ZBORNIK RADOVA

GEODEZIJA I VODE

BLUE SURVEYING

15. SIMPOZIJ OVLAŠTENIH INŽENJERA GEODEZIJE

15th Symposium of
Chartered Geodetic Engineers

OPATIJA, 12. -15. 10. 2022.

Hrvatska komora ovlaštenih inženjera geodezije
Croatian Chamber of Chartered Geodetic Engineers

u suradnji s

The Council of European Geodetic Surveyors
Comité de Liaison des Géomètres Européens

EuroSDR

Hrvatska komora ovlaštenih inženjera geodezije

OPATIJA,
12. - 15. listopada 2022.

GEODEZIJA I VODE
BLUE SURVEYING

15. simpozij ovlaštenih inženjera geodezije

ZBORNIK RADOVA

U suradnji s Council of European Geodetic Surveyors i EuroSDR

IMPRESUM

Naslov

Geodezija i vode, Zbornik radova 15. simpozija ovlaštenih inženjera geodezije

Izdavač

Hrvatska komora ovlaštenih inženjera geodezije

Za izdavača

Adam Agotić, dipl. ing. geod.
predsjednik Hrvatske komore ovlaštenih inženjera geodezije

Glavna urednica

prof. dr. sc. Ivana Racetin, dipl. ing. geod.

Urednici

prof. dr. sc. Mladen Zrinjski, dipl. ing. geod.
prof. dr. sc. Robert Župan, dipl. ing. geod.

Tehnička urednica

Klaudija Barić, bacc. admin. publ.

Oblikovanje i priprema

Grafomark, Zagreb, rujan 2022.

ISBN 978-953-49258-2-9

CIP zapis je dostupan u računalnome katalogu Nacionalne i sveučilišne knjižnice u Zagrebu pod brojem 001147960.

Copyright © Hrvatska komora ovlaštenih inženjera geodezije, 2022.

ORGANIZACIJSKI ODBOR

Predsjednica:

dr. sc. **Blaženka Mičević**, dipl. ing. geod.

Članovi:

Adam Agotić, dipl. ing. geod.

Adrijan Jadro, dipl. ing. geod.

Marko Mlinarić, dipl. ing. geod.

Marko Pilić, dipl. ing. geod.

Nataša Kapov Kostovski, dipl. ing. geod.

ZNANSTVENO-STRUČNI ODBOR

Predsjednica:

prof. dr. sc. **Ivana Racetin**
Sveučilište u Splitu, Fakultet građevinarstva, arhitekture i geodezije, Hrvatska

Članovi:

prof. dr. ir. **Joep (Johan) Crompvoets**
KU Leuven, Instituut voor de Overheid, Belgija

prof. **Zlatko Srbinoski**, PhD
Univerzitet "Sv. Kiril i Metodij", Gradežen fakultet, Sjeverna Makedonija

izr. prof. dr. sc. **Anka Lisec**
Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Slovenija

prof. Dr.-Ing. **Liqiu Meng**
Technische Universität München, Fakultät für Luftfahrt, Raumfahrt und Geodäsie, Njemačka

prof. dr. sc. **Željko Bačić**
Sveučilište u Zagrebu, Geodetski fakultet, Hrvatska

prof. dr. sc. **Mladen Zrinjski**
Sveučilište u Zagrebu, Geodetski fakultet, Hrvatska

prof. dr. sc. **Robert Župan**
Sveučilište u Zagrebu, Geodetski fakultet, Hrvatska

doc. dr. sc. **Danijel Šugar**
Sveučilište u Zagrebu, Geodetski fakultet, Hrvatska

prof. dr. sc. **Vlado Cetl**
Sveučilište Sjever, Odjel za geodeziju i geomatiku, Hrvatska

dr. sc. **Olga Bjelotomić Oršulić**
IGEA d.o.o., Varaždin, Hrvatska

UVODNIK

predsjednika Hrvatske komore ovlaštenih inženjera geodezije



Poštovane i drage kolegice i kolege,

tema ovogodišnjeg Simpozija „Geodezija i vode“ odnosno „Blue Surveying“ odnosi se na geodetska mjerenja i upravljanje geoprostornim podacima u svim vodenim okruženjima, od dubokih oceana do obalnih voda, jezera, rijeka i kanala. „Blue Surveying“ podržava aktivnosti održivog razvoja, na primjer upravljanje vodama potrebno za isporuku pitke vode, dezinfekciju otpadnih voda i navodnjavanje usjeva. Također podržava globalnu trgovinu, navigaciju, energiju i aktivnosti u slobodno vrijeme. Stoga je jasno zašto je Komora odlučila da ovogodišnja tema godine Europskog vijeća geodeta (CLGE) ujedno bude i tema našeg Simpozija.

Jedna od značajnijih novosti ovogodišnjeg Simpozija je da će isti, osim sad već uobičajenog sudjelovanja gostiju i predavača iz inozemstva, biti otvoren i za prisustvovanje sudionika iz inozemstva i priznat u okvirima stručnog usavršavanja njihovih nacionalnih organizacija, te želim zahvaliti predsjedniku CLGE-a g. Vladimiru Krupi i našim delegatima u CLGE-u gđi. Blaženki Mičević i g. Borni Gradečaku koji su svojim angažmanom to omogućili.

Simpozij će obuhvatiti i druge aktualne teme u našoj struci kao što je to običaj svake godine. Tako će se, osim evidentiranja javnog pomorskog i vodnog dobra, povesti panel diskusija i o nedavno uvedenoj zabrani dioba katastarskih čestica poljoprivrednog zemljišta, o razlozima i mogućim posljedicama.

Nakon dvije godine neizvjesnosti uzrokovane pandemijom koronavirusa, pred nama je još izazovnije razdoblje. Uz već poslovično stabilnu nestabilnost pri donošenju propisa i njihove primjene u struci, galopirajuće stope inflacije uz dramatični porast cijena energenata ne mogu nikoga ostaviti ravnodušnim. Stoga će i tema jednog od panela ovogodišnjeg Simpozija biti upravo izazovi koje našoj struci donosi inflacija.

Ohrabrujuća okolnost je što se geodetska struka i do sada često susretala sa izazovima različitih epicentara, pa je ipak u svemu tome uvijek pokazivala otpornost i sposobnost za prilagoditi se. Tako je za nadati se da ćemo dogodine i o svemu ovome pričati kao o nečemu što smo uspješno prebrodili.

Želim se zahvaliti Organizacijskom i Znanstveno-stručnom odboru Simpozija, pokroviteljima, pozvanim predavačima, gostima iz Hrvatske i inozemstva, autorima radova, sudionicima i moderatorima panela, recenzentima članaka, voditeljima sesija, sponzorima i izlagačima kao i svima onima koji su doprinijeli organizaciji ovog Simpozija.

Posebno se zahvaljujem svim sudionicima ovogodišnjeg Simpozija, radi kojih se simpoziji i održavaju svake godine.

Želim Vam dobrodošlicu na 15. SIMPOZIJ OVLAŠTENIH INŽENJERA GEODEZIJE i lijep i veseo boravak u Opatiji!

Predsjednik Hrvatske komore
ovlaštenih inženjera geodezije
Adam Agotić, dipl. ing. geod.

UVODNIK

predsjednice Znanstveno-stručnog odbora 15. simpozija ovlaštenih inženjera geodezije



Poštovane kolegice, cijenjeni kolege,

jubilarni 15. simpozij ovlaštenih inženjera geodezije održava se u ozračju glavne teme „Geodezija i vode“ (engl. „Blue Surveying“). Geodeti i geoinformatičari najveći dio svojih poslova obavljaju na kopnu. Stoga smo ove godine željeli preusmjeriti pogled naših stručnjaka na vode, kako kopnene tako i morske, s ciljem proširivanja i preusmjeravanja naše djelatnosti na nova područja djelovanja, a sve u okviru ozračja održivog razvoja. Zemljinu površinu, kao predmet istraživanja geodetsko-geoinformatičke struke, čini preko 70% površine pod vodom, a tek manje od 30% površine kopna. Unatoč tome u postotku najveći dio naše struke bavi se radovima na kopnu. „Plava ekonomija“ i „Plavi rast“ su pojmovi u uporabi već duži niz godina, a kojima se pokušava preusmjeriti, odnosno proširiti niz ljudskih aktivnosti s kopna na vode. Ekonomski rast u okviru održivog (zelenog) razvoja jedan je od ciljeva, kako Europske unije, tako i Ujedinjenih naroda. Budući da za taj rast ne postoje značajne mogućnosti na kopnu logično je usmjeriti ljudske aktivnosti na slane i slatke vode. Problem tehničkih struka, pa tako i geodetsko-geoinformatičke struke, jeste njihova nedovoljna zastupljenost na vodama. Uzmemo li za primjer prostorno planiranje na moru uvidjet ćemo da su prirodne, pa i društvene struke daleko uznapredovale na tom području, a da tehničke struke, kao ishodište društvenog razvitka u mnogome zaostaju u razvijanju tog područja. Rijeke i jezera mogli bi imati znatno veću uporabnu vrijednost ukoliko bi se pridodalo više pažnje njihovu evidentiranju. „Geodezija i vode“ je tema čija budućnost tek dolazi. Mali, ali značajan korak na tom putu čini i Simpozij pred vama.

Kako ćete vidjeti iz radova u Zborniku 15. simpozija ovlaštenih inženjera geodezije pristigao nam je veliki broj radova, njih ukupno 30, od kojih više od polovice, njih 18, fokus stavlja na kopnene i morske vode. Kao podtemu simpozija odabrali smo Suvremene tehnologije. Na podtemu je dospjelo 12 radova za koje vjerujem da će vam biti korisne i zanimljive. Zahvaljujući suvremenim tehnologijama i ove godine, kao i prošle, Simpozij će se održati u mješovitom obliku, uživo i putem digitalnih komunikacijskih sredstava. Novina 15. jubilarnog simpozija jeste da će biti simultano preveden s hrvatskog na engleski jezik i obrnuto i da će biti omogućeno njegovo slušanje i aktivno sudjelovanje i dionicima iz inozemstva, čime Simpozij dobiva cjelovit međunarodni karakter.

Zahvaljujem se ovim putem, prvenstveno čelništvu Hrvatske komore ovlaštenih inženjera geodezije i Organizacijskom odboru Simpozija na izvrsnoj suradnji. Povećali smo i broj domaćih i međunarodnih članova Znanstveno-stručnog odbora. Zahvaljujem im na aktivnom sudjelovanju i pozitivnom ozračju suradnje. Zahvaljujem i recenzentima, pozvanim predavačima te autorima radova i naposljetku vama, sudionicima skupa, bez kojih ne bismo mogli uspješno organizirati ovogodišnji Simpozij. Vjerujem da ćemo unutar nekoliko dana trajanja 15. simpozija ovlaštenih inženjera geodezije dobiti odgovore na mnoga otvorena pitanja na temu „Geodezija i vode“, te dobiti mnoštvo novih informacija o tehnologijama današnjice primjenjivih u našoj struci. Želim vam uspješan rad 15. simpozija.

Predsjednica Znanstveno-stručnog odbora
15. simpozija ovlaštenih inženjera geodezije
prof. dr. sc. Ivana Racetin, dipl. ing. geod.

SADRŽAJ

SESIJA 1: Geodezija i kopnene vode

Iva Cibilić, Vesna Poslončec-Petrić
Prikaz jezera Nacionalnog parka Plitvička jezera upotrebom otvorenih podataka i otvorenih alata 11

Zoran Šarić, Ivica Mustač
Uloga geodezije u razvoju sustava upozoravanja od poplava i izradi prognostičkog modela rijeke Mure 19

Mateo Gašparović, Marina Kalaš, Maja Ćuže Denona
Analiza utjecaja klimatskih promjena na Vransko jezero u Dalmaciji 29

Natalija Matić, Nikola Vučić
Promjena u opsegu vodenih ekosustava tijekom vremena 35

Dubravko Gajski, Katarzyna Dzięgielewska-Gajski
Računalne simulacije i analize površinskog tečenja 41

Zlatko Srbinoski, Zlatko Bogdanovski, Filip Kasapovski, Tome Gegovski
Application of GNSS Technology in the Geodetic Auscultation of the High Dams 47

SESIJA 2: Geodezija i more

Andrea Miletić, Karlo Kević, Ana Kuveždić Divjak
Otvoreni podaci u službi održivog upravljanja vodama i morskim okolišem Hrvatske 57

Elenora Kučić
Od jednog snopa do lepeze 63

Ljerka Vrdoljak
Batimetrijska izmjera za potrebe sigurnosti plovidbe 69

Igor Ružić, Dado Jakupović, Andrea Tadić, Vedrana Petrović, Gorana Ljubičić, Nino Krvavica
Analiza obalnog plavljenja uz pomoć trodimenzionalnih oblaka točaka 75

Igor Ružić, Andrea Tadić, Marinko Salopek
Primjena trodimenzionalnih oblaka točaka za monitoring morfoloških promjena plaže 81

Dino Dragun, Matko Raguž, Ivan Žokvić
Analiza metoda hidrografske izmjere u izgradnji vjetroelektrana u moru 87

SESIJA 3: Instrumentarij i tehnologije današnjice

Mladen Zrinjski, Krunoslav Špoljar, Đuro Barković, Antonio Tupek, Sergej Baričević
40 godina kalibracijske baze Geodetskog fakulteta Sveučilišta u Zagrebu 97

Robert Župan, Stanislav Frangeš, Adam Vinković
Određivanje vlažnosti šumskog pokrova i utjecaj na šumske požare 103

Marija Perić, Željko Bačić, Zvonimir Nevistić
Testiranje programskih rješenja za obradu podataka snimljenih dronom pri inspekcijskom snimanju 109

Vlado Cetl, Danko Markovinović, Sanja Šamanović, Milan Rezo
Integracija BIM-a i GIS-a 117

Loris Redovniković, Antun Jakopec, Iva Odak
Mogućnosti primjene jeftinog GNSS senzora za geodetsku izmjeru 125

Josip Peroš, Rinaldo Paar, Ivan Racetin, Boštjan Kovačić
Ispitivanje mogućnosti 20 Hz GNSS PPK mjerenja za određivanje pomaka i vlastitih frekvencija objekata 133

SESIJA 5: Uređenje morskog okoliša

Bojan Linardić, Robert Paj, Margareta Premužić, Ivan Landek
Prostorno planiranje morskih područja i granice na moru 141

Bojan Linardić, Margareta Premužić, Robert Paj, Ivan Landek
Mogućnosti primjene programa Copernicus za potrebe prostornog planiranja Republike Hrvatske 147

Olga Bjelotomić Oršulić, Stjepan Grđan, Marijana Iviček, Boris Fantulin, Nina Perko
Uspostava GIS rješenja i Jedinstvene nacionalne baze podataka pomorskog dobra Republike Hrvatske..... 155

Jelena Kilić Pamuković, Katarina Rogulj, Ivana Racetin, Ljerka Vrdoljak
Prostorno planiranje na moru 161

Katarina Rogulj, Jelena Kilić Pamuković, Ivo Lozić
Analiza trenutnog stanja i potrošnje energije mobilnih usluga jadranskih marina 167

Adam Vinković, Vesna Poslončec-Petrić
Kartografski prikaz hrvatskih otoka 175

SESIJA 6: Suvremeni katastar i prostorno uređenje

Renata Žeželj, Ines Štimac, Filip Pavelić, Stjepan Miletić
Geodetski poslovi u izradi tehničke dokumentacije za Popis stanovništva 2021. godine 183

Petar Delać, Mario Pranjić, Marinko Požega, Josip Šimić
Primjena metoda umjetne inteligencije i strojnog učenja u sređivanju zemljišnih podataka 191

Sanja Vaclavek, Martin Šutalo, Bojan Blažona
Korištenje umjetne inteligencije u raspoznavanju podzemne infrastrukture te primjena pri kreiranju sustava inteligentne infrastrukture..... 197

Jelena Jurišić, Ilija Ćaćić
Virtualni asistenti u zemljišnoj administraciji – mit ili nezaobilazna budućnost? 205

Sebastijan Sekulić, Jed Long, Urška Demšar
Prostorno-vremensko grupiranje tokova kretanja – detekcija promjene korištenja sustava javnih bicikala zbog COVID-19 zatvaranja u Londonu 213

Stjepan Miletić, Monika Friščić
Izazovi geodeta milenijalaca 219

SESIJA 1

Geodezija i kopnene vode

Prikaz jezera Nacionalnog parka Plitvička jezera upotrebom otvorenih podataka i otvorenih alata

Iva Cibilić[1], Vesna Poslončec-Petrić[2]

[1] Geodetski fakultet, Sveučilište u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, icibilic@geof.hr

[2] Geodetski fakultet, Sveučilište u Zagrebu, Kačićeva 26, Zagreb, Hrvatska,

vesna.posloncec-petric@geof.unizg.hr

Sažetak

Danas, u suvremenoj kartografiji vrlo se često koriste alati koji nisu prvenstveno razvijeni za kartografiju, već za su to alati i programi namijenjeni za grafički dizajn i/ili izdavaštvo. Prilagođavanje softvera zahtjevima kartografa ponekad je težak i zahtjevan zadatak. U tom kontekstu, alati otvorenog koda pokazuju svoj puni potencijal za kartografsku upotrebu, a otvorenost podataka i programa dobiva sve više na značaju. Da su podaci i alati otvoreni znači da se mogu slobodno koristiti, modificirati ili redistribuirati, a izrada karata otvorenog koda uključuje kako otvorene tehnologije i programe tako i otvorene podatke. Danas postoji mnoštvo otvorenih alata za obradu prostornih podataka i za njihovu grafičku obradu u procesu izrade kartografskog prikaza. Jedan od najpoznatijih servisa za stvaranje i prikupljanje otvorenih prostornih podataka jest OpenStreetMap, dok je među alatima najpopularniji QGIS. U radu je prikazan postupak izrade otvorenog kartografskog prikaza od prikupljanja prostornih podataka, njihove obrade u QGIS-u i grafičkim uređenjem u Inkscapeu te je pokazano kako se vrlo jednostavno i brzo mogu izraditi atraktivni kartografski prikazi upotrebom otvorenih tehnologija i otvorenih podataka. Otvoreni pristup omogućava potpunu kontrolu nad podacima i alatima te potiče prilagodbu proizvoda potrebama korisnika.

