>178,3</i>	<i>174,4</i>
2018	HAB 1 (20. 5.)	135,0	120,3	7,4	6,3	193,6	196,3
	HAB 2 (30. 5.)	329,2	307,0	8,9	7,1	174,5	174,1
	HAB 3 (10. 6.)	489,5	452,0	12,4	8,2	175,3	175,2
	HAB 4 (20. 6.)	801,7	773,4	13,0	12,3	178,6	179,9
	HAB 5 (30. 6.)	1069,8	1060,2	25,0	27,5	170,9	174,0
	<i>Povprečje</i>	<i>449,7</i>	<i>412,2</i>	<i>11,2</i>	<i>8,3</i>	<i>175,2</i>	<i>175,4</i>
2019	HAB 1 (20. 5.)	115,1	123,9	7,0	6,3	191,3	197,0
	HAB 2 (30. 5.)	324,3	308,6	8,6	7,2	163,5	177,6
	HAB 3 (10. 6.)	473,8	454,9	12,1	8,3	167,7	177,0
	HAB 4 (20. 6.)	778,8	781,8	14,2	12,1	172,2	181,4
	HAB 5 (30. 6.)	1096,3	1047,5	25,8	26,5	171,1	173,4
	<i>Povprečje</i>	<i>422,1</i>	<i>419,9</i>	<i>10,9</i>	<i>8,4</i>	<i>176,3</i>	<i>178,0</i>

5.3.1 Vrednotenje rezultatov (S-2 NDVI in S-1 koherenca)

Preglednica 17 podaja rezultate učenja na vseh razpoložljivih podatkih. Vhodni vektor v klasifikaciji vsebuje tri časovne vrste, in sicer NDVI (S-2), koherenco S-1 (ASC) in S-1 (DESC). Na učnih podatkih dosežemo za vsa leta nad 90 % natančnosti in od 55 do 60 % natančnost v primeru testnih podatkov (kartiranje HT ZRSVN – razširjen vzorec).

Preglednica 17: Natančnost metode nadzorovanega strojnega učenja (v odstotkih) na združenih podatkih S-1 in S-2.

Leto	Učni podatki	Testni podatki
2017	94,2	58,3
2018	91,2	55,3
2019	91,0	60,5

Za boljše razumevanje atributov pri kombinaciji podatkov obeh satelitov smo ovrednotili njihovo pomembnost (Preglednica 18). Med najbolj pomembnimi atributi prevladujejo podatki S-1. V predhodnih evalvacijah smo z njimi že dosegli dobre rezultate (glej poglavje 5.2). Njihova ponovna uvrstitev na seznam vplivnih atributov za ločevanje intenzivnih in ekstenzivnih travnikov je dodatna potrditev, da so radarski posnetki S-1 nepogrešljiv vir informacij za kartiranje traviščnih habitatnih tipov. Razlogi zato so predvsem neodvisnost od vremenskih pogojev. Ponovno vidimo, da so najvišje uvrščeni prav začetni in končni meseci rastne sezone (glej datume v preglednici). Iz tega sledi, da se ekstenzivni in intenzivni travniki najbolj razlikujejo prav v tem obdobju.

Preglednica 18: Pomembnost atributov za ločevanje razreda travnikov na podlagi kombinacije časovne vrste S-1 in S-2.

<i>pomembnost</i>	<i>atributi 2017</i>	<i>atributi 2018</i>	<i>atributi 2019</i>
1.	20. 7. 2017 (DESC)	aspect	20. 8. 2019 (ASC)
2.	8. 9. 2017 (DESC)	16. 4. 2018 (ASC)	7. 5. 2019 (ASC)
3.	28. 9. 2017 (ASC)	28. 9. 2018 (ASC)	9. 10. 2019 (ASC)
4.	23. 9. 2017 (DESC)	8. 10. 2018 (DESC)	29. 10. 2019 (DESC)
5.	10. 6. 2017 (ASC)	26. 4. 2018 (ASC)	17. 4. 2019 (DESC)
6.	13. 9. 2017 (DESC)	13. 10. 2018 (DESC)	22. 4. 2019 (ASC)
7.	3. 9. 2017 (DESC)	28. 9. 2018 (DESC)	29. 9. 2019 (DESC)
8.	1. 5. 2017 (ASC)	25. 6. 2018 (ASC)	7. 5. 2019 (DESC)
9.	10. 7. 2017 (ASC)	1. 5. 2018 (ASC)	2. 5. 2019 (DESC)
10.	21. 4. 2017 (ASC)	24. 8. 2018 (DESC)	4. 10. 2019 (DESC)


5.4 Primerjava klasifikacij

S primerjavo rezultatov klasifikacij, izdelanih na različnih vhodnih podatkih (izbrana časovna vrsta satelitskih posnetkov) ugotovimo, da med rezultati prihaja do manjših medletnih odstopanj. Deleži intenzivnih in ekstenzivnih travnikov, se medletno najbolj razlikujejo pri klasifikaciji izdelani na vhodni časovni vrsti S-2 (Preglednica 19). Kot smo že prej ugotovili, dobimo najbolj stabilne in zanesljive rezultate z uporabo kombinirane časovne vrste S-1 (ASC, DESC) in S-2 NDVI. Končni rezultati kažejo, da se v analiziranem obdobju (2017 – 2019) delež ekstenzivnih travnikov postopoma zmanjšuje (iz 21 % na 18 %), na račun povečevanja deleža intenzivnih travnikov (iz 76 % na 79 %).

Preglednica 19: Deleži zemljišč, razvrščenih v ciljne razrede (v odstotkih) glede na uporabljene časovne vrste in leta kartiranja - učni podatki in model razvrščanja so pri vseh enaki.

	<i>Vhodna časovna vrsta</i>	<i>Ekstenzivni travnik</i>	<i>Intenzivni travnik</i>	<i>Nedoločljivi travniki</i>
2017	S-1 (ASC)	18	79	4
	S-1 (DESC)	22	74	4
	S-1 (ASC in DESC)	19	77	4
	S-2	15	82	3
	S-1 (ASC, DESC) in S-2 NDVI	21	76	3
2018	S-1 (ASC)	16	80	4
	S-1 (DESC)	20	77	4
	S-1 (ASC in DESC)	20	76	4
	S-2	15	81	3
	S-1 (ASC, DESC) in S-2 NDVI	20	78	3
2019	S-1 (ASC)	15	81	4
	S-1 (DESC)	19	77	4
	S-1 (ASC in DESC)	17	79	4
	S-2	24	73	3
	S-1 (ASC, DESC) in S-2 NDVI	18	79	3

Če sloje končnih kartiranj (2017 – 2019), dobljene s kombinirano časovno vrsto S-1 (ASC, DESC) in S-2 NDVI, prekrijemo, dobimo karto travnikov z območji, ki se v vseh analiziranih letih ne spreminjajo (območja so vedno kartirana kot intenzivni oz. ekstenzivni travniki), nedoločljivimi območji in območji sprememb (območja, kjer model medletno različno klasificira v končne razrede)(Slika 63).




Slika 63: Karta območij kjer se kartiranja, dobljena s kombinirano časovno vrsto, v vseh opazovanih letih, tj. 2017, 2018 in 2019, določena kot ekstenzivni oz. intenzivni travnik, kot nedoločena območja oz. kot območja sprememb (med letnimi kartiranjimi prihaja do razlik).

Z območji, ki jih model določi z visoko zanesljivostjo (jih uvrsti v vseh letih v isti razred) lahko pri naslednjih letnih kartiranjih, povečamo število travnikov v učnem vzorcu. Tako dobimo vzorec, ki je na ravni države bolj homogen (saj nismo več omejeni samo na območja kartiranj ZRSVN), s tem pa lahko zagotovimo kakovostnejše pogoje za strojno učenje in rezultate klasifikacije. Ugotovili smo, da gre za večletni iterativni postopek modeliranja (travnikov), ki ga lahko izboljšujemo z letnim povečanjem učnih vzorcev in z večjim številom razpoložljivih satelitskih posnetkov.

5.5 Zaznavanje košenj

Ključni podatek za razvrščanje (klasifikacijo) v ciljna razreda intenzivni ali ekstenzivni travnik je število košenj ter datum prve košnje. Za ekstenzivne travnike pričakujemo manj košenj (vsaj eno, največ dve) ter kasnejšo prvo košnjo. Košnje smo določali s pregledom časovnih vrst radarskih podatkov S-1 (ASC) in S-1 (DESC) na poligonih vseh travnikov. Razvili smo postopek, ki samodejno zaznava pomembne skoke koherence (tj. spremembe, ki praviloma kažejo na košnjo), jih presoja po logičnih pogojih ter izpiše pripadajoče povprečne datume košenj (Slika 64). Podatek o košnji (povprečni datum, število košenj) se nato kot atribut poligona vpiše v atributno tabelo vektorske datoteke letne karte. Zaradi velike dinamike, ki jo pri koherenci opazamo med letom, je bolj zanesljiv podatek datum prve košnje⁴, število košenj pa je lahko precenjeno.

⁴ Gre za povprečne datume košenj, za oba razreda travnikov (intenzivne, ekstenzivne), kjer intenzivni travniki v vzorcu prevladujejo.




Slika 64: Zaznane košnje na koherenci podatkov S-1: s postopkom razpoznanje košnje so označene z rdečo črto.

Datum zaznane prve košnje se med opazovanimi leti različno izraža, to kaže (Slika 65). Rezultati tu nakazujejo, da je bila v letih 2017 in 2019 prva košnja prej kot leta 2018. Značilna je tudi razlika med območji rajonizacije HAB (Preglednica 20, Slika 65). Povprečni datumi košenj v sloju rajonizacije HAB 4 in 5 so kasnejši, v rajonizaciji HAB 1 in 2 pa zgodnejši. Pri sloju rajonizacije HAB 5 opažamo težave pri zaznavi, te so verjetno posledica spomladanskega snega (kar se na radarskih posnetkih odraža podobno kot zelo nizka vegetacija) in kasnejšega začetka rasti.


Preglednica 20: Povprečni datum zaznane prve košnje (intenzivnih in ekstenzivnih travnikov) po letih in rajonizaciji HAB.

Leto	Rajonizacija HAB	Povprečni zaznan datum prve košnje
2017	skupaj	18. 5. 2017
	1	6. 5. 2017
	2	16. 5. 2017
	3	20. 5. 2017
	4	22. 5. 2017
	5	21. 5. 2017
2018	skupaj	18. 5. 2018
	1	10. 5. 2018
	2	16. 5. 2018
	3	17. 5. 2018
	4	23. 5. 2018
	5	1. 6. 2018
2019	skupaj	16. 5. 2019
	1	13. 5. 2019
	2	14. 5. 2019
	3	17. 5. 2019
	4	22. 5. 2019
	5	22. 5. 2019


Rezultate, dobljene s podatki S-1, ocenjujemo kot zelo obetavne za zaznavanje povprečnega datuma košenj, vendar so potrebne nadaljnje raziskave za boljše razumevanje posamičnih vplivov. Informacije iz dvigajoče in padajoče tirnice niso identične (zaradi geometrije opazovanja glede na usmerjenost posameznega travnika), smiselno jih je povezati z oblikovnostjo reliefa, možnosti so tudi še druge polarizacije. Te naloge presegajo okvir te študije.



Slika 65: Povprečne prve košnje zaznane na podatkih S-1 koherence, prikazane glede na območja rajonizacije za ukrepe HAB in po letih 2017, 2018 in 2019.



Slika 66: Pogostost števila košenj na ekstenzivnih (modra) in intenzivnih travnikih (rdeča) glede na rajonizacijo HAB.