Ključne riječi: *kartografija, OpenStreetMap, otvoreni podaci, Plitvička jezera, QGIS*

1. Uvod

Vizualno atraktivan i sadržajan prikaz Zemljine površine uvijek je poseban izazov kartografima, a u ovom ubrzanom razvoju digitalnih tehnologija raste i ponuda softvera namijenjenih za vizualizaciju fenomena. Njihova konkurentnost na tržištu se povećava, pa tako i s njom i njihova cijena. U mnoštvu dostupnih sadržaja i alata veliku moć imaju oni koji su nastali radom zajednice, tzv. otvorenog koda. Danas je pojam otvorenosti prisutan u raznim fazama izrade kartografskog prikaza, od otvorenih podataka, alata i otvorenih formata. Otvoreni podaci i otvoreni programi zajedno čine cjelinu koja omogućava izradu kvalitetnih kartografskih prikaza.

Unutar kartografske zajednice javljaju se ideje i tehnike koje proširuju vidike tradicionalnih metoda izrade karte i otvaraju novi prostor za efektnu vizualizaciju. Tako je John Nelson u svojem blogu predstavio izradu postera svih jezera Michigan (URL 1) kategoriziranih prema njihovom obliku u tri kategorije: okrugli, duguljasti i vijugavi. Navedeni prikaz izrađen je u programu ArcGIS Pro, međutim pruža uvid u korištenje različitih grafičkih tehnika s ciljem učinkovite vizualizacije objekata. Sličan prikaz vidimo i u popularnom kartografskom blogu Daniela Huffmana: somethingaboutmaps.com (URL 2). Također je izrađen poster na temelju imena jezera u saveznoj državi Kanada, a primjenom izohipsi različitih boja i debljina linija naglašen je oblik samog jezera u odnosu na korištenu kartografsku podlogu. Osim ovog nedavnog trenda, istraživanje je inspirirano i posterom britanskih nacionalnih parkova koji je izradio Joe Harrison iz Ordnance Surveya (URL 3).

Cilj ovog rada jest predstaviti tehniku vizualizacije područja na inovativniji način koristeći samo besplatne i otvorene podatke i alate. Geoinformacijski sustav otvorenog koda QGIS podržava sve faze izrade karte, od obrade podataka do vizualizacije i dizajna karte (URL 4). Završna obrada izvršena je u softveru Inkscape.

1.1. Područje istraživanja

Nacionalni park Plitvička jezera je najstariji, najveći i najposjećeniji nacionalni park u Republici Hrvatskoj (URL 5). Nalazi se na području dvije županije, 91% parka je u Ličko-senjskoj županiji i 9% u Karlovačkoj županiji, a prostire se na gotovo 300 kilometara kvadratnih. Nacionalni park Plitvička jezera sastoji se od 16 imenovanih jezera koji zajedno čine cjelinu povezanu kaskadama i slapovima na sedrenim barijerama (Slika 1). Zbog svoje izvanredne prirodne ljepote od 1979. godine nalazi se na UNESCO popisu svjetske prirodne baštine (URL 5).



Slika 1: Nacionalni park Plitvička jezera (URL 6).

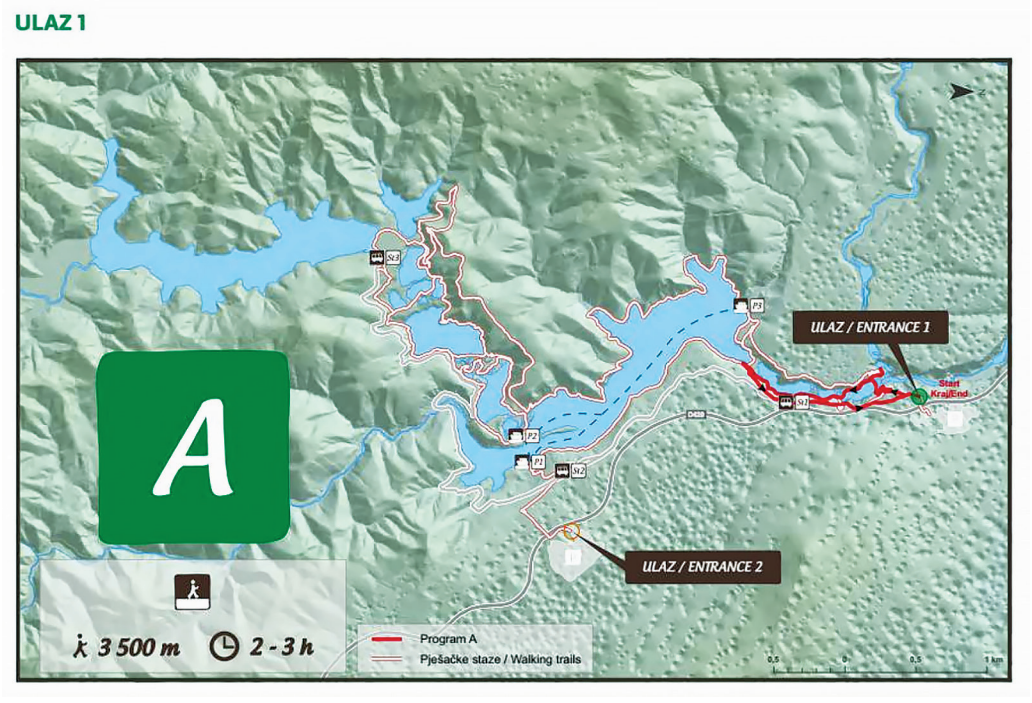
Analiza dostupnih kartografskih prikaza na stranicama Nacionalnog parka Plitvička jezera ukazala je na činjenicu da niti jedan prikaz ne navodi imena svih jezera. Na službenoj brošuri Nacionalnog parka (URL 7) prikazana su jezera s istaknutim turističkim sadržajem, međutim može se primijetiti kako su navedena imena samo dva najveća jezera. Brošura za vodiče (URL 8) sadrži prikaz različitih pješačkih ruta za posjetitelje uz jezera, a imena jezera nisu navedena na niti jednom od njih (Slika 2). Pretraživanjem interneta potvrđeno je da prevladavaju slični kartografski prikazi. Navedeni prikazi upućuju na konzistentne prikaze interesnog područja s naglaskom na turističke sadržaje i snalaženje u samom parku. Međutim, nedostaje prikaz jezera koji su simbol nacionalnog parka. Nacionalni park Plitvička jezera odabran je zbog svoje velike posjećenosti kao idealan teren za primjenu novih metoda kartografskih vizualizacija.

Upravo zbog navedenog, u ovom radu, naglasak je stavljen na prikaz jezera i njihove atribute kao pregledni turistički prikaz.

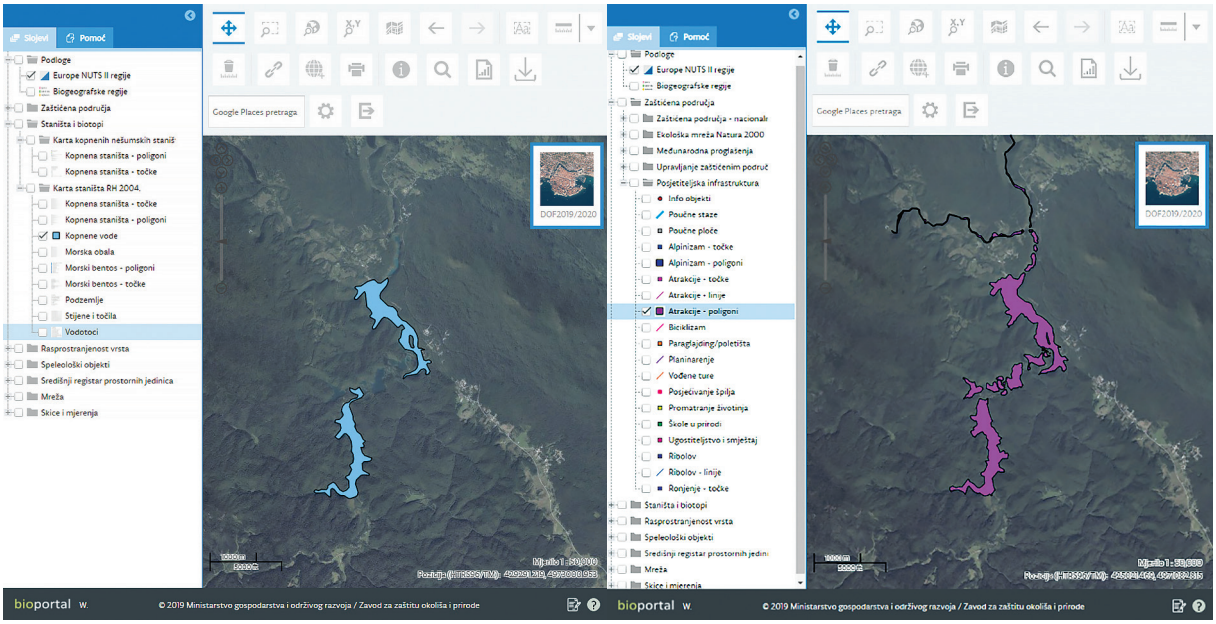
1.2. Korišteni podaci

Otvoreni prostorni podaci su danas vrlo traženi. Razvojem tehnologija i informacijskih sustava raste potreba za podacima dostupnima za analizu, upravljanje i podršku u prostornom upravljanju. Zahtjevi dostupnih skupova podataka rastu, od standardizacije formata, metapodataka i vremenske komponente. Za potrebe izrade prikaza Plitvičkih jezera nekoliko izvora se uzelo u obzir.

Nacionalna infrastruktura prostornih podataka (NIPP) definirana je kao skup tehnologija, mjera, normi, provedbenih pravila, usluga, ljudskih kapaciteta i ostalih čimbenika koji omogućavaju djelotvorno objedinjavanje, upravljanje i održavanje dijeljenja prostornih podataka u svrhu zadovoljenja potreba na nacionalnoj, kao i na europskoj razini, a koji će biti sastavni dio europske infrastrukture prostornih podataka definirane INSPIRE direktivom (URL 9). Geoportal NIPP-a predstavlja ishodišno mjesto za pronalaženje prostornih podataka Republike Hrvatske (URL 10). Svi podaci koji čine NIPP; 35 različitih tema prostornih podataka bi trebali biti dohvatljivi za pronalaženje i pregledavanje putem Geoportala NIPP-a.



Slika 2: Prikaz Plitvičkih jezera u službenoj brošuri bez njihovih naziva (URL 8).



Slika 3: Prostorni podaci Plitvičkih jezera u kategoriji Kopnene vode (lijevo) i Atrakcije (desno)

Pretragom dostupnog sadržaja na Geoportalu nije pronađen odgovarajući skup podataka koji sadrži podatke o Plitvičkim jezerima.

Geoportal Hrvatskih voda (URL 11) je interaktivni web preglednik prostornih podataka. Omogućava interaktivnu prezentaciju i analizu prostornih podataka na karti, podijeljenih u tematske podskupine iz različitih područja djelatnosti Hrvatskih voda. Među mnoštvom slojeva ne nalaze se vektorski slojevi vodenih površina kao takvih.

Bioportal (URL 12) je jedinstvena baza podataka o bio raznolikosti i zaštiti prirode u Hrvatskoj. Sadrži preglednik prostornih podataka odnosno interaktivnu web kartu na kojoj se mogu pregledavati, analizirati i pretraživati sve prostorne podloge Informacijskog sustava zaštite prirode (staništa, vrste, zaštićena područja, ekološka mreža i dr.). Na izradi portala je radio Državni zavod za zaštitu prirode, a financiralo ga je Ministarstvo zaštite okoliša i prirode kroz ''Projekt integracije u EU Natura 2000''. Pretraživanjem portala moguće je pronaći prostorne podatke Plitvičkih jezera u više kategorija, a njihovi prikazi vidljivi su na Slici 3. Može se primijetiti da ova dva skupa podataka predstavljaju isti entitet ali prikazan različitom razinom detalja.

DIVA-GIS (URL 13) je besplatni računalni program za kartiranje i analizu geografskih podataka (engl. Geographic Information System – GIS). Na njihovim stranicama nalaze se besplatni prostorni podaci za cijeli svijet. Skupovi podataka mogu se preuzeti u globalnom opsegu, ili na razini države. Podaci su kategorizirani u šest cjelina: administrativne granice, ceste, željeznice, nadmorska visina, pokrivenost zemlje i gustoća naseljenosti. Podaci za kopnene vodene površine nalaze se u vektorskom formatu Shapefile i zajedno s pratećim datotekama preuzimaju se u komprimiranoj datoteci. Međutim, preuzeti podaci su previše generalizirani i ne predstavljaju dobru podlogu za ciljani prikaz.

OpenStreetMap (OSM) (URL 14) je globalni projekt s ciljem stvaranja besplatne, svima dostupne karte čijem ažuriranju mogu svi doprinijeti. Međutim, najveći doprinos zajednici nije samo u svima dostupnoj karti već u skupu prostornih podataka koji su prikupljeni od strane korisnika korištenjem GNSS uređaja, zračnih ili satelitskih snimki ili jednostavno poznavanjem okoline. OpenStreetMap sadrži otvorene podatke koji su licencirani pod Open Data Commons Open Database License (ODbL) od strane OpenStreetMap Foundation (OSMF). Spomenuta licenca podržava slobodu kopirati, distribuirati, prenositi i prilagođavati podatke, sve dok je naveden OpenStreetMap kao vlasnik podataka. Ako se podaci mijenjaju ili nadograđuju, rezultati se smiju distribuirati samo pod istom licencom.

Podaci OpenStreetMapa za područje Nacionalnog parka Plitvička jezera preuzeti su putem servisa Overpass turbo (URL 15). Kao kriterij pretraživanja i preuzimanja vodenih površina na odabranom području korišten je upit „natural = water“. Na taj način detektiraju se sve prirodne vodene površine. Ovaj način pretraživanja i analize podataka pruža veliku slobodu u odabiru skupa prostornih podataka te omogućava pretraživanje prema bezbroj kriterija. Prostorni podaci se preuzimaju u GeoJSON formatu. Za traženo područje su vrlo sadržajni i detaljni.

Uvidom u navedene izvore slobodnih prostornih podataka i potpunosti njihovih sadržaja najsadržajniji prikaz Plitvičkih jezera pružaju podaci OpenStreetMapa te su oni korišteni za prikaz Plitvičkih jezera.

Za potrebe pozadine korištene su slojnice preuzete iz satelitske snimke. SRTM (engl. Shuttle Radar Topography Mission) je naziv istraživanja koji je producirao digitalni model visina. SRTM se sastojao od posebno modificiranog radarskog sustava koji je letio u veljači 2000. godine (URL 16). Snimka koja pokriva područje istraživanja preuzeta je sa stranice CGIAR CSI (URL 17). SRTM 90 m digitalni visinski model dostupan je

za preuzimanje u dimenzijama 5° x 5° u geografskom koordinatnom sustavu WGS84. Raster je dostupan u formatima ArcInfo ASCII i GeoTiff.

1.3. Softveri korišteni za prikaz jezera Nacionalnog parka Plitvička jezera

Mnogo je alata otvorenog koda koji podržavaju obradu prostornih podataka a svakako jedan od najpopularnijih je QGIS. QGIS je vrlo često korišten za vektorske i rasterske prostorne analize. U ovom radu prikazane su njegove mogućnosti izvoza u uređivač prikaza za ispis i dizajn karte te je u ovom radu korišten kao primarni alat za obradu prostornih podataka.

Kao što je već istaknuto, kartografi u svojem radu koriste i alata namijenjene za grafički dizajn. Takve alate dijelimo s obzirom koji tip podataka modeliraju, odnosno radi li se o rasterskoj ili vektorskoj grafici. Za završno uređivanje izabran je Inkscape kao alat za obradu vektorskog sadržaja.

2. Postupak izrade kartografskog prikaza jezera

Izrada kartografskog prikaza jezera Nacionalnog parka Plitvička jezera započela je učitavanjem GeoJSON datoteke preuzete s OSM-a. Zatim je učitan WFS sloj Bioportala kojem se pristupa putem poveznice: http://services.bioportal.hr/wfs. Prilikom odabira sloja odlučeno je koristiti sloj Zaštićena područja u kojem se nalazi granica nacionalnog parka. Prvo su odabrani slojevi spremljeni u HTRS96/TM projekciji te je izbrisan sadržaj koji je izvan granica NPPJ. Budući sedrene barijere čine mnoštvo malih jezera i prijelaza rijeke, odlučeno je prikazati samo 16 većih jezera. Ona se dijele na Gornja i Donja. Gornja jezera su: Prošćansko jezero, Ciginovac, Okrugljak, Batinovac, Veliko jezero, Malo jezero, Vir, Galovac, Milino jezero, Gradinsko jezero, Veliki Burget i Kozjak. Donja jezera su: Milanovac, Gavanovac, Kaluđerovac i Novakovića Brod. Svakom jezeru dodani su atributi o nazivu, nadmorskoj visini, dubini, površini koju pokrivaju i u koju skupinu spadaju (Tablica 1). Podaci o nadmorskoj visini, dubini i površini svakog jezera pronađeni su u službenoj brošuri Nacionalnog parka (URL 7).

Po uzoru na trendove, jezera su odvojena od podloge korištenjem linija njihovih obrisa. Linije se razlikuju u širini, obliku, boji i udaljenosti od same linije pojedinog jezera (Tablica 2).

Za podlogu je učitan SRTM 90 m DEM s 30° širine. Izrezan je na granice parka i promijenjen mu je koordinatni sustav u HTRS96/TM. Na temelju njega učitane su slojnice ekvidistancije 20 m. Za razliku od linija jezera, slojnice predstavljaju stvarne vrijednosti. Kreirane su naredbom Raster/Extraction/Contour. Kreirane slojnice izvezene su u formatu .png i učitane u Inkscape, gdje su korištene kao podloga u grafičkoj obradi samog prikaza. Izrađeni prikaz nalazi se na Slici 4.