Slika 67: Zaznavanje povprečnega datuma prve košnje travnikov na podlagi podatkov S-1.

5.6 Rastrska klasifikacija


Kot dodatno analizo smo izdelali rastrsko klasifikacijo travnikov na manjšem študijskem območju, (velikem 10 x 10 km). Izbrano območje pokriva območje Dravinje (kartirano 2019) in območje Haloz (kartirano 2016). Pri rastrski analizi je najmanjša enota kartiranja ena rastrska celica oz. piksel v velikosti 100 m² (Sentinel-2) in ~193 m² (Sentinel-1). Model na ta način ni omejen na poligone GERK-ov oz. na segmente, ampak izdelava klasifikacijo za vsako rastrsko celico posebej (Slika 68).

Vizualna analiza klasifikacije kaže, da model več intenzivnih travnikov klasificira na ravninskem predelu (največ v Dravinjski dolini), medtem, ko je več ekstenzivnih travnikov, na jugu, na bolj razgibanem terenu (območje Haloz). Slednje potrjujejo tudi terenski podatki, to je kartiranje ZRSVN.



Slika 68: Rezultat kartiranja z rastrsko analizo s podatki S-2 NDVI 2019.


Prednost rastrske analize je, da nismo prostorsko omejeni na poligone večje od 1000 m² ampak lahko analiziramo tudi manjše enote. V tem primeru ne izgubimo majhnih in ozkih parcel, obenem pa velike poligone razdelimo na manjše dele, na dele travnikov, kot se dejansko uporabljajo (Slika 69). To razberemo, če primerjamo državni ortofoto (stolpec a) in rezultate kartiranja z rastrsko analizo, kjer se uporabi časovna vrsta S-2 (stolpec c). V primeru kartiranja z rastrsko analizo in časovno vrsto S-1 (stolpec d) pa vidimo, da se končni rezultati bistveno razlikujejo od prej omenjenih kartiranj (S-2). Za dosego večjega ujemanja med podatki je potrebna dodatna analiza, ki presega okvir zastavljene študije.




Slika 69: Primeri posameznih travnikov (1–4). Stolpec (a) prikazuje kartografsko podlago DOF (vir: GURS, 2020), stolpec (b) prikazuje kartiranja s kombinirano časovno vrsto S-1 in S-2 (2019) na poligonih GERK-ov oz. segmentov, stolpec (c) prikazuje kartiranja z rastrsko analizo in časovno vrsto S-2 (2019) ter stolpec (d) prikazuje kartiranja z rastrsko analizo in časovno vrsto S-1 (2019).

Tako kot pri predhodno izvedenih analizah smo tudi tu preverili povprečne letne časovne vrednosti NDVI na kartiranih intenzivnih in ekstenzivnih travnikih. Značilen vzorec se ponovi tudi v primeru rastrske analize (Slika 70).

Če primerjamo povprečne vrednosti NDVI še med posameznimi leti, vidimo, da vrednosti v posameznem razredu (intenzivni, ekstenzivni travnik) kažejo medletno korelacijo, ampak med njimi prihaja tudi do razlik. Gre za problem izpada podatkov zaradi medletnih vremenskih nihanj ter posledično različnega števila uporabnih satelitskih posnetkov (izpad posnetkov zaradi oblačnosti).



Slika 70: Časovna vrsta S-2 NDVI (skupno povprečje) intenzivnih (rdeča) in ekstenzivnih (modra) travnikov z rastrsko analizo.




Slika 71: Medletna primerjava povprečnih NDVI vrednosti na ekstenzivnih (levo) in intenzivnih travnikih (desno) na ožjem analiziranem območju z rastrsko analizo.

Rastrska analiza je v primerjavi z vektorsko analizo (vsa prej izvedena kartiranja, ki so vezana na poligone GERK-ov in segmentov) pokazala na določene prednosti. Glavne so: možnost klasifikacije

majhnih površin in delov travnikov, s čimer se zelo približamo tudi namenu monitoringa travnišč in varovanih okolij, ki so prostorsko bolj omejena. Pozitivno presenečenje je tudi, da so rezultati kartiranja razmeroma homogeni (ustrezno označujejo dejanske dele travnikov). To pripisujemo skrbno pripravljenim satelitskim in učnim podatkom. Glavna slabost je, da dolžina priprave in obdelave podatkov na ravni rastrske celice še vedno presega trenutne razpoložljive računalniške zmogljivosti in kapacitete. Analizirano študijsko območje, ki zajema približno 250 000 rastrskih celic z RABO 1300 (trajni travniki) je model klasificiral 5 ur, zato taka analiza na ravni države v tej študiji ni bila izvedena. Za morebitno odločitev za državno kartiranje travnikov na nivoju rastrske celice, ki zahteva večjo računsko zmogljivost (najetje t. i. super računalnika), se znatno poveča tudi končna cena ocenjenih stroškov letnega kartiranja.

5.7 Vizualna ocena klasifikacije in območja zanesljivosti

Končne rezultate lahko ocenimo tudi vizualno. Primer vizualne ocene je izdelan za manjše območje, ki leži na območju Dravinjske doline in Haloze (Slika 72). Uporabljeni so sloj kartiranja HT ZRSVN, učni vzorci za učenje modela, izvedena kartiranja na kartiranih enotah GERK-ov in segmentov ter kartiranja na enoti rastrske celice.



Slika 72: Primerjava terenskih kartiranj HT ZRSVN (1a), učnih podatkov (2a), klasifikacija modela z vektorsko analizo in s podatki daljinskega zaznavanja S-1 in S-2 za leto 2019 (1b – območja terenskih kartiranj HT ZRSVN in 2b – razširjeno analizirano območje s poligoni GERK-ov in segmentov) ter klasifikacija modela z rastrsko analizo s podatki daljinskega zaznavanja S-2 za leto 2019 (1c – območja terenskih kartiranj HT ZRSVN in 2c – razširjeno analizirano območje, ki zajema rastrske celice z RABO 1300).


Vsa kartiranja kažejo podobne zaključke. Več intenzivnih travnikov se nahaja na ravninskih predelih, ki so človeku dostopnejši in lažji obvladljivi s hitrim mehanskim načinom obdelovanja in omogočajo večjo

intenzifikacijo. Ekstenzivni travniki se pojavljajo na manjših parcelah in na strmejšem terenu, kjer naravni pogoji sami po sebi zahtevajo bolj tradicionalne načine kmetovanja, ki so v današnjem času časovno in ekonomsko manj donosni. Primer vizualne analize (Slika 72) nakazuje, da je klasifikacija na enoti rastrske celice lahko dovezetnejša za kartiranje ekstenzivnega razreda travnikov, vendar bi zaključek ali tudi zares daje točnejše rezultate lahko podali le z analizo in pregledom na več različnih območjih.

5.8 Zanesljivost in določljivost postopka ločevanja travnikov

V luči skupne ocene rezultatov klasifikacije lahko strnemo naslednje splošne ugotovitve:

- Model klasifikacije (pri vseh uporabljenih kombinacijah vhodnih časovnih vrst podatkov) dosega na učnih podatkih visoko statistično natančnost kartiranja (nad 90 %), na testnih podatkih pa okoli 60 %.
- Končne letne klasifikacije (razvrščanje trajnih travnikov na intenzivne in ekstenzivne travnike) se razlikujejo glede na izbrane vhodne časovne vrste. V študiji smo dokazali, da dobimo najbolj natančne in homogene rezultate kartiranja s kombinirano časovno vrsto satelitskih posnetkov Sentinel-1 in Sentinel-2.
- Stabilnost kartiranja je spremenljiva tako med leti (isti vhodni podatki) kot za isto leto med različnimi vhodnimi podatki. Površin, ki so z različnimi vhodnimi podatki (Sentinel-1, Sentinel-2) enako klasificirane v vseh analiziranih letih je približno 7 % pri ekstenzivnih travnikih in okoli 65 % pri intenzivnih. S temi območji lahko prostorsko enakomerno razširimo trenutno uporabljen učni vzorec klasifikacije in tako povečamo končno natančnost letne klasifikacije.
- Rezultati klasifikacije se v opazovanem obdobju (2017 – 2019) spreminjajo. Izkazalo se je, da se površina ekstenzivnih travnikov postopno zmanjšuje na račun večanja intenzivnih travnikov.
- Zanesljiva klasifikacija travnikov je na območjih, ki so identično klasificirana z vsemi tremi postopki (terensko kartiranje, učni poligoni in z daljinskim zaznavanjem).
- Zemljiška razdrobljenost Slovenije: na območjih majhnih in ozkih parcel (široke manj kot 10 m) klasifikacije razredov s posnetki Sentinel na osnovi vektorskih podatkov (poligoni travnikov) ni mogoče izvesti (Slika 73), za ta območja bi bila primerna rastrska analiza.
- Vzorec učnih podatkov lahko s podatki o zanesljivosti klasifikacije modela v prihodnje razširimo na raven države, kar pomeni, da vzorec travnikov ne bi bil omejen le na območja kartiranja ZRSVN.
- V primeru, da bi v model klasifikacije vključili še potencialno zaznane povprečne datume košenj in njihovo število, lahko točnost končnega letnega kartiranja na ravni države izpopolnimo in znatno izboljšamo.




Slika 73: Območja, kjer klasifikacija travnikov z daljinskim zaznavanjem (podatki Sentinel) na poligonih travnikov (GERK in segmenti) ni možna. Zaradi premajhnih zemljišč postopka klasifikacije ni mogoče izvesti na 3 % opazovanega območja trajnih travnikov (~920 ha).

6 Predlagan postopek ločevanja intenzivnih in ekstenzivnih travišč

Postopek letnega kartiranja traviščnih habitatnih tipov z namenom ločevanja intenzivnih in ekstenzivnih travišč iz satelitskih podatkov Sentinel-1 in Sentinel-2 je zasnovan v več korakih (glej Slika 74). Ključna elementa za uspešnost kartiranja sta razpoložljivost ustreznih učnih podatkov za strojno učenje ter razpoložljivost in skrbna priprava časovnih vrst poligonov travnikov.

Trenuten predlog za ločevanje intenzivnih in ekstenzivnih travišč temelji na obeh virih satelitskih podatkov, radarskih Sentinel-1 in optičnih Sentinel-2, ter za ločevanje uporablja strojno učenje (delno nadzorovano z naključnimi gozdovi). Najprej je treba opredeliti in izdelati masko opazovanih območij ter pripraviti satelitske podatke (časovne vrste satelitskih podatkov: koherenca za S-1 in NDVI za S-2). Nato pripravimo učne vzorce in vse razpoložljive poligone travnikov (GERKi, segmenti) povežemo z izbranimi atributi (naklon, nadmorska višina, usmerjenost, rajonizacija HAB, časovni profili iz časovnih vrst satelitskih podatkov S-1 ter S-2). Za radarske podatke (radarska časovna vrsta S-1) in optične podatke (optična časovna vrsta S-2) izvedemo postopek klasifikacije s strojnimi učenjem. Rezultate klasifikacije povežemo z identifikacijskim atributom poligona in rezultate kartiramo glede na prispevek vključenih klasifikacij (potrjevanje). Rezultat zapišemo v vektorski sloj, ki vsebuje tri kategorije: intenzivni travniki, ekstenzivni travniki in nedoločljivo. Postopek je primeren za letno kartiranje intenzivnih in ekstenzivnih travišč.



Slika 74: Postopek kombinirane obdelave podatkov Sentinel-1 in Sentinel-2 za namen ločevanja intenzivnih in ekstenzivnih travišč.