Tablica 1: Atributna tablica jezera.

	Naziv jezera	Nadmorska visina [m]	Dubina jezera [m]	Površina jezera [ha]	Skupina jezera
1.	Novakovića brod	504	5	0,3	Donja jezera
2.	Kaluđerovac	508	14	2	Donja jezera
3.	Gavanovac	518	10	0,9	Donja jezera
4.	Milanovac	524	18	3	Donja jezera
5.	Kozjak	535	48	82	Gornja jezera
6.	Burgeti	544	10	1	Gornja jezera
7.	Gradinsko jezero	554	10	8	Gornja jezera
8.	Milino jezero	564	1	0,1	Gornja jezera
9.	Galovac	583	24	12	Gornja jezera
10.	Vir	598	4	0,6	Gornja jezera
11.	Malo jezero	604	9,5	1	Gornja jezera
12.	Veliko jezero	606	7	2	Gornja jezera
13.	Batinovac	608	5	1	Gornja jezera
14.	Okrugljak	614	13	4	Gornja jezera
15.	Ciginovac	626	11	7	Gornja jezera
16.	Prošćansko jezero	637,2	37	68	Gornja jezera

Tablica 2: Vrijednosti crtanja linija vizualizacije jezera.

Linija	Širina	Oblik	Boja [RGB]	Udaljenost od linije jezera [m]
Izvan jezera	0,2 mm	Puna linija	146, 202, 230	5
Unutar jezera	0,2 mm	Puna linija	224, 241, 248	5
	0,1 mm	Crtice 15 mm, razmak 10 mm	224, 241, 248	10
	0,3 mm	Crtice 5 mm, razmak 20 mm	224, 241, 248	15



Slika 4: Izrađeni kartografski prikaz Plitvičkih jezera.

3. Zaključak

Alati otvorenog koda su jedan od glavnih doprinosa brzom rastu alata za prostornu podršku i grafičku obradu u posljednjem desetljeću. Danas omogućavaju stvaranje kartografskih vizualizacija bez velike razlike u odnosu na plaćeni softver. Sveprisutni su i njihovo korištenje nije ograničeno političkim ni geografskim granicama. Međutim, otvoreni podaci još uvijek nisu dosegli svoj vrhunac rasta. Pregledom nekolicine dostupnih portala lokalne i globalne razine koji sadrže otvorene podatke o vodenim površinama najbolji skup podataka za ovu svrhu pronađen je na OpenStreetMapu. Sadržaj domaćih portala nije potpun ni redovno ažuriran, što svakako treba u skoro vrijeme promijeniti. Manjak određenog podatka ima za posljedicu značajan utjecaj na rezultat prostornih analiza i kvalitetu pružene podrške.

Primjena alata otvorenog koda pruža široku paletu alata i mogućnosti. Autori kartografskih prikaza mogu izraziti svoju slobodu na beskonačno mnogo načina, prilagoditi alat svojim potrebama s ciljem izrade što efektnijih prikaza. Trendovi se danas brzo mijenjaju, a na ovaj način omogućeno je praćenje trenutnih i uspostava novih.

ZAHVALA. Ovaj rad je motiviran istraživanjem u okviru Twinning Open Data Operational – TODO projekta financiranom u okviru Horizon2020 Twinning programa (Grant Agreement Number 857592 – TODO). Zahvaljujem se Luciji i Radi Jug na privoli za korištenje fotografije Plitvičkih jezera.

Literatura

URL 1: Adventures in mapping blog, https://wp.me/p6QipF-1Da, (15.6.2022.).

URL 2: Something about maps blog, https://wp.me/psOyY-1e3, (15.6.2022.).

URL 3: Ordnance survey blog, https://www.ordnancesurvey.co.uk/newsroom/blog/newposter-to-celebrate-70-years-of-britains-national-parks, (15.6.2022.).

URL 4: QGIS, https://www.qgis.org/, (15.6.2022.).

URL 5: Wikipedija, https://hr.wikipedia.org/wiki/Nacionalni_park_Plitvi%C4%8Dka_jezera, (15.6.2022.).

URL 6: Fotografija Plitvičkih jezera,

https://np-plitvicka-jezera.hr/wp-content/uploads/2017/10/plitvicka-jezera-379.jpg, (15.6.2022.).

URL 7: Brošura NPJJ, https://issuu.com/plitvicelakes/docs/hr_-_it_web, (15.6.2022.).

URL 8: Brošura za vodiče NPJJ,

https://issuu.com/plitvicelakes/docs/vodi__za_vodi_e, (15.6.2022.).

URL 9: NIPP, https://www.nipp.hr/default.aspx?id=22. (15.6.2022.).

URL 10: Geoportal NIPP-a, https://www.nipp.hr/default.aspx?id=97, (15.6.2022.).

URL 11: Geoportal Hrvatskih voda, https://preglednik.voda.hr/, (15.6.2022.).

URL 12: Bioportal, https://www.bioportal.hr/gis/, (15.6.2022.).

URL 13: Diva-GIS, https://www.diva-gis.org/, (15.6.2022.).

URL 14: OpenStreetMap, www.openstreetmap.org, (15.6.2022.).

URL 15: Overpass Turbo, https://overpass-turbo.eu/, (15.6.2022.).

URL 16: SRTM, https://www.usgs.gov/centers/eros/science/usgs-eros-archive-digital-elevation-shuttle-radar-topography-mission-srtm?qt-science_center_objects=0#overview, (15.6.2022.).

URL 17: CGIAR, https://srtm.csi.cgiar.org/srtmdata/, (15.6.2022.).

Lakes of the Plitvice Lakes National Park from Open Data and Open Tools

Abstract

Cartographers often use tools that were not primarily developed for cartography, but for graphic design or publishing. Customizing the software to meet the requirements of the cartographer is a difficult task. In this context, open source tools show their full potential for cartographic use. Data or tools are open if someone is free to use, modify or redistribute them. Open cartography includes open technologies and software, and open data. Today, there are many open tools for spatial data processing, as well as for their graphic development in the process of creating a cartographic representation. One of the most popular services for creating and collecting open spatial data is OpenStreetMap, while QGIS is the most popular among the tools. The paper presents the process of creating an open cartographic representation from the collection of spatial data, their processing in QGIS software and graphics in Inkscape. This paper shows how effective cartographic representations can be created very easily and quickly using open technologies and data. Open access allows complete control over data and tools and encourages customization of products to your needs.

Keywords: *cartography, OpenStreetMap, open-source, Plitvička jezera, QGIS*

Uloga geodezije u razvoju sustava upozoravanja od poplava i izradi prognostičkog modela rijeke Mure

Zoran Šarić[1], Ivica Mustač[2]

[1]GiP Šarić d.o.o., Vučetinec 30B, Lopatinec, zoran@saric.com.hr

[2]Hrvatske vode d.o.o., I. pl. Zajca 53, Čakovec, mustac@voda.hr

Sažetak

Uslijed utjecaja klimatskih promjena, zabilježeni su učestali ekstremni sušni (2003. g., 100 m^3/s) i vlažni/kišni (2014. g., 1.448 m^3/s) događaji za rijeku Muru, a koja se proteže 49,5 km uzduž mađarskog i hrvatskog teritorija. Za zaštitu od poplava potrebni su nam aktualni topografski i hidrografski podaci, a sve u svrhu zajedničkog i održivog upravljanja rijekom Murom i područjem uz nju. Austrija, Slovenija, Hrvatska i Mađarska razvile su 2011. godine međunarodni prognostički sustav za uzbunu i prognozu od poplava za cijelo slivno područje Mure. Koristeći LIDAR s kombinacijom digitalne fotogrametrije dobiven je 3D model terena područja obale i priobalja Mure, a snimanje riječnih profila obavljeno je integriranim sustavom dubinomjera i GPS uređaja, čime je dobiven 3D model korita rijeke, kojim se može odrediti i debljina mulja. Ulazni podaci dobili su se mjerenjem razine vodene površine posebnim ultrazvučnim mjeračima vodostaja, koji su smješteni na posebno za to izrađenoj konstrukciji. Količine oborina mjerene su kišomjerima. Njihov je zadatak da kontinuirano mjere razinu vode i količinu oborina, te šalju podatke na server, gdje se posebnim softverom izrađuje više vrsta prognoza, odnosno modela poplava. Takve statičke konstrukcije sa senzorima snimljene su geodetski i potrebna je njihova periodička geodetska kontrola. Svrha sustava je da ostvarimo koordiniranu, profesionalniju i stručniju razinu mađarsko-hrvatske suradnje tijekom obrane od poplave na rijeci Muri.

Ključne riječi: *3D oblak točaka, Digitalni ortofoto, LIDAR, Mura*

1. Uvod

Zemlja je nastala otprilike prije 4,5 milijarde godina, „preživjela" je oscilacije toplih razdoblja i ledenih doba, čiji su ciklusi trajali desecima tisuća ili čak milijunima godina. Globalna zagrijavanja uzrok su klimatskih promjena uslijed čega se u atmosferu ispuštaju staklenički plinovi, bez čijeg bi efekta temperatura Zemlje bila oko -18°C. Međutim, uslijed sagorijevanja fosilnih goriva kao što su nafta, ugljen i prirodni plin, te ljudske aktivnosti kao što su poljoprivreda i krčenje šuma, došlo je do rasta temperature na Zemlji.

Upravo iz tog razloga u zadnjih 150 godina, temperaturni skok je brži nego ikada. Zemlja se zagrijala u zadnjih 10.000 godina za 5°C. Iz tog razloga postoji realna zabrinutost, da takve klimatske promjene mijenjaju učestalost i veličinu riječnih poplava. Iz svega navedenog moramo si postaviti jedno pitanje, nalazi li se Europa trenutno u razdoblju bogatom poplavama iz dugoročne perspektive.

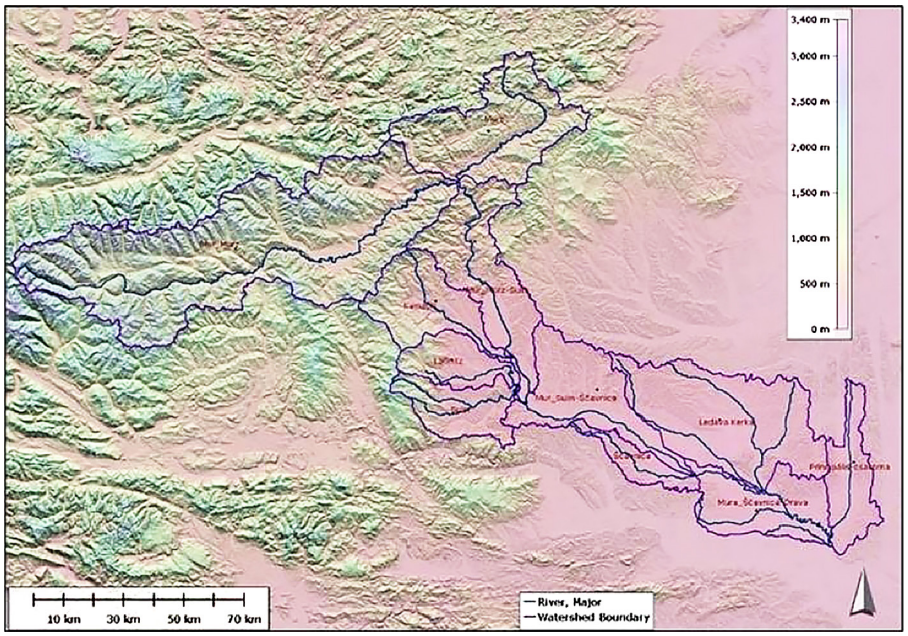
Činjenica je da poplave mogu prouzročiti ozljede i gubitke života, znatne ekonomske troškove te nanijeti štetu okolišu i kulturnoj baštini, uništavajući zgrade, infrastrukturu (promet, energiju, komunikaciju) i sredstva za život (kuće, stanove, prijevozna sredstva i dr.).

Između 1980. i 2017. godine poplave su odnijele oko 4300 života i stajale su europsko gospodarstvo više od 170 milijardi eura, što predstavlja gotovo trećinu ukupne štete od prirodnih opasnosti.

Poplave nećemo moći izbjeći, no opasnost od istih treba svesti na minimum, na način da pratimo nove tehnologije na području svih znanosti, posebice u geodeziji, kao i mogućnosti primjene novih alata temeljenih na procesu procjene rizika od poplava, a koji obuhvaćaju uključene fizičke mehanizme i strategije upravljanja rizicima.

2. Općenito o rijeci Muri

Mura izvire u Austriji u Visokim Turama i svoj tok nastavlja preko Slovenije, Mađarske i Hrvatske. Njena dužina je 465 km, a veličina sliva 14.304 km2 (Slika 1), preko Drave se pridružuje riječnom sustavu Dunav. Na svojem donjem toku u dužini od oko 100 km čini državnu granicu (35 km austrijsko-slovenska, 20 km hrvatsko-slovenska, 49 km hrvatsko-mađarska). Izvire iz više izvora, među kojima je najznačajniji Murursprung sa svojim protokom od 100 l/s, koji se nalazi na visini 1898 m. Primajući još nekoliko manjih izvora, potok se u blizini naselja St. Michel pretvara u jasno definiranu rijeku. Prije ušća u Dravu, u Muru se ulijeva voda potoka Trnave, a njezina širina u prosjeku iznosi 150-280



Slika 1: Topografija sliva Mure (URL 6)

m. Naziv rijeke Mure potječe od riječi „die Mure", što u prijevodu znači – Bujica. Uglavnom, kratak opis rijeke Mure bi bio, brza, opasna i nemilosrdna. Mura je lijeva pritoka Drave, a u Dravu se ulijeva između Donje Dubrave i Legrada, na lokaciji Veliki Pažut.

3. Poplava uz rijeku Muru 2014. godine

Jedna od posljednjih velikih poplava dogodila se u rujnu 2014. godine, kada je nastao ogroman poplavni val na rijekama Muri i Dravi. Poplavni val bio je uzrokovan zasićenošću tla, umjerenom napunjenošću korita i obilnim kišama koje su padale šest dana zaredom. Tada je vodostaj bio na najvišoj razini unazad nekoliko desetljeća. Nasip je na nekoliko mjesta bio niži od prognozirane razine poplave. Osim toga vrijeme pripreme za obranu je bilo kraće zbog značajnih količina oborina koje su pale u relativno kratkom vremenu, te je došlo do ubrzanog rasta poplavnog vala.

U to vrijeme zaključilo se da je jedini izlaz za obranu od poplava što točnije predviđanje vremena vršnog vodostaja, pouzdani reljefni prikaz i poznavanje korita (dubine) Mure.

U današnje vrijeme stvaraju se modeli poplava putem aplikacija, tj. računalnih programa, sa nizom parametara (mjerenja količina padalina i visine vodostaja putem senzora u realnom vremenu) i matematičkim modelima, koji u kratkom vremenskom roku stvaraju prognostičku kartu i 3D model (simulaciju) poplave.

Takve aplikacije i modeliranja u suvremeno doba dobivaju sve više na važnosti, a pomoću njih stvaramo realne prognoze od poplava kako bismo dobili pouzdan sustav obavješćivanja i obrane od poplave u svrhu učinkovite zaštite ljudskih, materijalnih i kulturnih dobara.

4. Hidrografski atlas rijeke Mure

U ožujku 2012. godine upućena je Europskoj komisiji prijava za projekt: „Mađarsko-hrvatski hidrografski atlas rijeke Mure na području od zajedničkog interesa" pod akronimom HAMURA. Projekt je prijavljen u sklopu IPA prekograničnog programa Mađarska-Hrvatska 2007-2013. na temelju III. poziva za podnošenje projektnih prijedloga objavljenog 22. studenog 2011. godine. Glavni korisnik u projektu je Nyugat-dunántúli Vizügyi Igazgatóság Szombathely (Zapadno-prekodunavska uprava vodnog gospodarstva, Sombatelj), dok su Hrvatske vode Projektni partner.

Osnovni cilj projekta je dobivanje aktualnih topografskih i hidrografskih podataka o rijeci Muri, a u svrhu zajedničkog i održivog upravljanja rijekom i područjem uz nju.

Hidrografski atlas rijeke Mure izrađen je za tok rijeke Mure od ušća rijeke Krke u rijeku Muru (rkm 48+000) pa do ušća rijeke Mure u rijeku Dravu (rkm 0+000), a to je područje od zajedničkog vodnogospodarskog interesa Mađarske i Republike Hrvatske.

Za potrebe izrade Atlasa snimljeno je 6.800 ha zemljišta i 381 riječnih profila. Snimanje terena obavljeno je fotogrametrijski i LIDAR tehnologijom tj. laserskim skeniranjem iz zraka (engl. Airborne Laser Scanning - ALS) s minimum 6 točaka/m2, te visinskom i horizontalnom točnošću ± 10 cm dok su riječni profili snimani pomoću integriranog sustava dubinomjera i GPS uređaja.

Lasersko skeniranje iz zraka obavljeno je 28. studenog 2013. godine u sklopu Projekta plana upravljanja rizicima od poplava za naručioca Državnu glavnu direkciju za vodno gospodarstvo Mađarske. Skeniranje je obavila tvrtka Eurosense Kft. iz Budimpešte dok je snimanje riječnih profila obavila tvrtka ESRI Magyarország Kft. iz Budimpešte u razdoblju od studenog

2014. do siječnja 2015. godine, kao i obradu podataka i izradu Atlasa u digitalnom i analognom obliku.