7 Razčlenjena finančna ocena naslednje izvedbe

Preglednica 21 podaja oceno finančne vrednosti izvedbe letnega kartiranja travnišč s poudarkom na ločevanju na intenzivne in ekstenzivne travnike s satelitskimi podatki Sentinel-1 in Sentinel-2. V ceno za letno posodobitev karte travnišč je vključena obdelava podatkov in izvedba kartiranja. Stroški podatkov niso zajeti, saj za podatke Sentinel-1 in Sentinel-2 velja politika proste dostopnosti in so brezplačni. Enako velja za učne podatke, s katerimi ponudnik že razpolaga, in obnovo postopka na obstoječih učnih podatkih. V primeru pridobivanja in izboljšave učnih podatkov se skupna ocena stroškov lahko poveča.

Preglednica 21: Izračun stroškov ponovne izvedbe kartiranja.

	cena v € brez DDV
Pridobivanje, predobdelava in shranjevanje podatkov daljinskega zaznavanja	3000
Izvedba kartiranja travnišč s strojnim učenjem in validacija rezultatov	7000
Priprava izročkov	800
Ponovna izvedba kartiranja (SKUPAJ)	10 800 €

8 Zaključki

V študiji smo testirali prosto dostopne satelitske posnetke Sentinel-1 in Sentinel-2, v prostorski ločljivosti 10 m, za razvrščanje travišč glede na intenzivno ali ekstenzivno rabo. S postopkom delno nadzorovane klasifikacije s strojnim učenjem na poligonih travnikov smo izdelali karte travišč za leta 2017, 2018 in 2019. Vsebujejo tri razrede: ciljna razreda intenzivni travniki in ekstenzivni travniki ter razred nedoločeno. Razred nedoločeno vsebuje zemljišča, ki jih model klasifikacije ni zmozel razvrstiti v nobenega od dveh ciljnih razredov. Takšnih površin je 3 % (od vseh opazovanih trajnih travnikov), nanašajo pa se na zemljišča, ki so premajhna za zanesljivo opazovanje s posnetki Sentinel (ozke parcele, majhna zemljišča). Zaradi izpada premajhnih in preozkih parcel smo na ožjem območju Dravinjske doline izdelali dodatno rastrsko analizo, kjer je bila najmanjša enota kartiranja ena rastrska celica (v velikosti 10 m²). Metoda se je izkazala za zelo učinkovito, sploh za kartiranje manjših travniških enot, kot so dejansko v uporabi. Najbolj zanesljive klasifikacije na nivoju države smo dosegli s kombinacijo optičnih in radarskih posnetkov, kar potrjujejo najmanjša odstopanja natančnosti. Ocenjujemo, da je predlagan postopek kartiranja primeren za primerjalno (med)letno kartiranje travišč, predvideli pa smo tudi nekatere izboljšave, s katerimi bi lahko dosegli boljšo točnost ločevanja travišč.

V študiji smo predpostavili, da je za ločevanje intenzivnih in ekstenzivnih travišč pomemben podatek o prvi košnji in številu košenj v rastni sezoni. Te informacije smo skušali pridobiti tako iz optičnih kot radarskih časovnih vrst satelitskih posnetkov. Pokazalo se je, da oba senzorja zaznavata značilne spremembe, ki jih lahko povežemo s košnjami, vendar imajo oboji podatki omejitve. Pri optičnih podatkih lahko izgubimo podatke zaradi neveljavnih vrednosti (najpogosteje oblaki), pogosto ravno v ključnem obdobju, ki najbolj razlikuje oba tipa travišč, to je na začetku rastne sezone (april – maj). V takšnem primeru informacij o prvi košnji ne moremo pridobiti. Pri radarskih podatkih do izgube podatkov ne prihaja, ker niso vremensko odvisni, so pa veliko bolj kompleksni za interpretacijo. Na informativne vrednosti namreč vpliva tudi geometrija opazovanja radarskega senzorja glede na usmerjenost posameznega travnika, kar dodatno zaplete proučevanje košenj na območju opazovanja (celotna Slovenija). V nalogi smo pripravili samostojen postopek, ki vključuje tako zaznavo prve košnje kot nadaljnjih. Razpoznavna datuma prve košnje je informativna, medtem ko pri razpoznavi vseh košenj dobimo precenjene rezultate.

Pri testiranju zmožnosti ločevanja travišč na intenzivne in ekstenzivne travnike smo lahko potrdili, da je regionalizacija območij pomembna. Vse kombinacije časovnih vrst, na katerih smo izvedli klasifikacijo, so pokazale na značilne razlike med območji rajonizacije rabe v okviru operacije HAB. Pokazali smo tudi, da imajo največji vpliv na ločevanje travnikov časovne vrednosti zgodnjih datumov (april-maj), usmerjenost površja, regionalizacija in naklon. Vključitev naravnogeografskih značilnosti (dodatni atributi časovnih vrst) se je v klasifikaciji s strojnim učenjem izkazala za relevantno izbiro tako pri radarskih kot optičnih vhodnih podatkih.

Izredno pomembna je vključitev vseh podatkov daljinskega zaznavanja, torej podatkov satelitov S-1 in S-2. Ne glede na rezultate ocene strojnega učenja, ki se med posameznimi vhodnimi kombinacijami podatkov značilno ne razlikujejo, se je pokazalo, da je združena časovna vrsta iz podatkov S-1 koherence (padajoča in dvigajoča tirnica) in S-2 NDVI najboljša. Tak pristop namreč daje najbolj stabilne rezultate, ki so med leti tudi najbolj primerljivi. Pokazali smo, da je najznačilnejša razlika med intenzivnimi in ekstenzivnimi travišči v začetku rastne sezone, vendar se je pri klasifikaciji s strojnim učenjem izkazalo, da je zelo pomembno v učenje vključiti celo rastno sezono, saj se model na njej največ nauči.

Medletna odstopanja natančnosti klasifikacije, tako na učnih, kot na testnih podatkih, kažejo, da se rezultati ločevanja intenzivnih in ekstenzivnih travnikov med posameznimi leti v celoti ne ujemajo.

Študija je tudi pokazala, da terenskih popisov traviščnih habitatnih tipov (kartiranja HT ZRSVN) ne moremo neposredno uporabiti kot učne podatke v predlaganem postopku kartiranja, zelo pomembni pa so za izračun natančnosti kartiranja in preverjanje točnosti rezultatov, torej kot testni podatki. Za strojno učenje so podatki kartiranja HT zajeti preredko in kar se razporeditve tiče neenakomerno, na izbranih lokacijah. Tudi interpretacije Physis kod ni bilo mogoče ustrezno povezati z interpretacijo (beleženjem) na satelitskih podatkih. Ocenjujemo, da bi bilo kartiranja HT mogoče prilagoditi za opazovanje s sateliti Sentinel že z izbiro in opisom večjih travnikov in enakomernejšem pridobivanjem vzorcev (tudi za intenzivne travnike) po celotnem območju države.

Strojno učenje deluje tako dobro, kot so dobri učni vzorci. V študiji smo pripravili učne vzorce, ki smo jih določili z upoštevanjem napovedi klasifikacije in opazovanjem posnetkov. Učne vzorce smo močno prečistili (so travniki), jih uravnotežili (razmerje med intenzivnimi in ekstenzivnimi primeri) ter poskrbeli za enakomernejšo zastopanost po vseh območjih rajonizacije HAB. Še vedno pa ni dovolj podatkov na nekaterih območjih rajonizacije HAB, kar se kaže v slabši kakovosti klasifikacije, še sploh kadar so tudi časovne vrste satelitskih podatkov okrnjene.

Tehnične zahteve za izvedbo kartiranja:

- Zelo velika količina vhodnih podatkov zahteva prilagojeno obdelavo in uporabo zmogljivih pomnilniških rešitev (diskov), kot tudi hiter dostop do repozitorija podatkov.
- Začetna priprava satelitskih podatkov in časovnih vrst je dolgotrajen postopek, z utečenim protokolom in sprotno obdelavo podatkov daljinskega zaznavanja znatno zmanjšamo čas priprave podatkov za kartiranje.
- Povezava zbirk podatkov in pridruževanje dodatnih atributov osnovni zbirki (časovni vrsti poligonov travnikov) je pomembna in zato skrbno premišljena in rešena naloga, ki v postopku teče samodejno.
- Kakovosti referenčni oziroma učni podatki. Dobri učni podatki za strojno učenje morajo izpolnjevati določene zahteve: enakomerna razporeditev po območju, zadostna številčnost, ustrezno pokrivanje ciljnih razredov klasifikacije, reprezentativen nabor primerov.
- Učenje je najzahtevnejša faza v klasifikaciji s strojnim učenjem, ki terja največ časa (tudi več dni), sama klasifikacija je nato razmeroma kratek postopek.
- Če želimo nepristransko ugotavljati stanja travišč med dvema ali več leti, je ključno, da so vhodni podatki za obe obdobji primerljivi (razpoložljivi, enakomerno in dovolj goste časovne vrste optičnih posnetkov).
- Dosežena stopnja podrobnosti rezultatov postopka klasifikacije je povezana s prostorsko ločljivostjo uporabljenih podatkov daljinskega zaznavanja.

Možne izboljšave in optimizacija postopka:

- Kartiranje travišč na ravni države pomeni obdelavo več kot 621 000 poligonov. Poleg paralelnega računanja je treba zagotoviti najhitrejšo in najbolj zmogljivo strojno opremo.
- Količina daljinsko zaznanih podatkov je ogromna (v našem primeru 13,5 TB). Pohitritev priprave podatkov daljinskega zaznavanja (časovnih vrst satelitskih podatkov) je možna s prenosom računanja v oblaku in neposrednim dostopom do repozitorijev podatkov.
- Boljše rezultate bi lahko pridobili z boljšim učnim vzorcem travišč. Učni vzorec mora biti zanesljiv, priporočljivo je tudi, da je reprezentativen in zajema celotno tipologijo travišč (tudi glede na značilna kmetijska opravila), predvsem pa morajo biti primeri čim bolj enakomerno razporejeni po celotnem območju opazovanja (zastopana vsa območja rajonizacije HAB).
- Podatki optičnega satelita S-2 omogočajo različne kombinacije spektralnih kanalov, s katerimi bi lahko poudarili razlike, pomembne za razlikovanje travnikov. Predpostavljamo, da bi

natančnost kartiranja lahko izboljšali z vpeljavo indeksa S2REP, ki je za izbrane naloge opazovanja kmetijskih površin precej obetaven, saj poudarja vsebnost klorofila in je lahko indikator gnojenja.

Časovne vrste satelitskih podatkov jasno kažejo razliko med intenzivnimi in ekstenzivnimi travniki. Postopek obdelave je zastavljen in kartiranje travnikov lahko ponovimo vsako leto. Ocenjujemo, da kartiranje lahko izvedemo za katero koli leto v dveh mesecih (večino časa je potrebno za predobdelavo in pripravo podatkov), z obdelavo v oblaku ta čas lahko skrajšamo na en mesec.

Ocenjujemo, da smo z opravljeno študijo uporabnosti daljinsko zaznanih podatkov za spremljanje travišč dosegli pomembna spoznanja in znanja, s katerimi lahko predlagani postopek v nadaljnjih korakih razvijemo do operativne rabe. Spoznali smo, kako je treba optimalno pripraviti satelitske podatke in kakšen mora biti učni vzorec za strojno učenje. Protokol postopka priprave podatkov je določen in poteka samodejno, prav tako povezljivost različnih vhodnih setov podatkov (časovnih vrst optičnih in/ali radarskih satelitskih podatkov) s poligoni travnikov in modelom strojne klasifikacije. Okolje, ki smo ga vzpostavili za letna kartiranja travišč, je stabilno, a hkrati prilagodljivo za spremembe, izboljšave ali nova testiranja.