Hidrografski atlas rijeke Mure izrađen je u digitalnom i analognom obliku i u hrvatskom i mađarskom koordinatnom i visinskom sustavu. Izrađen je u dvije sadržajno identične verzije na hrvatskom i mađarskom jeziku i kao takav biti će dostupan na web stranicama Hrvatskih voda kao i na web stranicama Zapadno-prekodunavske uprave vodnog gospodarstva iz Sombatelja. Prikupljeni podaci laserskog skeniranja iz zraka i terenskog geodetskog snimanja obrađeni su i pripremljeni za korištenje GIS tehnologijom te je u tu svrhu formirana GIS baza podataka. Podaci su tematski grupirani u datoteke koje sadrže geodatabaze sa tematskim podacima i GIS prikaze tih podataka. Koncipiran na takav način uvijek će se moći mijenjati i nadopunjavati, te na različite načine prikazivati i koristiti. Navedene karakteristike, osim praktičnije uporabe, omogućuju još i da Hidrografski atlas rijeke Mure postane djelotvorno oruđe u procesu planiranja po smjernicama za integralno upravljanje rijekom i slivom sukladno vodnogospodarskoj koncepciji EU. Baza podataka Atlasa Mure prilagođena je za korištenje programskim paketom ArcGIS koji omogućava jednostavno prebacivanje i prikazivanje GIS podataka u različitim projekcijskim i referentnim sustavima. (Slika 2)

Hidrografski atlas rijeke Mure završen je u ožujku 2015. godine te je 15.04.2015. godine održana završna konferencija.

5. Primjena LIDar tehnologije

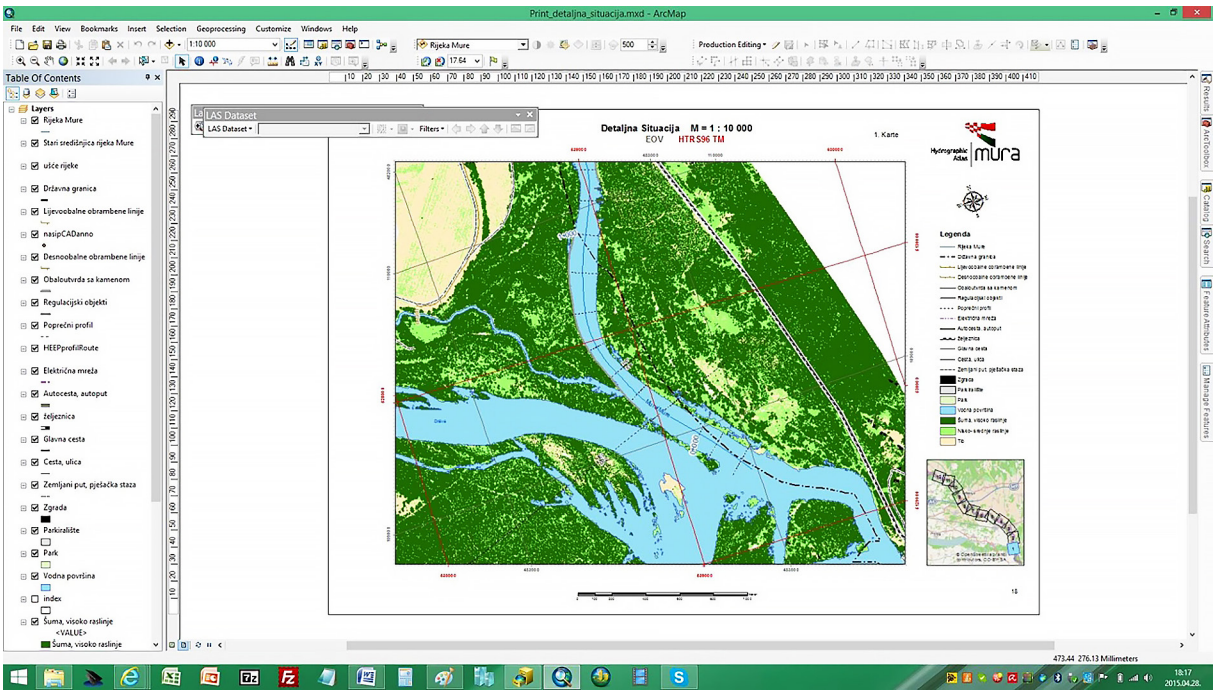
Projekt „ForMURA“ se bavi pronalaženjem sustava modela za obranu od velikih voda tj. zaštitu poplavne ravnice i priobalja rijeke Mure u dužini 49.5 km, koja zadire na područje Mađarske i Hrvatske.

Poplavni učinci i rizici utječu na oba područja i stoga postoji potreba za tijesnom suradnjom u aktivnostima zaštite inundacijskog pojasa rijeke Mure. Cijelim poplavnim područjem posljedice poplava su neodvojive u obje države, dakle zahvaćaju oba područja i zahtijevaju efikasnu suradnju u preventivnim aktivnostima.

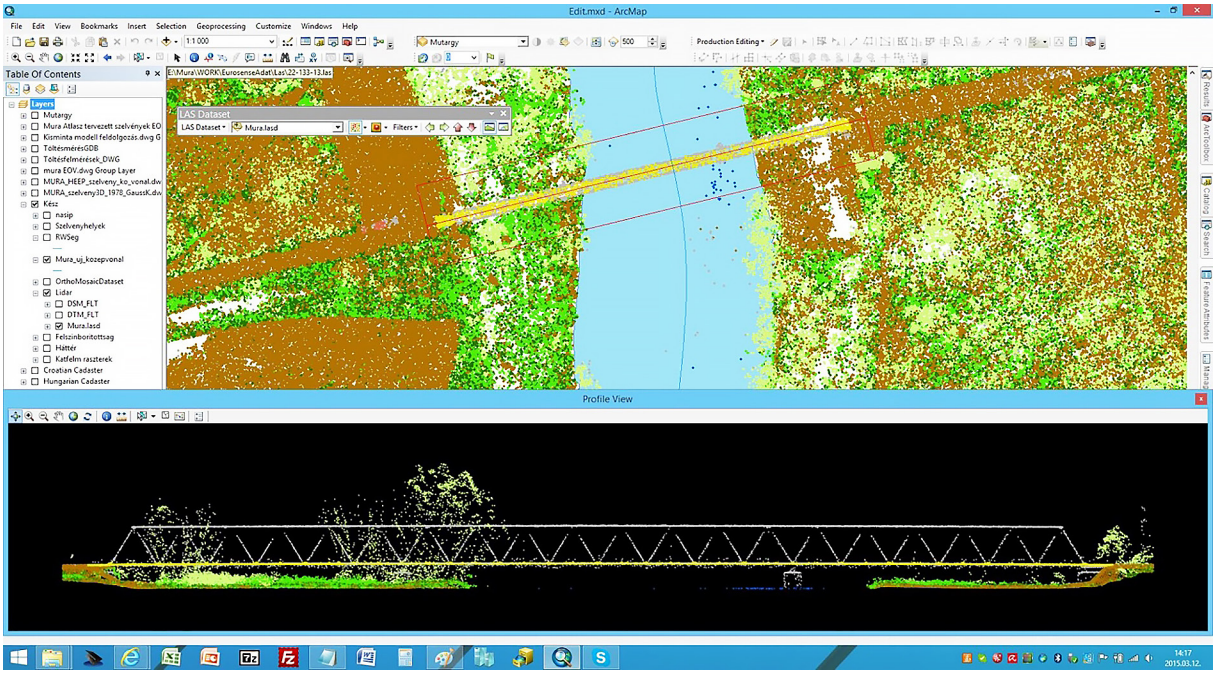
Opći cilj projekta je razviti učinkovitu suradnju u slučaju poplava u stvarnom vremenu između mađarskih i hrvatskih vlasti. Zajedničkom prekograničnom suradnjom nadležnih mađarskih i hrvatskih institucija rizik od poplava može biti znatno predvidljiviji. Suradnja se odnosi na razmjenu svih vrsta podataka u realnom vremenu. Unosom ili očitavanjem parametara i podataka računalni softver stvorit će model prognoze poplava, te će se omogućiti brzi pristup relevantnim informacijama duž cijelog sliva rijeke Mure, a koji su presudni za učinkovito obavještavanje i obranu od poplava. Vodeći partner projekta je Zapadno - transdunavska uprava za vode iz Mađarske. Projekt traje od 01.01.2021.g. – 31.08.2022 g..

6. Primjena LIDar tehnologije

Prilikom izrade Lidarska tehnologija (engl. LIDAR = *Light Detection and Ranging*) u posljednje se vrijeme sve više primjenjuje za dobivanje podataka o površinama uz riječna korita, jer može pružiti veoma točne informacije o obliku georeferenciranih 3D točaka. Jedno je od glavnih svojstava toga sustava njegova mogućnost prikupljanja velikoga broja visoko preciznih trodimenzionalnih prostornih podataka velikih područja u razmjerno kratkom razdoblju. (Slika 3) LI-



Slika 2: Primjer detaljne situacije za Hrvatsku

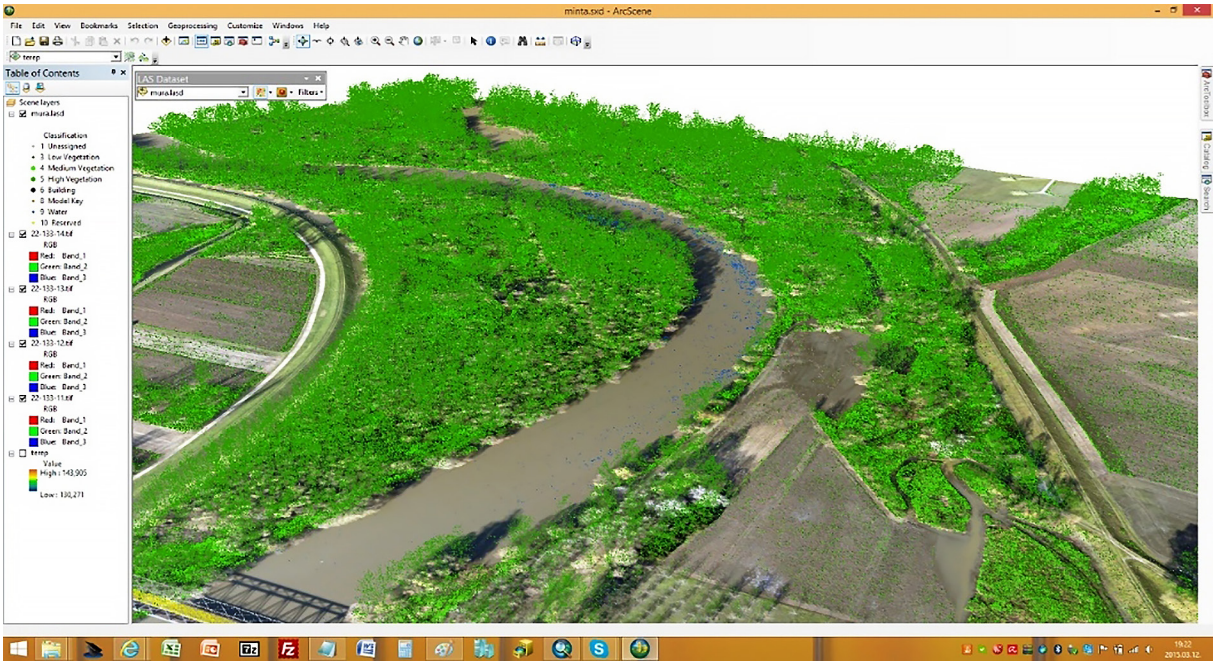


Slika 3: Oblak točaka dobiven LIDARom

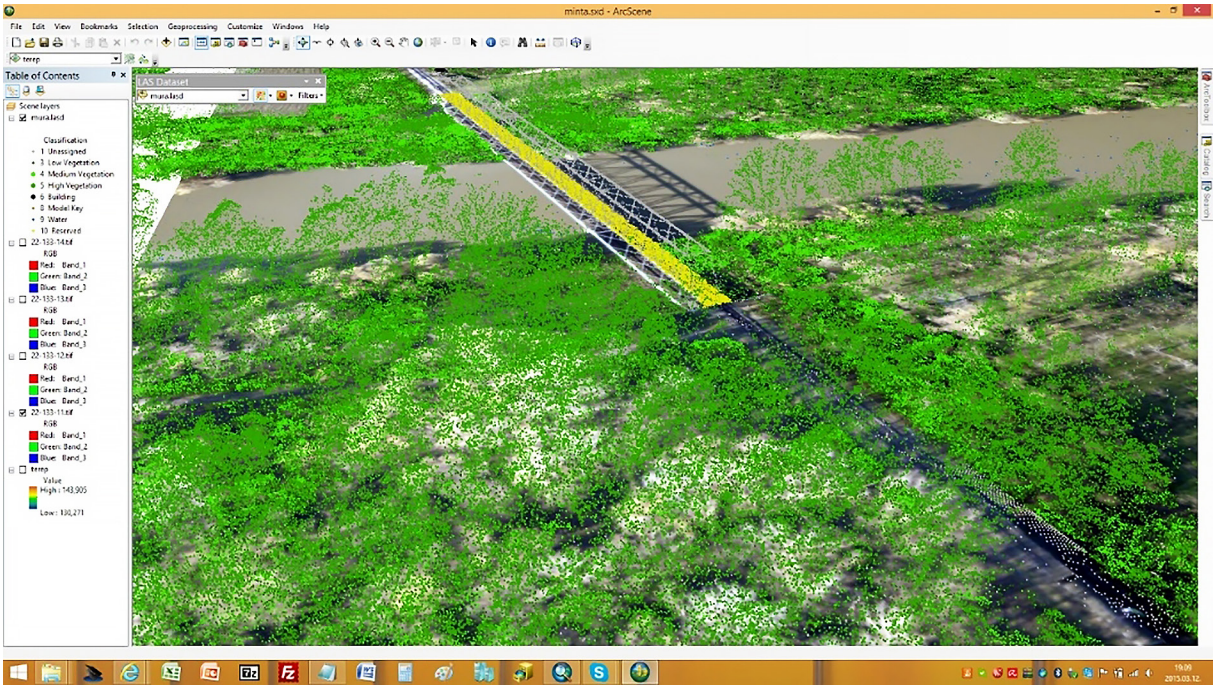
DAR sustav sastoji se od triju osnovnih komponenata: GNSS-a (globalni navigacijski satelitski sustav), IMU-a (engl. Inertial Measuring Unit) i laserskog skenera.

Lidarski sustav temelji se na laserskom skeniranju koje mjeri udaljenost između skenera i objekta izmjere, a ona se računa pomoću brzine svjetlosti i vremena potrebnoga da emitirano lasersko zračenje dođe do objekta. Jedna je od prednosti toga sustava njegova iznimna preciznost koja se ogleda u činjenici da se prilikom laserskoga skeniranja iz zraka ponekad mogu dobiti podaci koji su precizni u centimetar, dok je lasersko skeniranje sa Zemlje još preciznije i ide ka milimetarskoj točnosti.

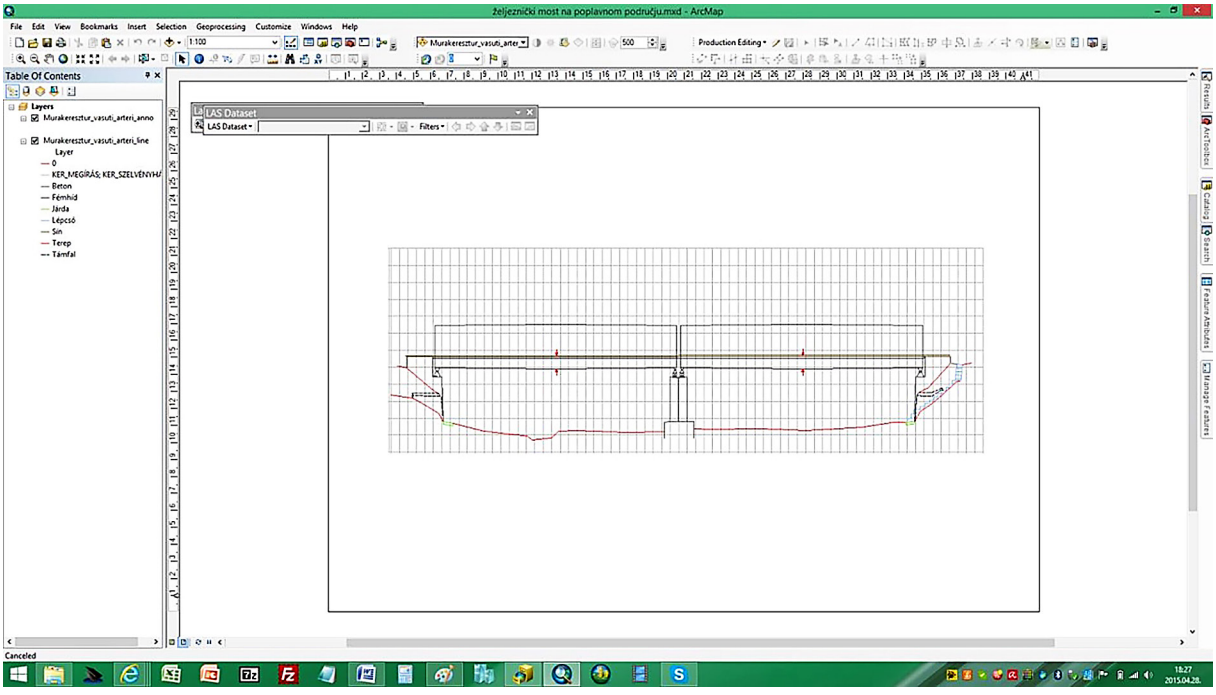
Sustav je neovisan o danjem svjetlu, ali zato traži čistu atmosferu prilikom skeniranja (bez smoga ili magle koji bi onemogućili ili produljili vrijeme skeniranja). Osim toga laser se ne može koristiti za kišnog vremena, jer većina emitiranoga zračenja ne može prodrijeti kroz vodu. Međutim, kako bi podaci dobiveni laserskim skenerima bili korisni, potrebno je dobro poznavati problematiku samog načina nastanka, obrade i pohrane trodimenzionalnog oblaka točaka. Ukoliko se tome doda i problem kretanja, te potreba za praćenjem lokacije uređaja za svo vrijeme snimanja, dolazi se do kompleksnog sustava koji uključuje razna mjerna i softverska rješenja.



Slika 4: Obrađeni podaci LiDAR-a – prikaz Mure



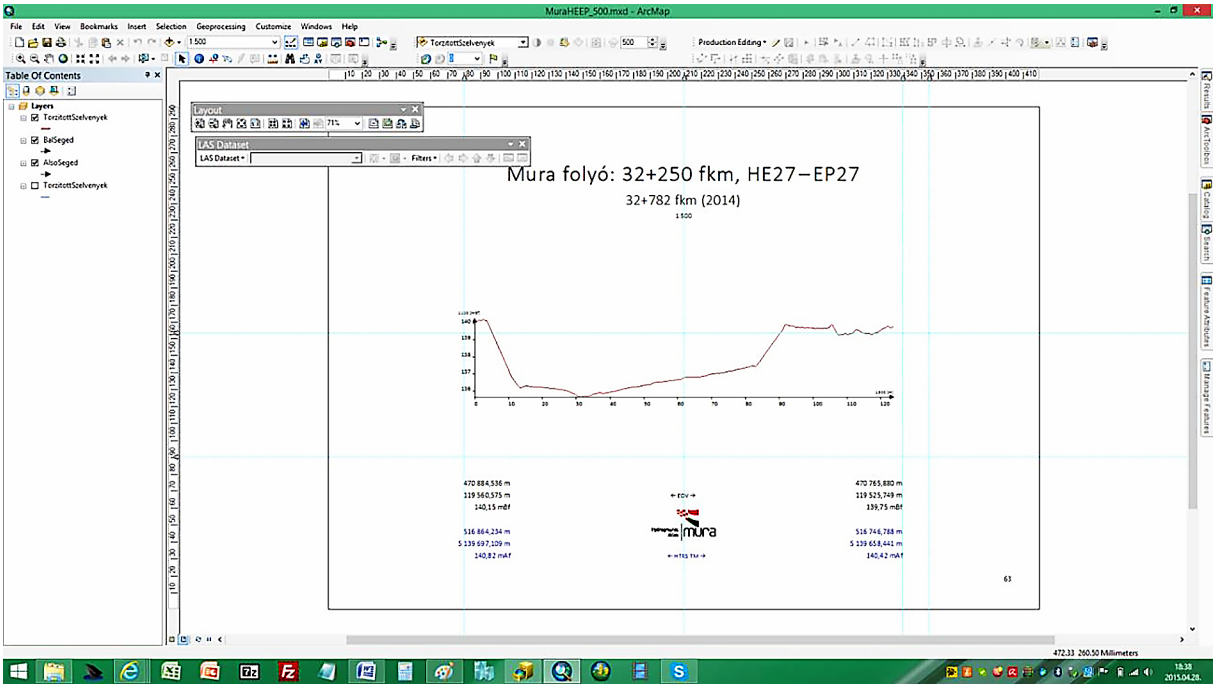
Slika 5: Obrađeni podaci LiDAR-a – prikaz mosta



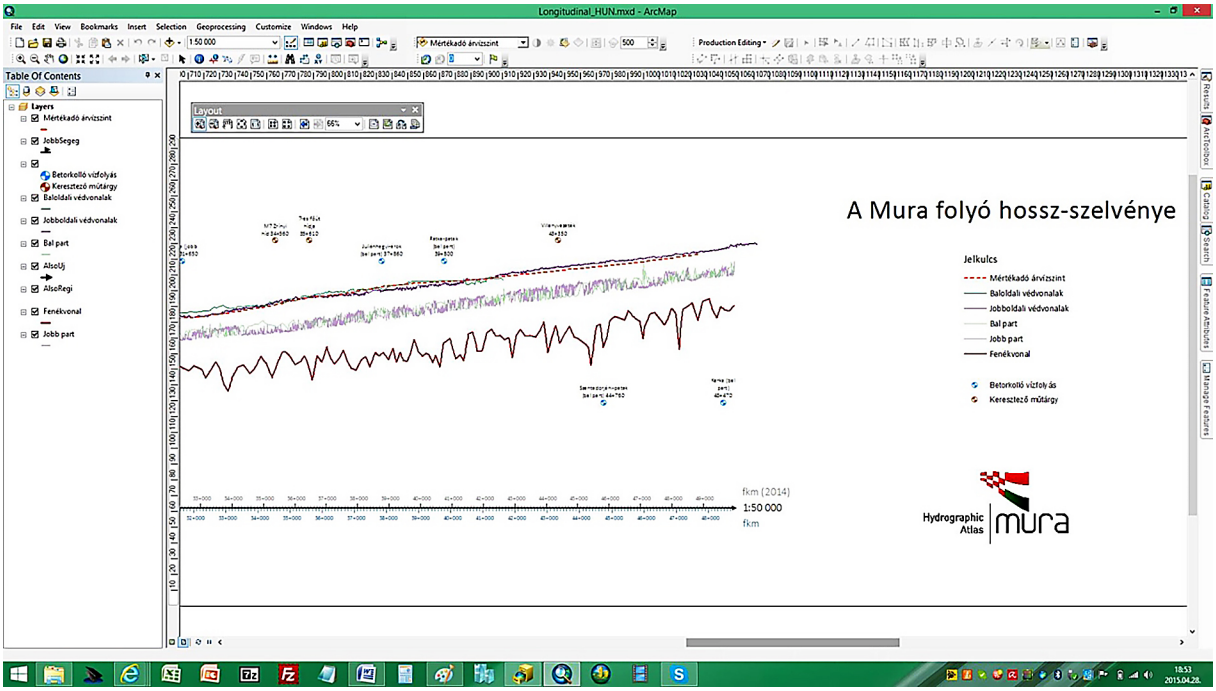
Slika 6: Poprečni profil mosta

Primjenom programa CAD i GIS moguće je iz klasificiranog oblaka točaka izraditi proizvode poput digitalnoga modela reljefa i digitalnoga modela površine, a snimanjem digitalnom kamerom moguće je izraditi digitalni ortofoto snimak. LIDAR u kombinaciji s klasičnim geodetskim metodama daje sve bitne prostorne informacije koje se na učinkovit način mogu koristiti za potrebe izrade digitalnog modela reljefa (DMR-a), (Slika 4) i (Slika 5), poprečnog profila mosta (Slika 6), poprečnih (Slika 7) i uzdužnih profila (Slika 8), uzdužnog profila desne obale nasipa rijeke Mure (Slika 9). Takvi profili sadrže i podatke u koordinatnom i visinskom sustavu obje strane.

Kombinacija LIDar mjerenja i sustava koji se temelje na integraciji različitih mjernih senzora omogućavaju dobivanje raznovrsnih podataka na temelju kojih je moguća i detekcija potencijalnih opasnosti, u našem slučaju, moguće je na vrijeme opaziti potencijalnu opasnost kod oštećenja nasipa, nanosa ili zapreka u rijeci Muri.



Slika 7: Poprečni profil



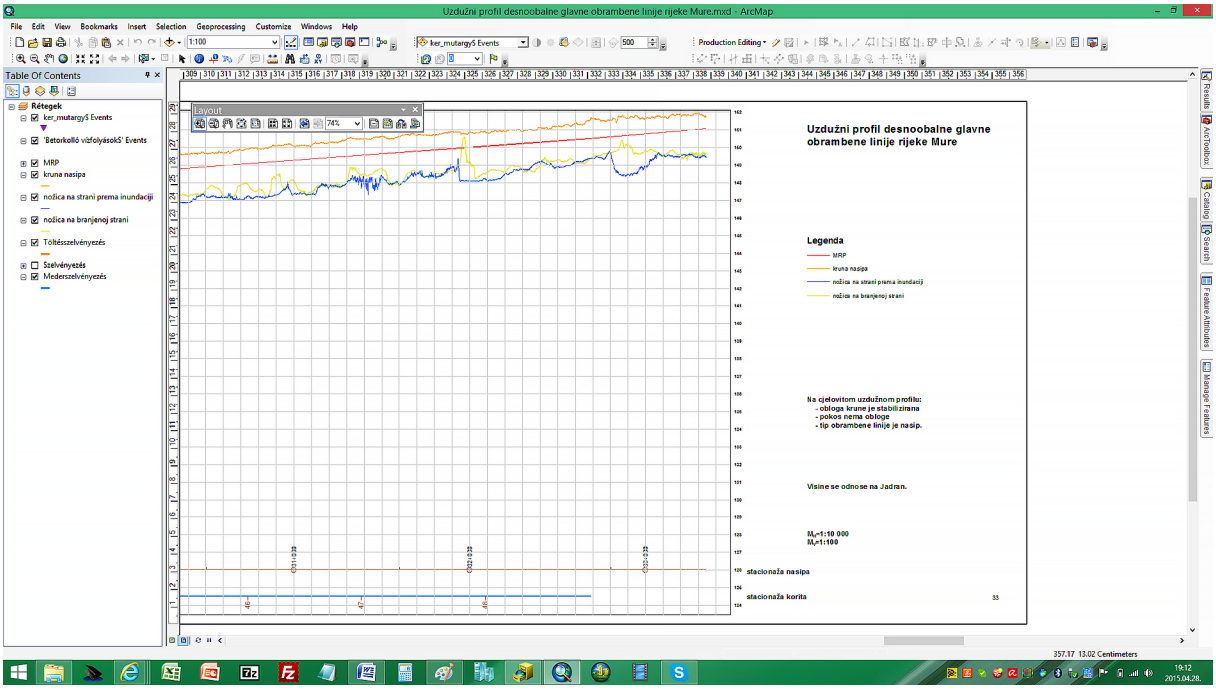
Slika 8: Uzdužni profil

7. Mjerenje razine vode i količine oborina

U svrhu računanja što realnijeg modela plavljena inundacijskog pojasa rijeke Mure, postavljeno je devet vodomjera (Slika 10) i kišomjera (Slika 11) na mostovima i na posebnim stupovima. Isti su spojeni na FTP server i stalno šalju podatke mjerenja visine vodostaja i količine oborina u bazu putem NB-IoT (Narrow Band Internet of Things) tehnologije.

Internet i njegov razvoj uvelike je doprinio napretku komunikacijskih tehnologija i informatike. IoT ili Internet stvari (engl. Internet of Things) je trend, tehnologija sljedećeg bežičnog interneta. IoT se posljednjih godina ubrzano razvijao i predložen je velik broj tehnologija koje ga omogućavaju, a našao je primjenu u infrastrukturi: pametni gradovi, praćenje okoliša, pametne kuće i dr.

Korištenjem NB-IoT tehnologija za vodomjer (mjeri vodostaj rijeke Mure) i kišomjer (mjeri količinu obori-



Slika 9: Prikaz Uzdužnog profila desne obale nasipa rijeke Mure

na) koji odašilju podatke na server, gdje se kasnije isti obrađuju. Pozitivne karakteristike ove mreže su brzina prijenosa malih količina podataka, velik domet i minimalno korištenje energije (životni vijek baterije do 10 godina) za pokretanje senzora (npr. razna mjerenja) putem LPWAN (Low-Power Wide-Area Network) tehnologije. LPWAN prijenosni sloj uspostavlja bežične kanale između krajnjih uređaja i cloud platforme i omogućava brzi prijenos malih količina podataka. Moguća je i međusobna komunikacija uređaja sa NB-Iot tehnologijom.



Slika 10: Vodomjer smješten na posebnom nosaču sa NB-IoT uređajem



Slika 11: Kišomjer sa NB-IoT uređajem

8. Modeli prognoze poplava

Model prognoze poplava izradio bi se u jednodimenzionalnim i dvodimenzionalnim hidrodinamičkim modelima koji pokrivaju cijeli riječni sustav sliva i modelima oborinskog otjecanja koji određuju dotok u riječnu mrežu.

Jednodimenzionalni hidrodinamički model uzima u obzir svaku varijablu stanja (razinu vode, protok, brzinu, koncentraciju, područje protoka, širinu vodene površine) sa srednjom vrijednošću odjeljka. Rezultati proračuna bi se prikazivali kao vremenski nizovi i uzdužni presjeci vodostaja, brzine protoka i širine vodene površine.

Dvodimenzionalno hidrodinamičko modeliranje može se koristiti za modeliranje poplavnih valova koji preplavljuju poplavno područje i akumulacije za smanjenje poplava. Vodotok je slobodno površinski, turbulentan, pretežno jednoličan tok, ali se može očekivati prelijevanje preko cestovnih nasipa mjestimično nejednolikog toka. Određujuće sile su: gravitacija, trenje, inercija.

Model je prikladan za proračun protoka u glavnom kanalu i poplavnim područjima numeričkim rješavanjem dvodimenzionalnih hidrodinamičkih jednadžbi plitke vode.

Poplave s vremenom postupno ulaze u poplavno područje iz korita širokog nekoliko kilometara, a u složenoj topografiji smjer toka obično se ne može unaprijed procijeniti. To se posebno odnosi na razvijene meandre Mure, koje dijelom presijeca tok kroz poplavno područje.

Za dvodimenzionalno hidrodinamičko modeliranje toka poplavnih valova važna je topografija cijele poplavne ravnice, koja mora biti dana s dovoljnom točnošću i detaljima. Brojni izvori podataka mogu se koristiti za izradu topografije: rasjedne linije (nasipi, riječne obale, pukotine terena), trodimenzionalne polilinije, vektorizirane konturne linije, istraživanja korita rijeke, podatkovne točke istraživanja LIDAR. Na temelju njih softver stvara mrežu modela čija gustoća nije ujednačena.

Za Dvodimenzionalni hidrodinamički model veoma je bitna i namjena zemljišta, a razlikujemo četiri klase glatkoće tj. hrapavosti zemljišta:

- riječno korito,
- glatke poplavne ravnice: pašnjaci, oranice i drugi otvoreni tereni,
- grubo poplavno područje: šuma, grmlje i naselje,
- nasipi.

Dvodimenzionalni hidrodinamički modeli također zahtijevaju specificiranje rubnih uvjeta, koji su obično protok na gornjoj granici i razina vode na donjoj granici. Za Dvodimenzionalni hidrodinamički model, rubni uvjeti mogu se uzeti iz hidroloških modela ili čak Jednodimenzionalnih hidrodinamičkih modela. Veoma bitan rubni uvjet je oborinsko otjecanje u slivovima zbog prognoziranih oborina. Ovo oborinsko otjecanje pojavljuje se u vodotocima kao ulazno ispuštanje.

Najvažnije očekivanje je da se rezultati modela moraju prilagoditi najnovijim dostupnim promatranim podacima od jedne serije do druge, jer u slučaju ozbiljne poplave između dvaju modela nije moguće resetirati ili ponovno kalibrirati parametre modela. Dakle, potrebna mu je automatska radna mogućnost korekcije, koja primljene rezultate čini upotrebljivim i pruža zaštitu od „kvara" modela. Za to je rješenje asimilacija podataka, koja automatski ispravlja rezultate modela na temelju najnovijih dostupnih opažanja u promijenjenim diskretnim točkama (mjernim stanicama vodomjera i kišomjera).

Osim deterministčkih ulaznih meteoroloških podataka, potrebno je staviti na raspolaganje sustavu za obradu i nekoliko različitih prognoza oborine i temperature. Potrebno je definirati vremenske serije oborine kao ulazne podatke za podslivove. Sustav prvo mora generirati vremenske serije oborina za svaki podsliv iz padalina u točkama mreže. Sustav bi tada trebao izračunati oborinu od -2 dana (48 sati ranije) do +6 dana (144 sata kasnije) iz svake vremenske serije u odnosu na vrijeme generiranja scenarija.

Sve navedeno treba obraditi putem softvera, koji mora imati dvije karakteristike: softver mora biti razvojni i funkcionalan u smislu jednostavnog unosa vanjskih podataka i brze izrade modela za predviđanje poplava.

Predviđeni vodostaji, protok vode i alarmi moraju biti prikazani na online karti na web klijentu, pohranjeni na središnjem poslužitelju okvira, s pristupom na više razina:

- razina operatera (operatori sustava): s punim pristupom,
- stručna razina: projektni partneri i organizacije u zaštiti od poplava,
- javna razina: svi ostali.

Postoji potreba za uspostavom višerazinskog pristupa, jer pouzdanost automatske prognoze nije zajamčena, a organizacije uključene u obranu od poplava imaju pravo izraditi službene prognoze poplava tako da samo one mogu procijeniti koji su podaci pouzdani. Sustav predviđanja mora generirati matricu upozorenja za određeno vrijeme unaprijed (npr. šest dana) što se može postići na razinama pristupa Operator i Stručnjak.

Budući da prognostički sustav uključuje i informatičke i profesionalne (hidrodinamičko modeliranje) sustave, bitno je sudjelovanje i suradnja ne samo stručnjaka za modeliranje, već i IT stručnjaka.

Cilj projekata je značajno smanjiti rizike od poplava u slivnom području rijeke Mure i uspostaviti zajednički model za predviđanje poplava u svim zemljama područja sliva i razviti zajednički sustav upozorenja koji će informirati organizacije uključene u obranu od poplava i sve donositelje odluka.

9. Zaključak

Za učinkovit sustav informiranja i obrane od poplava, potrebno je izraditi što vjerodostojniji model Zemljine površine i riječnih korita, tj. prikupiti točan i vjerodostojan prostorni podatak. U ovom radu također je prikazana značajna uloga geodezije u smislu korištenja novih tehnologija u prikupljanja velikih količina visoko preciznih podataka u što kraćem vremenskom razdoblju, kao i uspostava baze podataka za upravljanje geoprostornim podacima.

Takve baze podataka i digitalni modeli reljefa koriste se za izradu jednodimenzionalnih i dvodimenzionalnih idhrodinamičkih modela za predviđanje i obranu od poplava.

Jednodimenzionalni modeli koriste se za predviđanje očekivanih razina vode, ali ne pokazuju izravno područja očekivanih poplava. U predstavljenom susta-

vu, dvodimenzionalna poplavljena područja mogu se koristiti za učinkovitiju zaštitu od poplava, jer je moguće procijeniti područja za koja se očekuju poplave. Rezultati jednodimenzionalnog i dvodimenzionalnog modela mogu se koristiti za upravljanje matricom upozorenja. Sposobnost predviđanja lokacija i vrsta očekivanih zaštitnih intervencija stoga može imati učinkovitu ulogu potpore u odlučivanju. Modeli su obično kalibrirani samo za jednu ili dvije velike poplave, tako da ne mogu predvidjeti sve poplavne valove s jednakom učinkovitošću. Najveći problem obično uzrokuje nalet na poplavne valove i modeliranje kišnog otjecanja. Također, ne treba zaboraviti nesigurnost vremenskih tj. oborinskih prognoza, koje temeljno određuju veličinu nadolazećih poplavnih valova.