Rezultati kartiranja so naročniku na voljo na povezavi:

<https://oblak.fgg.uni-lj.si/s/AkCq7bcpisPk7rM>

Geslo: zrsvn2020

9 Viri in reference

- Čož, Nejc; Pehani, Peter; Veljanovski, Tatjana; Kokalj, Žiga, 2020. Testing of the compositing algorithm for Sentinel-2 products : technical report. Ljubljana: ZRC SAZU.
- Izvedena kartiranja habitatnih tipov. <https://zrsvn-varstvonarave.si/informacije-za-uporabnike/katalog-informacij-javnega-znacaja/habitatni-tipi/izvedena-kartiranja-habitatnih-tipov/>
- Kmetijsko-okoljska-podnebna plačila 2015-2020, 2019. Predhodno usposabljanje 2019. https://www.program-podezelja.si/images/SPLETNA_STRAN_PRP_NOVA/Napovednik/2019/Predhodno_usposabljanje_KOP_OP_2019/Brosura_KOPOP_6_izdaja_PU_2019_kon.pdf
- Kolečka, Natalia; Ginzler, Christian; Pazur, Robert; Price, Bronwyn; Verburg, Peter, 2018. Regional Scale Mapping of Grassland Mowing Frequency with Sentinel-2 Time Series. Remote Sensing 10 (8), 1221. DOI: 10.3390/rs10081221.
- Life to Grassland, <https://www.lifetograsslands.si/o-projektu/dodatne-informacije/o-traviscih/>
- Ministrstvo za kmetijstvo, gozdarstvo in prehrano, 2013. Interpretacijski ključ. Podroben opis metodologije zajema dejanske rabe kmetijskih in gozdnih zemljišč. http://rkg.gov.si/GERK/documents/RABA_IntKljuc_20131009.pdf
- Orange, <https://orange.biolab.si/>
- Oštir, Krištof; Čotar, Klemen; Marsetič, Aleš; Pehani, Peter; Perše, Matej; Zakšek, Klemen; Zaletelj, Janez; Rodič, Tomaž, 2015. Automatic near-real-time image processing chain for very high resolution optical satellite data. V: Schreier, G. (ur.), Skrovseth, P. E. (ur.), Staudenrausch, H. (ur.). 36th International Symposium on Remote Sensing of Environment, 11-15 May 2015, Berlin, Germany, ISPRS Archives, ISSN 2194-9034, vol. XL-7/W3 (2015). [Hannover: International Society for Photogrammetry and Remote Sensing]. 2015, str. 669-676, ilustr. <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XL-7-W3/669/2015/isprsarchives-XL-7-W3-669-2015.html>
- Pehani, Peter; Čož, Nejc; Veljanovski, Tatjana; Kokalj, Žiga; Lisec, Anka; Oštir, Krištof, 2020. Automatic processing of Sentinel-1 sigma and coherence. Tehnično poročilo, 25 str.
- Rajonizacija paše/košnje v okviru operacije HAB. 2016. Interni vir poslan s strani naročnika (ZRSVN).
- Sen4CAP, 2020. Use Case implementation - Crop Diversification. Quick user guide. http://esa-sen4cap.org/sites/default/files/Sen4CAP_UserGuide_CropDiversification_V1.2.pdf
- Škornik, Sonja; Ivajnšič, Danijel; Špur, Natalija; Otopal, Josip; Bakan, Branko; Paušič, Igor (2016): Popisi začetnega stanja ciljnih habitatnih tipov ter spremljanje vplivov projektnih aktivnosti na stanje ciljnih habitatnih tipov na projektnih pod-območjih Haloze, Pohorje, Kum, Gorjanci- Radoha za izvedbo projekta z naslovom: ohranjanje in upravljanje suhih travnišč v vzhodni Sloveniji, LIFE TO GRASSLANDS, LIFE Narava in biodiverziteta, LIFE14 NAT/SI/000005. Poročilo o popisu začetnega stanja ciljnih habitatnih tipov.
- Tipologija HT, 2013. https://zrsvn-varstvonarave.si/wp-content/uploads/2019/07/Tipologija_HT_2013.xls.

10 Priloge

Priloga 1: Ločevanje intenzivnih in ekstenzivnih travnišč po kodi Physis

Ekstenzivni travniki:

- 34.1 Srednjeevropska pionirska travnišča
 - 34.11 Evrosibirska pionirska travnišča peščenih in kamnitih tal
- 34.2 Travišča na s težkimi kovinami bogatih tleh
- 34.3 Evrosibirska suha in polsuha sekundarna travnišča, pretežno na karbonatih
 - 34.32 Srednjeevropska suha in polsuha travnišča s prevladujočo pokončno stoklaso
- 34.7 Submediteranska in mediteransko-montanska suha in polsuha travnišča
 - 34.75 Vzhodnosubmediteranska (submediteransko-ilirska) suha in polsuha travnišča
 - 34.752 Submediteransko-ilirski pašniki in suhi kamniti travniki
 - 34.7521 Submediteransko-ilirski pašniki in suhi kamniti travniki z nizkim šašem in skalnim glavnem
 - 34.7521-S1 Submediteransko-ilirski pašniki in suhi kamniti travniki Visokega krasa z nizkim šašem in skalnim glavnem
 - 34.7521-S2 Submediteransko-ilirski pašniki in suhi kamniti travniki kraških planot Nizkega krasa z nizkim šašem in skalnim glavnem
 - 34.7523 Submediteransko-ilirska kamnita travnišča s celovenčno košeničico in ostnatim šašem
 - 34.753 Submediteransko-ilirski polsuhi travniki
 - 34.7531 Submediteransko-ilirski polsuhi ekstenzivni travniki
 - 34.7531-S1 Submediteransko-ilirski polsuhi ekstenzivni travniki na flišu
 - 34.7531-S2 Submediteransko-ilirski polsuhi ekstenzivni travniki primorskega krasa
- 35 Suha travnišča na kislih tleh
- 35.1 Suha volkovja in podobna kisl travnišča pod gozdno mejo
 - 35.11 Mezofilna do kserofilna volkovja pod gozdno mejo
 - 35.12 Kisl travnišča s šopuljami in bilnicami
 - 35.14 Sestoji navadne šašulice
- 35.2 Srednjeevropska travnišča z nesklenjeno rušo na nekarbonatnih kamninah
 - 35.21 Pionirske pritlikave enoletne združbe na nekarbonatnih kamninah
- 36 Alpiska in subalpiska travnišča
- 36.1 Združbe snežnih tal ali vegetacija snežnih kotanjic
 - 36.11 Vegetacija snežnih dolinic na kisl tleh
 - 36.111 Alpske snežne dolinice z mahovi
 - 36.112 Alpske snežne dolinice z zelnato vrbo
 - 36.12 Subalpinske bazilne združbe snežnih tal
 - 36.121 Alpska zelnata vegetacija snežnih tal na karbonatni podlagi
 - 36.122 Subalpinski sestoji pritlikavih vrb snežnih tal na karbonatni podlagi
- 36.3 Alpiska in subalpiska travnišča na kisl podlagi
 - 36.31
 - 36.34
- 36.4 Alpiska in subalpiska travnišča na karbonatni podlagi
 - 36.41 Alpiska in subalpiska mezofilna in zmerno suha travnišča
 - 36.412 Alpiska in subalpiska mezofilna travnišča
 - 36.413 Alpiska in subalpiska zmerno suha travnišča
 - 36.417 Dinarsko-mezijska subalpiska oligotrofna travnišča na karbonatni podlagi
 - 36.42 Vetrovne trate z elino
 - 36.43 Subalpisko-alpiska travnišča z nesklenjeno rušo
 - 36.433 Alpska in Dinarska blazinasta travnišča s čvrstim šašem
 - 36.4331 Alpska blazinasta travnišča s čvrstim šašem
 - 36.4334 Dinarska blazinasta travnišča s čvrstim šašem
- 36.5 Subalpiska in alpiska gnojena travnišča
 - 36.51 Subalpinski gojeni travniki z zlatim ovsencem
 - 36.52 Subalpinski, s hranili bogati pašniki
- 37.2 Mokrotni mezotrofni in evtrofni travniki ali pašniki
 - 37.21 Mezotrofni mokrotni travniki
 - 37.211 Mehko osatovje
 - 37.212 Potočno osatovje
 - 37.219 Gozdno sitčevje
 - 37.24 Evtrofni poplavni travniki in vlažni pašniki


	37.241	Evtrofni pašniki z visokimi ločki
	37.242	Evtrofni poplavni travniki
37.26		Vlažni travniki z rušnato masnico
37.3		Oligotrofni mokrotni travniki
	37.31	Oligotrofni mokrotni travniki z modro stožko in sorodne združbe
	37.311	Mokrotni travniki z modro stožko
	37.3111	Srednjeevropski travniki z modro stožko
	37.3116-S1	Ilirski travniki z modro stožko
	37.312	Travniki modre stožke na kislih tleh
	37.3124	Travniki modre stožke in ločkov
	37.313	Mezofilni do vlažni travniki s trstikasto stožko
	37.313-S1	Vlažni travniki s trstikasto stožko
	37.313-S2	Mezofilni travniki s trstikasto stožko
38.2		Mezotrofni do evtrofni gojeni travniki
	38.22	Srednjeevropski mezotrofni do evtrofni nižinski travniki
	38.221	Srednjeevropski kseromezofilni nižinski travniki na razmeroma suhih tleh in nagnjenih legah s prevladujočo visoko pahovko
	38.222	Srednjeevropski mezofilni travniki na srednje vlažnih tleh s prevladujočo visoko pahovko ali lisičjim repom
	38.2221-S1	Srednjeevropski mezofilni travniki na srednje vlažnih tleh s prevladujočo visoko pahovko
	38.2222-S1	Srednjeevropski mezotrofni vlažni travniki s travniškim lisičjim repom

Intenzivni travniki:


38.1	Mezofilni pašniki
38.11	Intenzivni mezofilni pašniki
38.13	Ruderalizirani opuščeni pašniki38.11
81	Intenzivno gojeni in sejani travniki
81.1	Zmerno suhi intenzivno gojeni travniki
81.2	Vlažni intenzivno gojeni travniki

Poleg zgoraj navedenih habitatnih tipov se v naravi pojavljajo prepleti dveh ali več habitatnih tipov (križanci), ki jih ni mogoče ločiti. Med samimi tipi travnikov ali z različnimi grmišči (Physis 31.8 in podrejeni), steblikovji, ipd., ki jih je prav tako treba upoštevati. Križani habitatni tipi se v atributni tabeli označijo s povezanimi kodami z znakom »x« zapisanim kot mala tiskana črka in brez presledkov na vsaki strani veznega znaka.


Priloga 2: Kartiranje traviščnih habitatnih tipov z daljinskim zaznavanjem 2017




Priloga 3: Kartiranje traviščnih habitatnih tipov z daljinskim zaznavanjem 2018




Priloga 4: Kartiranje traviščnih habitatnih tipov z daljinskim zaznavanjem 2019




Priloga 5: Območja ujemanja kartiranih intenzivnih in ekstenzivnih travnikov med vsemi opazovanimi leti 2017-2019



Priloga 6: Detekcija datuma 1. košnje travnikov s podatki Sentinel-1 2017



Priloga 7: Detekcija datuma 1. košnje travnikov s podatki Sentinel-1 2018



Priloga 8: Detekcija datuma 1. košnje travnikov s podatki Sentinel-1 2019