Najvažniji rezultat ovog sustava predviđanja bio bi stvaranje zajedničke baze podataka zemalja riječnog sliva koja bi sadržavala ključne informacije potrebne za izradu modela.

Nadalje, za učinkovitu obranu od poplava bitna je suradnja svih zemalja sliva, jer protok informacija o stanju poplave u uzvodnom dijelu je veoma važan. Ogromna je korist da se dalje razvija kompletan sustav, kako za operatere prognostičkih modela tako i za organizacije zadužene za upravljanje poplavama i katastrofama, kao i za pogođeno stanovništvo.

Dugoročno gledano, učinkovitija obrana od poplava smanjit će troškove zaštite od istih, a gospodarstva dotičnih zemalja osjetit će korist od projekta kao rezultat manjih šteta.

Literatura

EEA, 2020: Economic losses from climate-related extremes in Europe

URL 1: The European Environment Agency, https://www.eea.europa.eu/ims/economic-losses-from-climate-related

URL2: István Juhász (2021) Establishment of the flood forecasting and warning system for the Drava and Mura Rivers-

https://www.researchgate.net/publication/361734868_Establishment_of_the_flood_forecasting_and_warning_system_for_the_Drava_and_Mura_Rivers

URL 3: https://en.wikipedia.org/wiki/Narrowband_IoT

URL 4: Hrvatske vode, https://www.voda.hr/hr/madarsko-hrvatski-hidrografski-atlas-rijeke-mure

URL 5: Hrvatske vode,

https://www.voda.hr/hr/nadogradnja-razvoj-sustava-upozoravanja-prognostickog-modela-mure

URL 6: UNILJ (2011) Hidrološka študija reke Mure (2012), Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Ljubljana, Republika Slovenija

https://mvd20.com/zbornik.php?page=letnik2&leto=2011

The Role of Geodesy in the Development of a Flood Warning System and the Creation of a Prognostic Model of the Mura River

Abstract

Due to the impact of climate change, frequent extreme dry (2003., 100 m^3/s) and wet/rainy (2014., 1.448 m^3/s) events were recorded for the Mura River, which stretches 49.5 km along Hungarian and Croatian territory. For flood protection, we need up-to-date topographic and hydrographic data, all for the purpose of joint and sustainable management of the Mura River and the area adjacent to it. In 2011, Austria, Slovenia, Croatia and Hungary developed an international prognostic system for flood warnings and forecasts for the entire Mura catchment area. Using LIDAR with a combination of digital photogrammetry, a 3D terrain model of the Mura's coast and shores was obtained, and river profiles were recorded with an integrated system of depth gauges and GPS devices, resulting in a 3D model of the river bed, which can also be used to determine the thickness of the silt. The input data was obtained by measuring the water surface level with special ultrasonic water level meters, which are placed on a specially made construction. Precipitation amounts were measured with rain gauges. Their task is to continuously measure the water level and the amount of precipitation, and send the data to the server, where several types of forecasts, or flood models, are created using special software. Such static constructions with sensors are geodetically recorded and their periodic geodetic control is required. The purpose of the system is to achieve a coordinated, more professional and expert level of Hungarian-Croatian cooperation during flood defence on the Mura River.

Keywords: *3D point cloud, Digital orthophoto, LIDAR, Mura*

Analiza utjecaja klimatskih promjena na Vransko jezero u Dalmaciji

Mateo Gašparović[1], Marina Kalaš[2], Maja Ćuže Denona[3]

[1] Sveučilište u Zagrebu – Geodetski fakultet, Kačićeva 26; Zagreb, Hrvatska, mgasparovic@geof.unizg.hr

[2] Geoposition j.d.o.o., Svetog Spasa 26, Split, Hrvatska, mkalas997@gmail.com

[3] Park Prirode Vransko jezero, Kralja Petra Svačića 2, 23210 Biograd na Moru, Hrvatska, maja.cuze.denona@pp-vransko-jezero.hr

Sažetak

Ovo se istraživanje temelji na razvoju metoda daljinskih istraživanja za potrebe prostorno-vremenskog praćenja koncentracije zelenog pigmenta klorofila temeljem satelitskih snimaka Landsat na području Vranskog jezera u Dalmaciji. Kako bi se učinkovito upravljalo ciljnim stanišnim tipovima i vrstama područja ekološke mreže potrebno je razumjeti dinamiku i predvidjeti buduće ponašanje ekosustava ovog plitkog slatkovodnog jezera i kriptodepresije u neposrednoj blizini i u interakciji s morem. Svakom godinom sve smo više svjesni klimatskih promjena koje utječu na hidrološki režim i fizikalno-kemijske parametre jezera te posljedično i cijeli slatkovodni ekosustav. Uzorkovanjem vode i praćenjem koncentracije klorofila u vodi određuje se biomasa fitoplanktona koja je jedan od četiri obavezna biološka elementa kakvoće za ocjenu ekološkog stanja voda. Biomasa fitoplanktona dobar je pokazatelj antropogenog utjecaja zbog brzog odgovora na opterećenje ekosustava hranjivim tvarima (iz poljoprivrede, otpadnih voda) koje je sezonski jako izraženo pogotovo u kombinaciji s višim temperaturama vode. Daljinskim praćenjem koncentracije klorofila kroz duži vremenski period moguće je pratiti promjene u prostorno-vremenskoj raspodjeli fitoplanktona te indirektno utjecaja klimatskih promjena, dok je istovremeno moguće razvijati sustav rane detekcije kritičnih prekomjernih koncentracija klorofila u jezerskim ekosustavima. Metoda procjene koncentracije klorofila temeljena je na podacima satelitskih snimki i laboratorijskim mjerenjima koncentracije klorofila u vodi uzorkovanoj na terenu, te razvijena usporedbom vrijednosti mjerene koncentracije klorofila i niza spektralnih indeksa i kanala satelitske misije Landsat od 2004. do 2011. godine. Razvijenom metodom izrađena je karta prostorne raspodjele koncentracije klorofila u jezeru te je utvrđeno da su najveće koncentracije klorofila prisutne kod viših temperatura kad dolazi i do većeg razvoja fitoplanktona.

Ključne riječi: *daljinska istraživanja; geodezija; klorofil; Landsat; modeliranje*

1. Uvod

Mnogi ekosustavi i zaštićena područja u Europi, kao i u cijelom svijetu su pod pritiskom klimatskih promjena. Veliki utjecaj klimatskih promjena predstavlja prijetnju biološkoj raznolikosti na kopnu i u morima, dok su slatkovodni ekosustavi prepoznati kao najugroženiji klimatskim promjenama. Ti isti slatkovodni ekosustavi (rijeke, jezera i pogotovo močvarna staništa) osim zbog visoke bioraznolikosti važni su i za ljude zbog usluga ekosustava koje daju (usluge koje priroda pruža besplatno, a čovjek ih koristi – pročišćavanje vode, hrana, obrana od poplava, regulacija klime, turizam). U okviru ovog istraživanja praćene su promjene koncentracije klorofila koje ukazuje na biomasu fitoplanktona – fotosintetskih mikroorganizama koji žive u stupcu vode. Cvjetanje fitoplanktonskih algi utječe na prozirnost jezera, kvalitetu vode i ubrzava proces eutrofikacije, koji ubrzava starenje jezera. Zajedno s podacima s terena korišteni su podaci daljinskih istraživanja koji se sve više koriste kao dopuna podacima mjerenim na terenu. Kombinacijom te dvije vrste podataka stvara se istinski sinoptički alat za istraživanje jezera tj. praćenje kvalitete vode pomoću vrijednosti koncentracije klorofila (Allan, 2011). Korištenje daljinskih istraživanja za proučavanje jezera je zahtjevan proces s obzirom na različitost svakog jezera po pitanju dimenzija, ekologije, vode i vrsti korištenja zemljišta u slivu; stoga svako jezero predstavlja pojedinačan izazov (Tebbs i dr., 2013). U raznim novijim istraživanjima, daljinska istraživanja se koriste kao alat za praćenje parametara kakvoće vode, uključujući koncentracije klorofila (chl-a) (Rodríguez-López i dr., 2020). Klorofil je zeleni biljni pigment, nužan u procesu fotosinteze, a nalazi se u svim zelenim dijelovima biljke. Klorofil imaju sve zelene biljke, alge i jedna skupina primitivnih fotosintetskih bakterija. Povećana koncentracija klorofila ukazuje na proces eutrofikacije, promjene u ekosustavu uzrokovane prekomjernom brzinom stvaranja organske tvari (URL 1). Stoga, koncentracija klorofila (chl-a) važan je indeks za otkrivanje stupnja onečišćenja unutarnjih voda poput rijeka, jezera i dr.

Ovo se istraživanje temelji na razvoju metoda daljinskih istraživanja za potrebe prostorno vremenskog praćenja koncentracije zelenog pigmenta klorofila



Slika 1: Park prirode Vransko jezero u Dalmaciji (URL 3)

temeljem satelitskih snimaka Landsat na području Vranskog jezera u Dalmaciji. Kako bi se učinkovito upravljalo ciljnim stanišnim tipovima i vrstama područja ekološke mreže, što je obveza Hrvatske kao članice EU, potrebno je razumjeti dinamiku i predvidjeti buduće ponašanje ekosustava ovog plitkog slatkovodnog jezera i kriptodepresije u neposrednoj blizini i u interakciji s morem. Svakom godinom sve smo više svjesni klimatskih promjena (trendovi smanjenja ukupne količine oborina, podizanja temperature zraka i podizanja razine mora) koje utječu na hidrološki režim i fizikalno-kemijske parametre jezera te posljedično i cijeli slatkovodni ekosustav. Rezultati dosadašnjih istraživanja provedenih na Vranskome jezeru dokazala su iznimnu osjetljivost Vranskoga jezera na nepovoljne hidrološke uvjete. Pokazalo se da postoje veliki rizici ugrožavanja opstojnosti jezera kao slatkovodnoga sustava, ukoliko se nastave dosadašnji negativni trendovi hoda oborina i temperature, dotoka u jezero te kolebanja razine jezera i mora (Rubinić, 2014).

Cilj ovoga rada je procijeniti i analizirati odnose koncentracije klorofila u Vranskome jezeru i spektralnih indeksa i kanala dobivenih iz podataka Landsat satelitske misije prikupljenih putem Google Earth Engine-a. Da bi se pronašao kvantitativno-prediktivni odnos između koncentracije klorofila i vegetacijskih indeksa usredotočili smo se na višestruku linearnu regresijsku analizu. Osim toga, cilj nam je kreirati prostornu raspodjelu koncentracije klorofila (za svaku Landsat satelitsku misiju) na Vranskome jezeru za pojedine datume kako bi na što bolji način prikazali rezultate istraživanja.

2. Materijal i metode

2.1. Područje istraživanja

Vransko jezero je najveće prirodno jezero u Hrvatskoj. Radi se o kriptodepresiji u kršu (dno jezera je na -3,47 m n.m.) koja je ispunjena blago zaslanjenom vodom (Slika 1). Jezero zauzima površinu od 30,2 km^2, dugo je 13,6 km, a široko 1,4-3,4 km. Pruža se u smjeru sjeverozapad-jugoistok i to paralelno s morskom obalom, a od mora je odijeljeno 800-2500 m širokim vapnenačkim grebenom čija je najviša nadmorska visina 113 m. Produljenoga je oblika, najpliće je u sjeverozapadnom dijelu (0,5-1 m), a prema jugoistočnom dijelu je dublje te doseže dubinu 4-6 m. Jezero je polimiktičko s obzirom na učestalost miješanja vodenog stupca. Vodostaj je promjenjiv i ovisi o količini oborina tijekom godine na cijelom slivnom području površine 515 km^2. Vodostaj jezera varira u rasponu od 2-4 m, s najvećim dotokom vode tijekom jeseni i zime što rezultira najvišim vodostajem u zimu i proljeće te najnižim vodostajem ljeti i u jesen. Strujanje vode u jezeru je posebno uzrokovano jugoistočnim i sjeveroistočnim vjetrovima koji stvaraju valove do jedan metar visine. S obzirom da nema vertikalne podjele tj. mali je stupac vode, konvekcijska strujanja vode nisu izražena. Voda jezera je podložna naglim promjenama temperature ovisno o temperaturi zraka zbog svoje plitkoće. Temperatura vode se kreće u rasponu od 2,9°C (veljača) do 25,2°C (srpanj). Povremeno dolazi do zamrzavanja površinskih slojeva vode i obale koju voda oplakuje zbog prodora polarnih zračnih masa. Rubni pojas oko ušća kanala i vrela nikad ne zaledi jer se temperatura kreće od 9,2 do 17°C (URL 2).

2.2. Terenski i satelitski podaci

U ovome radu uključeni su terenski podaci mjereni na dvije mjerne stanice smještene na Vranskome jezeru, a nose naziv Motel i Prosika. Podatke mjerenja s terena su ustupile Hrvatske vode, a uključuju koncentraciju klorofila izraženu u µg/l. Terenski podaci za stanicu Motel obuhvaćaju razdoblje mjerenja od svibnja 2005. godine do prosinca 2019. godine. Terenski podaci za stanicu Prosika obuhvaćaju razdoblje od rujna 2004. godine do lipnja 2018. godine s pauzom u razdoblju od travnja 2010. godine do travnja 2013. godine. Mjerenja nisu obuhvatila svaki mjesec u godini, već je posebni naglasak stavljen na mjerenja za vrijeme trajanja proljeća i ljeta. Na slici ispod prikazane su lokacije navedene dvije mjerne stanice (Slika 2).

Za svrhu rada prikupljene su satelitske snimke misije Landsat 5 pomoću platforme Google Earth Engine. Ukupno je prikupljeno 13 satelitskih snimki u razdoblju od +/-2 dana od datuma mjerenja na terenu za mjernu stanicu Motel, dok se za mjernu stanicu Prosika njih šest poklapa s datumom mjerenja na terenu.

Landsat 5 je lansiran iz zrakoplovne baze Vandenberg u Kaliforniji 01. ožujka 1984. godine. Poput Landsat 4 nosio je multispektralni skener (MSS) i tematski maper (TM). Landsat 5 je isporučio zemaljske satelitske snimke za gotovo 29 godina te je postavio Guinnessov svjetski rekord za 'Najdulji operativni sa-

Tablica 1: Landsat 5 spektralni kanali (URL 5)

Kanal	Valna duljina	Karakteristike
Kanal 1 – plavi	0,45-0,52	Batimetrijsko mapiranje, razlikovanje tla od vegetacije i listopadne od crnogorične vegetacije
Kanal 2 – zeleni	0,52-0,60	Naglašava vršnu vegetacije, pogodan za procjenu bujnosti biljaka
Kanal 3 – crveni	0,63-0,69	Diskriminira vegetacijske padine
Kanal 4 – NIR	0,77-0,90	Naglašava sadržaj biomase i obale
Kanal 5 – SWIR1	1,55-1,75	Diskriminira sadržaj vlage u tlu i vegetaciji; prodire u tanke oblake
Kanal 6 – termalni	10,40-12,50	Termičko mapiranje i procjena vlažnosti tla
Kanal 7 – SWIR2	2,09-2,35	Hidrotermalno izmijenjene stijene povezane s mineralnim naslagama

telit za promatranje Zemlje'. Za vrijeme trajanja njegovog snimanje prenio je preko 2,5 milijuna slika zemljine površine širom svijeta (URL 4). Landsat 5 sadrži sedam spektralnih kanala, uključujući termalni kanal. Kanali su prikazani u tablici 1.

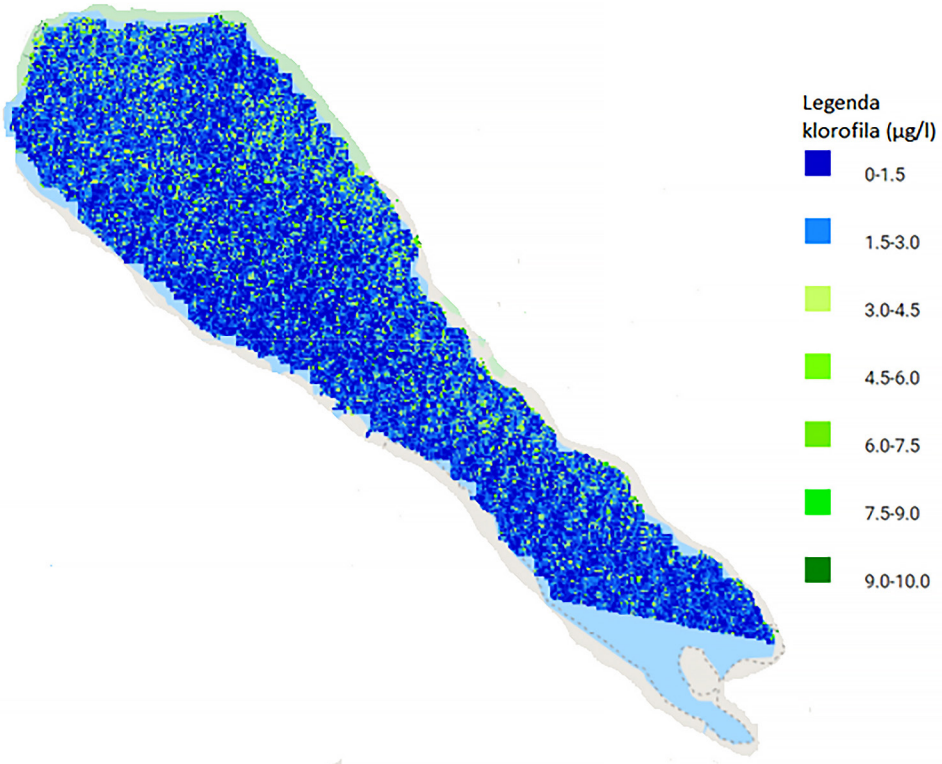
2.3. Metodologija istraživanja

Nakon prikupljanja satelitskih snimaka izdvojene su radiometrijske vrijednosti svih spektralnih kanala (Tablica 1) svakog snimka za lokacije mjernih postaja. Temeljem spektralnih kanala izračunato je i 10-ak različitih spektralnih indeksa svakog snimka poput vegetacijskog indeksa normalizirane razlike (NDVI – engl. Normalized difference vegetation index), zelenog vegetacijskog indeksa normalizirane razlike (GNDVI – engl. Green normalized difference vegetation index) i Indeks zelenog klorofila (CIgreen – engl. Chlorophyll Index Green) po uzoru na Rodriguez-Lopez i dr., 2020. Svi spektralni kanali i indeksi korišteni su za izradu regresijskog modela za procjenu koncentracije klorofila.

Rezultati dobiveni kombinacijom podataka satelitskih snimaka i podataka mjerenih na terenu imaju za cilj daljnju upotrebu u regresijskim analizama. Regresijska analiza je statistička tehnika procjene odnosa između dvije ili više varijabli koje su međusobno povezane. Glavni fokus regresijske analize je analizirati odnos između ovisne varijable i neovisne varijable te formulirati jednadžbu između ovisne i neovisne varijable. Regresijski model s jednom ovisnom i više neovisnih varijabli naziva se model višestruke regresijske analize (Uyanik, 2013). Podaci istraživanja su analizirani jednostavnom linearnom regresijskom analizom i višestrukom regresijskom analizom. Pomoću jednostavne linearne regresijske analize utvrđena je linearna povezanost koncentracije klorofila sa svim varijablama te kreirana matrica korelacije, dok su višestrukom regresijom kreirani modeli za izračun koncentracije klorofila za pojedinu satelitsku snimku koristeći se spektralnim indeksima i spektralnim kanalima.



Slika 2: Park prirode Vransko jezero u Dalmaciji (URL 3)



Slika 3: Prostorna raspodjela koncentracija klorofila procijenjena modelom za Landsat 5 satelitsku misiju za datum 12. siječnja 2005. godine (Kalaš 2021)

3. Rezultati

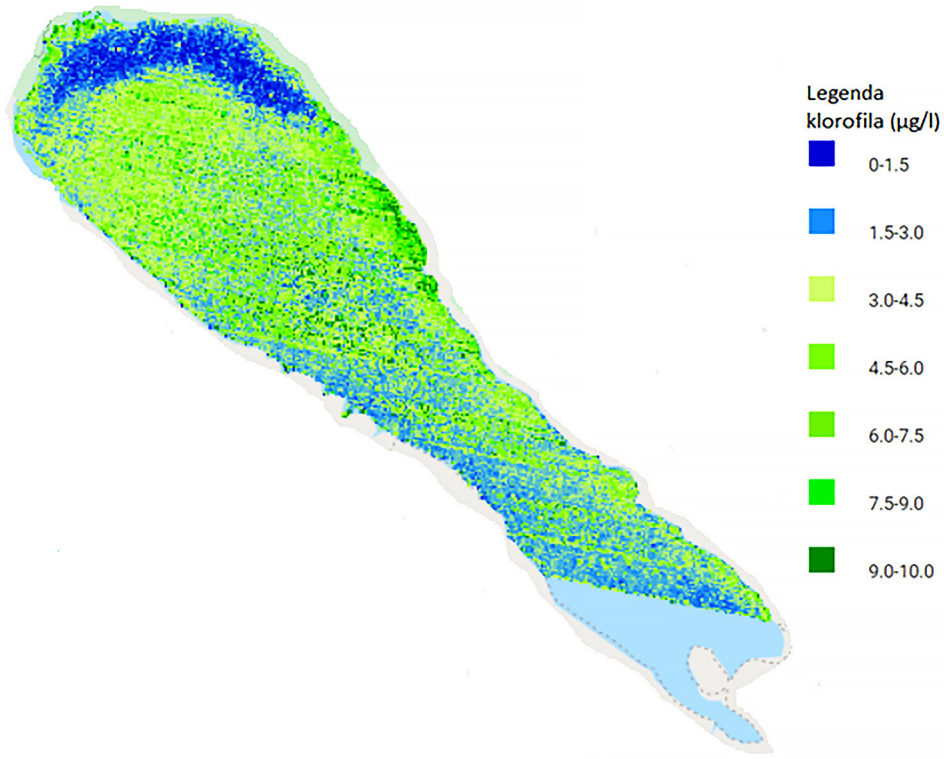
Za korištene Landsat 5 misije izračunate su koncentracije klorofila za postojeće satelitske snimke, izrađen graf kretanja koncentracija klorofila tijekom raspoloživog vremenskog perioda te prikazana prostorna raspodjela koncentracije klorofila procijenjena modelom. U nastavku je prikazana prostorna raspodjela koncentracije klorofila putem modela dobivenom višestrukom linearnom regresijskom analizom (Slika 3 i Slika 4). Izabrana su dva datuma po izboru i to jedan u zimskom (Slika 3), a jedan u ljetnom periodu (Slika 4) za bolju usporedbu.

Iz priloženoga možemo zaključiti da se u Vranskome jezeru nalaze veće koncentarcije klorofila za vrijeme ljetnoga perioda te posebno na sjeverozapadnom dijelu jezera. U nastavku je prikazan graf (Slika 5) vremenske raspodjele koncentracije klorofila tijekom nekoliko godina te su malim kružićima naznačeni datumi koje smo uzeli za primjer gore.

Slika 5: Graf vremenske raspodjele koncentracije klorofila za period od 2004. godine do 2011. godine za Landsat 5 satelitsku misiju (Kalaš 2021)

4. Zaključak

Predmet istraživanja ovog rada je analiza utjecaja klimatskih promjena na Vransko jezero u Dalmaciji s posebnim naglaskom na praćenje koncentracije klorofila u Vranskome jezeru na temelju terenskih mjerenja i mjerenja dobivenih pomoću satelitskih snimki Landsat misije. Kako bi zaštitili posebno vrijedne vodne resurse poput ovoga potrebno ih je analizirati kao dinamičke sustave kako bi razumjeli njihovo djelovanje te predvidjeli ponašanje u novim uvjetima. Sukladno tome, u ovome radu smo pratili promjene u koncentraciji klorofila u rasponu od nekoliko godina te pratili razlike u koncentraciji u ovisnosti o mjesecu u godini. Cilj ovoga rada bio je razvoj modela za izračun koncentracije klorofila pomoću spektralnih indeksa i kanala temeljenog na primjeni višestruke linearne regresijske analize. Nadalje izrađene su karte prostorne raspodjele koncentracije klorofila u Vranskome jezeru u Dalmaciji. Vransko jezero je zaštićeno kao Park prirode i nalazi se na popisu međunarodno važnih vlažnih područja (Ramsarski popis) te je potrebno na vrijeme prepoznati djelovanje klimatskih promjena kako bi ga se moglo zaštititi od negativnih učinaka istih prilagodbom upravljačkih aktivnosti. Važnost ovoga dijela rada je u otkrivanju područja u jezeru s najvećom koncentracijom klorofila te utvrđivanjem potreba za dodatnim terenskim mjerenjima na tome području. Osim izrade karte, izrađen je i graf s koncentracijom klorofila u rasponu od nekoliko godina. Izradom grafa vremenske raspodjele koncentracije klorofila u jezeru utvrdili smo da su najveće koncentracije klorofila prisutne za vrijeme ljetnih mjeseci kada su temperature vrlo visoke te nastupa suša. Ovim radom potvrđena je mogućnost primjene besplatno dostupnih satelitskih snimaka misije Landsat u svrhu provedbe analize utjecaja klimatskih promjena na Vransko jezero u Dalmaciji te izrade karata koncentracije klorofila metodama daljinskih istraži-



Slika 4: Prostorna raspodjela koncentracija klorofila procijenjena modelom za Landsat 5 satelitsku misiju za datum 24. kolovoza 2005. godine (Kalaš 2021)

vanja. Navedena metodologija može se primijeniti i na drugim lokacijama kako u Republici Hrvatskoj tako i u svijetu. Ovim radom prikazan je razvoj novih metoda daljinskih istraživanja u svrhu širenja primjene geodezije u ekologiji i očuvanju okoliša.

Literatura

Allan, M.G., Hamilton, D.P., Hicks, B.J., Brabyn, L. (2011): Landsat remote sensing of chlorophyll a concentrations in central North Island lakes of New Zealand. International Journal of Remote Sensing, 32(7), 2037-2055.

Kalaš, M. (2021): Analiza utjecaja klimatskih promjena na Vransko jezero u Dalmaciji, Sveučilište u Zagrebu – Geodetski fakultet, Zagreb.

Rodriguez-Lopez, L., Duran-Llacer, I., Gonzalez-Rodriguez, L., Abarca-del-Rio, R., Cardenas, R., Parra, O., Martinez-Retureta, R., Urrutia, R. (2020): Spectral analysis using LANDSAT images to monitor the chlorophyll-a concentration in Lake Laja in Chile. Ecological Informatics, 60, 101183.

Rubinić, J. (2014): Vodni režim Vranskog jezera u Dalmaciji i klimatski utjecaji. Građevinski fakultet sveučilišta u Rijeci, Rijeka.

Tebbs, E.J., Remedios, J.J., Harper, D.M. (2013): Remote sensing of chlorophyll-a as a measure of cyanobacterial biomass in Lake Bogoria, a hypertrophic, saline-alkaline, flamingo lake, using Landsat ETM+. Remote Sensing of Environment, 135, 92-106.

Uyanik, G.K., Guler, N. (2013): A study on multiple linear regression analysis. Procedia-Social and Behavioral Sciences, 106, 234-240.

URL 1: Klorofil, https://www.enciklopedija.hr/natuknica.aspx?id=31988, (10.06.2022.).

URL 2: Park prirode Vransko jezero, http://www.pp-vransko-jezero.hr/hr/karakteristike-jezera/, (11.06.2022.).

URL 3: Vransko jezero (Dalmacija), https://hr.wikipedia.org/wiki/Vransko_jezero_(Dalmacija), (12.06.2022.).

URL 4: U.S. Geological Survey, https://www.usgs.gov/core-science-systems/nli/landsat/landsat-5?qt-science_support_page_related_con=0#qt-science_support_page_related_con, (12.06.2022.).

URL 5: U.S. Geological Survey, https://www.usgs.gov/faqs/what-are-best-landsat-spectral-bands-use-my-research?qt-news_science_products=0#qt-news_science_products, (12.06.2022.).

URL 6: L3 Harris Geospatial documentation center, https://www.l3harrisgeospatial.com/docs/NarrowbandGreenness.html#Modified2, (17.06.2022.).

Influence Analysis of the Climate Changes on Vransko Lake in Dalmatia

Abstract

This research is based on the development of remote sensing methods for spatio-temporal monitoring of the concentration of the green pigment chlorophyll based on Landsat satellite imagery in the area of Lake Vrana in Dalmatia. To effectively manage the target habitat types and species of the ecological network, it is necessary to understand the dynamics and predict the future behavior of the ecosystem of this shallow freshwater lake and cryptodepression in close proximity and interaction with the sea. Every year we become more and more aware of climate change affecting Lake Vrana, influencing the hydrological regime and physico-chemical parameters of the lake and consequently the entire freshwater ecosystem. By taking water samples and monitoring the chlorophyll concentration in the water, the biomass of phytoplankton is determined, which is one of the four mandatory biological quality components for the assessment of the ecological status of the water. Phytoplankton biomass is a good indicator of anthropogenic impacts because it responds rapidly to ecosystem loading of nutrients (from agriculture and wastewater), which is very pronounced seasonally, especially in conjunction with higher water temperatures. Remote monitoring of chlorophyll concentrations over an extended period of time makes it possible to monitor changes in the spatio-temporal distribution of phytoplankton and, indirectly, the effects of climate change, while developing a system for early detection of excessive critical chlorophyll concentrations in lake ecosystems. The method for estimating chlorophyll concentrations is based on data from satellite imagery and manual measurements of chlorophyll in water, and was developed by comparing measured chlorophyll concentration values and a series of spectral indices and channels from the Landsat satellite mission from 2004 to 2011. The developed method was used to create a map of the spatial distribution of chlorophyll concentrations in the lake, and it was found that the greatest concentrations of chlorophyll are present at higher temperatures when there is greater development of phytoplankton.

Keywords: *chlorophyll; geodesy; Landsat; modelling; remote sensing*

Promjena u opsegu vodenih ekosustava tijekom vremena

Natalija Matić[1], Nikola Vučić[2]

[1] Hrvatske vode, Ulica grada Vukovara 220, Zagreb, Hrvatska, nmatic@voda.hr

[2] Državna geodetska uprava, Gruška 20, Zagreb, Hrvatska, nikola.vucic@dgu.hr

Sažetak

Prema globalnom pokazatelju Cilj 6 Agende za održivi razvoj do 2030. godine koji se odnosi na „Osigurati pristup pitkoj vodi za sve, održivo upravljati vodama te osigurati higijenske uvjete za sve" kroz podcilj 6.6. „Promjena u opsegu vodenih ekosustava tijekom vremena" i Indikatoru 6.6.1 „Kako i zašto se ekosustavi s vremenom mijenjaju u opsegu" kojeg je definirala Statistička komisija Ujedinjenih naroda, potrebno je zaštititi i vratiti ekosustave vezane uz vode, uključujući planine, šume, močvare, rijeke, vodonosnike i jezera. U radu se razmatra suradnja geodetske i hidrogeološke struke za potrebe praćenja postotka promjene ekosustava vezanih uz vodu tijekom vremena. Ove informacije važne su za formiranje baza podataka koje omogućavaju donošenje odluka o zaštiti i obnovi ekosustava povezanih s vodom. U Hrvatskoj do sada nije bilo sustavnog praćenja takvih promjena i proizvodnje podataka o tomu, no potrebe za sustavnim praćenjem su nužne te će pridonijeti bazi nacionalnih podataka uz mogućnost utvrđivanja utjecaja klimatskih promjena na ekosustave. Rad prikazuje kako integrirani i holistički pristup različitih struka može pridonijeti cilju održivog razvoja 6.6.1.

Ključne riječi: *Agenda za održivi razvoj do 2030., geodezija, hidrogeologija*

1. Uvod

Održivi razvoj je izazov 21. stoljeća. Ukupno 193 države članice Ujedinjenih Naroda (UN) usvojile su u rujnu 2015. godine dokument pod nazivom „Transformacija našeg svijeta: Program 2030 za održivi razvoj" (Agenda do 2030.), i s njime povezanim 17 globalnih ciljeva održivog razvoja (COR) i 169 podciljeva. Prethodili su im Milenijski ciljevi održivog razvoja za nerazvijene zemlje koji su sada kvantificirani i vremenski ograničeni. Program 2030 za održivi razvoj je dokument koji predstavlja univerzalni i interdisciplinarni okvir za promicanje blagostanja ljudi i planeta (URL 1). Prema Akcijskom planu za implementaciju COR (engl. SDG) pokazatelja, ključnu ulogu u osiguravanju podataka za praćenje i pregled COR i s njima povezanim podciljevima ima Nacionalna Statistička institucija koja koordinira i podacima za izvješćivanje svih 17 globalnih ciljeva i 169 podciljeva. Nacionalna statistička institucija osim što izvješćuje o ciljevima održivog razvoja ima ulogu i davanja podloga u smislu podataka i statistike za mjerenje napretka u postizanju globalnih ciljeva i podciljeva održivog razvoja (Slika 1, URL 2). Za hidro struke (hidrolozi, hidrogeolozi, hidromorfolozi, hidrogeografi itd.) najvažniji je globalni cilj održivog razvoja 6 (COR 6 „Osigurati pristup pitkoj vodi za sve, održivo upravljati vodama te osigurati higijenske uvjete za sve"). U ovom radu naglasak se daje na Podcilj 6.6. „Promjena u opsegu vodenih ekosustava tijekom vremena" i Indikator 6.6.1 „Kako i zašto se ekosustavi s vremenom mijenjaju u opsegu". I ovaj Cilj, Podcilj i Indikator definirala je Statistička komisija Ujedinjenih Naroda prema Agendi do 2030. godine, pri čemu je potrebno zaštititi i vratiti ekosustave vezane uz vode, uključujući planine, šume, močvare, rijeke, vodonosnike i jezera. Hidro struke su jedne od rijetkih struka koje imaju svoj cilj održivog razvoja (COR) u ovom slučaju COR 6 (SDG 6) o kojemu brinu, a sve ostale struke im pomažu u tome. Kako je navedeno u Rezoluciji XIII. 7 Ramsarske konvencije o močvarnim područjima, Tajništvo kao su-čuvar pokazatelja održivog razvoja 6.6.1 doprinosi tom pokazatelju podacima iz nacionalnih izvješća koja se temelje na Ramsarovim definicijama i zahtjevima (Convention on Wetlands, 2021a) u bazu podataka ciljeva održivog razvoja čiji je koordinator Odjel UN-a za statistiku. Konvencija i UNEP (UN SDG, 2018), kao su-skrbnici za pokazatelj održivog razvoja 6.6.1. su odgovorni za svoje linije izvješćivanja i zajednički doprinose cilju održivog razvoja 6.6.1. (URL 3). Za potrebe izvješćivanja prema UN za globalni pokazatelj 6.6.1. u Hrvatskoj do sada nije bilo dostupnih podataka o promjeni u opsegu vodenih ekosustava tijekom vremena. Proizvođači podataka do sada su procjenjivali te vrijednosti jer preciznih sustavnih mjerenja nije bilo kao ni programa i plana sustavnog praćenja i unošenja u bazu podataka.

Da bi se riješio ovaj izazov u svijetu iniciran je projekt primjerice SWOS projekt financiran putem Horizon 2020 (URL 4). SWOS (Satellite-based Wetland Observation Service) se temelji na praćenju močvarnih područja putem satelita. Alati za praćenje koji su razvijeni u okviru SWOS projekta imaju za cilj pomoći zemljama u inventarizaciji nacionalnih močvarnih područja za obveze izvješćivanja i praćenja ciljeva održivog razvoja te dodatno olakšava druge obveze praćenja, poput onih propisanih Ramsarskom



Slika 1: Ciljevi održivog razvoja (izvor: URL 2).

konvencijom uz donošenje odluka o lokalnim aktivnostima zaštite. Projekt se sastoji od izrade karata i pokazatelja; razvoja softvera; izgradnje kapaciteta i inicijalizacije GEO portala močvarnih područja za dionike. Korištenje slobodno dostupnih robusnih i standardiziranih resursa za promatranje Zemlje (Earth Observation – EO) i satelitskih podataka Sentinel iz programa Copernicus, kao i arhiva Landsat, pružaju osnovu za kartiranje i inventarizaciju močvarnih područja, dobivanje informacija o ekološkom stanju, kao i dugoročnim i kratkoročnim trendovima u obilježjima močvarnih područja. Međutim, njihovo korištenje zahtijeva stručno znanje o često složenim tehnikama obrade podataka što opet usporava praktično korištenje sustava (Weise i dr., 2020).

U Hrvatskoj je u provedbi projekt LIFE CROLIS (LIFE program) sufinanciran EU sredstvima. LIFE CROLIS (Hrvatski zemljišni informacijski sustav LIFE19 GIC/HR/001270) koji pomaže u ispunjavanju UN Ciljeva održivog razvoja uspostavom jedinstvenog informacijskog sustava zemljišta RH uz definiranje površina pojedine kategorije iz domene Korištenja zemljišta, prenamjene zemljišta i šumarstva (engl. *Land Use, Land-Use Change and Forestry* – LULUCF) te upotrebom prostorno točno utvrđenih podataka za svaku kategoriju zemljišta i za svaku vrstu prenamjene zemljišta iz jedne kategorije zemljišta u drugu (URL 4). S obzirom na navedeno ovo je prilika da se precizno utvrde površine vodenih ekosustava i njihove promjene u opsegu tijekom vremena za potrebe izvješćivanja cilja održivog razvoja 6.6.1.

Kako bi se postigli ciljevi održivog razvoja, svaki pojedinac treba steći znanja o održivom razvoju, globalnom građanstvu i vještinama 21. stoljeća koje su ključne za rješavanje zajedničkih globalnih izazova i promicanje budućnosti pravednih, uključivih i otpornih društava. Uz obrazovanje koje je ključni pokretač ove transformacije, primjenu interdisciplinarnog pristupa, saznanja o prijetnjama poput klimatskih promjena i prilagodbi, suočavanje s do sada nepredvidivim složenim i prekograničnim izazovima poput brze degradacije zemljišta, staništa i biološke raznolikosti, rastuće urbanizacije itd. u sinergiji utječu na ekosustave (UN SDG, 2018).

Nadalje, proizvodnja podataka o promjenama u opsegu vodenih ekosustava tijekom vremena je potrebna za planske dokumente zaštite prirode i okoliša. Osim toga planere zanima i distribucija zelenih površina, broj vrsta (bioraznolikost) koje su rasprostranjene na površinama, koliko se mogu širiti gradovi, koliko je moguće skladištenje CO_2 s obzirom na klimatske promjene u adaptaciju, koliko oborina mogu prihvatiti močvarna područja budući znamo njihovu ulogu spužve za potrebe skladištenja CO_2 u tresetištu, vodi i sedimentu kao i skladištenje oborina i dreniranju u vodonosnike itd. Za znanstvenike vrlo su bitna rješenja temeljena na prirodi (engl. *nature-based solutions*). U kontekstu navedenoga hidrogeolozi zajedno s hidrolozima i drugim hidro inženjerima imaju svoj cilj održivog razvoja 6 o kojemu brinu dok većina drugih struka poput geodeta, kemičara i drugih struka imaju ulogu potpore i podrške hidro strukama u smislu aktivnog poticanja i poboljšane razmjene podataka. Najznačajnija su terestrička i satelitska snimanja i mjerenja te praćenja uz sustavno formiranje baze podataka. Da bi sve te izazove nadišli nije više moguće raditi poslove kao obično (*business as usual*) zbog heterogenosti sustava znanja. U situacijama kada postoji konkurencija oko korištenja zemljišta (npr. poljoprivreda, biološka raznolikost, šumarstvo, urbano zemljište), korištenje vizualne karte i skupovi podataka s različitim slojevima također pružaju korisno sredstvo za izgradnju zajedničkog razumijevanja i pronalaska rješenja. Ključno je izgraditi povjerenje među strukama, objediniti stručno znanje iz različitih disciplina i ubrzati proces donošenja dobrih političkih odluka koje će očuvati planetu Zemlju. Također treba intenzivirati interdisciplinarna istraživanja u praktičnim područjima kako bi se dobilo jasnije razumijevanje ciljeva održivog razvoja, za osmišljavanje

putova transformacije u konkretne kontekste i pružiti dokaze o rješenjima i intervencijama koje djeluju. Konvencionalne znanstvene modele potrebno je nadopuniti drugim oblicima znanja, kao što su tradicionalno, kulturno i praktično znanje uz formate i forume koji potiču veću širinu i integraciju istraživanja u različitim disciplinama s naglaskom na pronalaženju rješenja za složene izazove.

2. Karakteristike močvarnih područja

Močvare su zadnjih godina dobile na značaju u okviru pristupa rješenja temeljena na prirodi (engl. *nature based solutions*) pa se uz pošumljavanje kao najčešću aktivnost sve češće obnavljaju močvare. Sastoje se od mozaika različitih staništa, štite obale, održavaju rijeke i podzemne vode čiste u smislu visoke kakvoće i pohranjuju velike količine ugljika koje sudjeluju u promjeni klime, predstavljaju genetske resurse, kulturne vrijednosti itd. Prema definiciji močvare su plitke vode stajaćice, odnosno tlo zasićeno slatkom ili slanom vodom, kontinuirano ili sezonski, tako da poprimaju karakteristike zasebnog ekosustava. Odlikuje se niskom pH vrijednošću (odnosno kiselošću) i bioraznolikošću staništa za mnoge biljne i životinjske vrste. Prema procjenama znanstvenika sve močvare pa tako i one najmanje sadrže pohranjene velike količine ugljika u obliku treseta ili poluraspadnutog biljnog materijala. Često se radi o količinama s više milijuna tona. Kopnena močvarna područja uključuju jezera i rijeke, podzemne vode ili vodonosnike, močvare, vlažne travnjake, tresetišta, poplavne ravnice i oaze. Uključuju i močvarna područja koja je stvorio čovjek primjerice rižina polja, slane površine i poljoprivredne ribnjake. Obalna močvarna područja uključuju ušća, delte i plimne površine, šume mangrova i obalna morska područja kao i koraljne grebene (Convention on Wetlands, 2021b). Višestruke pogodnosti i usluge koje pružaju močvarna područja (Davidson i dr., 2019) ključne su u postizanju ciljeva održivog razvoja s naglaskom na važnost očuvanja, održive uporabe i obnavljanje ovog resursa. Močvare su pouzdan izvor čiste površinske i podzemne vode za piće te vode za navodnjavanje osobito u vrijeme suša (UN SDG, 2018). Isušivanjem tresetišta za potrebe širenja plodnog poljoprivrednog zemljišta ili njegovom ekstrakcijom za kompost, vegetacija se razgrađuje brže oslobađajući ugljik u atmosferu. Na taj se način oslobađa više stotina tisuća tona CO_2 po godini. Stoga je zaštita močvara važna ako se želi postići cilj nulte neto stope emisije CO_2 do 2030. kao ambiciozni globalni strateški cilj (URL 5). Pravilno upravljanje močvarama bez obzira na njihove dimenzije može dati veliki doprinos prema Agendi održivog razvoja do 2030., ali širenjem močvara može se kontrolirati kakvoća i utjecati na količinu površinske i podzemne vode, biološku raznolikost, smanjiti emisije ugljika i poboljšati vlastita dobrobit koristeći potencijal "prirodnih rješenja" koji omogućuje prirodnim ekosustavima pomoć u rješavanju klimatske krize kao i prilagodbu na krizu te rješavanje krize biološke raznolikosti. Održivo korištenje močvarnih područja prema Ramsarskoj konvenciji o močvarnim područjima kao i tzv. Aichi ciljevi ili ciljevi definirani u Strateškom planu Konvencije o biološkoj raznolikosti direktno utječu na postizanje ciljeva održivog razvoja. Obzirom da se gotovo sva svjetska potrošnja slatke vode crpi izravno ili neizravno iz močvarnih područja, močvarna područja direktno podržavaju postizanje ciljeva održivog razvoja COR 1, COR 2, COR 5, COR 6, COR 8, COR 9, COR 11, COR 13, COR 14 i COR 15, a indirektno i svih ostalih ciljeva održivog razvoja (UN SDG, 2018).

3. Uloga močvara

Različite vrste koristi mogu biti povezane sa zaštitom močvarnih područja primjerice ekološke, ekonomske, obrazovne, društvene, rekreativne ili estetske. Sljedeće aktivnosti pomažu smanjenju gubitka i stvaranju dobitka u prirodnim močvarama i njihovim povezanim funkcijama i utjecajima: pomažu u poboljšanju kvalitete i kvantitete vode, mogu smanjiti i usporiti otjecanje površinske vode do vodotoka i ukloniti onečišćujuće tvari fizičkim, kemijskim i biološkim procesima. Poznato je da močvare uklanjaju veliku količinu onečišćujućih tvari iz sliva ekvivalentno onoj koju bi uklonio uređaj za pročišćavanje otpadnih voda. Ključna su purifikacijska svojstva, ali imaju i funkciju filtera. Močvarna područja pružaju isplativu alternativu tradicionalnim mogućnostima pročišćavanja otpadnih i oborinskih voda. Imaju pozitivnu ulogu u opskrbi vodom služeći kao rezervoar za sliv i ispuštajući zadržanu vodu u površinske i podzemne vode. Pomažu u smanjenju amplitude velikog vodnog vala (poplava) prihvaćanjem, upijanjem i skladištenjem velike količine oborina. One prihranjuju podzemne vode pogotovo u vrijeme velikih suša. Močvare pomažu u kontroli erozije. Obalna močvarna područja, slane močvare i močvare smještene na rubovima jezera štite obale i obale vodotoka od erozije. Korijeni močvarnih biljaka drže tlo na mjestu i mogu smanjiti brzinu strujanja vodotoka. Močvare mogu poboljšati staništa za sve vrste biljnog i životinjskog svijeta poboljšavajući bioraznolikost i krajobraznu raznolikost. Močvarna područja pružaju stanište više od 40% vrsta biljaka i životinja, međutim to su i najugroženiji ekološki sustavi. U posljednjih 50 godina izgubljeno je 50% svih močvarnih staništa u svijetu. Močvarna područja su genske banke biološke raznolikosti staništa brojnih biljnih i životinjskih vrsta. Mogu se koristiti u rekreativne svrhe i postati odredište za aktivnosti na otvorenom kao što su planinarenje, ribolov, promatranje ptica, fotografiranje i lov. Zaštita močvarnih područja može omogućiti zajednicama, pojedincima, organizacijama i drugima izgradnju partnerstva kroz aktivnosti zaštite i pružati različitim subjektima pristup podacima i resursima koji inače ne bi bili dostupni (UN SDG, 2018). Prema Ramsarskoj konvenciji obveza je svake zemlje potpisnice na opće očuvanje močvara na vlastitom teritoriju i ona predstavlja okvir za međunarodnu suradnju u zaštiti i održivom korištenju močvarnih staništa. Hrvatska je potpisnica Ramsarske konvencije od 1991 godine, a na Ramsarskom popisu su parkovi prirode Kopački rit, Lonjsko polje i Vransko jezero te ribnjaci Crna Mlaka u Jastrebarskom i Donji tok Neretve (Convention on We-

tlands, 2021c). Aktivnosti zaštite močvarnih područja pružaju značajne mogućnosti za edukaciju javnosti o znanosti o močvarnim područjima, zaštiti močvarnih područja i vrijednosti vodnih resursa. Močvarna područja pružaju određenu vizualnu vrijednost i često su ugrađena kao značajke u krajobraznom dizajnu. Ona su najproduktivniji i najdinamičniji ekosustavi, na koje kontinuirano utječe društveni i gospodarski razvoj. Kao rezultat toga, onečišćenje močvarnih površinskih i podzemnih voda u susjednim regijama postalo je novonastalo globalno pitanje koje zahtijeva stalno praćenje i procjenu. Koraljni grebeni, šume mangrova, slane močvare koriste se u zaštiti i smanjenju visine i snage valova, smanjenju olujnih udara i upijanju dijela viška vode. Močvarna područja služe kao uzvodni bazeni za zadržavanje vode i sprječavaju poplave u gradovima nizvodno. Borba protiv klimatskih promjena zahtijeva sveobuhvatan i višestruki strateški pristup. Močvarna tla sadrže više od trećine (35%) svjetskog organskog ugljika. Obalni ekosustavi, šume mangrova, slane močvare i morske trave odvajaju dva do četiri puta više ugljika od kopnenih šuma i "ekosustavi plavog ugljika" imaju važnu ulogu u oslabljenju klimatskih promjena. Ovaj ugljik se dugoročno skladišti u močvarnim tlima. Sprečavanje daljnje degradacije, dreniranje i gubitak ekosustava močvarnih područja ključni su za sprečavanje daljnjih emisija CO_2. Tresetišta iako čine samo 3% Zemljine površine, drže dvostruko više ugljika nego svjetske šume. Gubeći močvarišta doprinosimo klimatskim promjenama no obnavljajući ih smanjujemo uzroke klimatskih promjena. Isušena tresetišta mogu značajno smanjiti emisije CO_2 i razviti nove oblike održive poljoprivredne proizvodnje (UN SDG, 2018; Convention on Wetlands, 2021a, c).

4. Primjeri dobre prakse mjerenja promjena u opsegu vodenih ekosustava u Hrvatskoj

U Hrvatskoj do sada nije bilo sustavnog mjerenja promjena u opsegu vodenih ekosustava tijekom vremena. Međutim, mjerenja izvedena u okolici Grada Velike Gorice na jezerima Novo Čiče, Donja Lomnica i Brodec doprinijet će bazi podataka iako se ne radi o močvarama prema Ramsarskoj konvenciji, ali u budućnosti podaci bi mogli poslužiti kao mjerljivi pokazatelji promjena u prirodi i okolišu. Tako je Grad Velika Gorica u suradnji s Geodetskim fakultetom proveo snimanje dubina i pokosa jezera za potrebe Prostornog plana uređenja Grada Velike Gorice i Urbanističkog plana uređenja ŠRC jezera Novo Čiče. Nakon izvedenih geodetskih mjerenja hidrografskom i aerofotogrametrijskom metodom, izrađene su batimetrijske karte jezera u webGIS-u. Navedeni setovi i baze podataka primjer su dobre prakse koji će dugoročno moći koristiti za monitoring kako klimatskih promjena i prilagodbe tim promjenama tako i drugih promjena za različite namjene. Mjerenjima jezera Novo Čiče na 100 m n.m. i dubine od 38 m na nekadašnjem eksploatacijskom polju "Novo Čiče – Velkom". Na temelju podataka o dubinama izrađena je batimetrijska karta s prikazanim dubinama jezera (URL 6). Jezero nastalo eksploatacijom šljunka s potencijalom za uređenje je jezero Donja Lomnica dubine od 26 m. Batimetrijska karta s prikazom dubina u webGIS-u (URL 7) dok je jezero Brodec s dubinom od 2 m i batimetrijskom kartom prikazano u webGIS-u (URL 8). Osim geodetskih mjerenja izvedena su i istraživanja kakvoće vode te je utvrđeno postojeće stanje voda pomoću fizikalno-kemijskih i bioloških parametara. Voda odgovara zahtjevima I. ili II. kategorije voda sukladno Uredbi o standardu kakvoće voda te su one u vrlo dobrom ili dobrom stanju. Vrijednosti fizikalno-kemijskih elemenata te koncentracije hranjivih tvari za akvatičke sustave ne prelaze vrijednosti određene da osiguraju funkcioniranje ekosustava i postizanje vrijednosti određenih za biološke elemente kakvoće. Na temelju ovoga primjera prikazana je suradnja hidro struka i geodeta uz integrirani pristup rješavanju problema.

Nadalje, vrlo vrijedan primjer projekta gdje hidro struke i geodeti surađuju je LIFE projekt CROLIS sufinanciran sredstvima EU. Bavi se razvojem usklađenog podatkovnog modela za praćenje tla koji će omogućiti integraciju i procesuiranje pokrova i namjene tla, podataka o upravljanju tlom iz različitih izvora i njegove uporabe u različite svrhe. Projekt pomaže Hrvatskoj u ispunjavanju budućih međunarodnih i europskih ciljeva: UN Ciljeva održivog razvoja te regulacija EU za ruralni razvoj, očuvanje prirodnih staništa i mnogih drugih. Projektom CROLIS (Croatian Land Information System) razvit će se i uspostaviti prvi višestruki i višenamjenski usklađeni sustav praćenja zemljišta koji omogućuje integraciju i obradu podataka o pokrovu, korištenju i upravljanju zemljištem. Ovaj pilot projekt koristit će se za demonstraciju tehničkih rješenja za složene probleme konzistentnog, točnog i potpunog praćenja zemljišta (land monitoring) i kao takav jedinstven je u EU. Neki od rezultata projekta će biti smanjenje emisija stakleničkih plinova i primjena mjera definiranih u okviru tzv. "scenarija ublažavanja klimatskih promjena". Utjecaj CROLIS-a na smanjenje emisija stakleničkih plinova očekuje se pet godina nakon uspostave CROLIS-a kad će CROLIS već biti korišten kao alat za planiranje mjera ublažavanja klimatskih promjena. Cijelo kopneno područje Republike Hrvatske bit će uključeno u usklađeni informacijski sustav praćenja zemljišta te će, kao rezultat toga, biti dobivene nove informacije o povezanosti hrvatskih praksi upravljanja zemljištem i emisijskih faktora. Također će pomoći u uvođenju praksi upravljanja zemljištem s nižim emisijama stakleničkih plinova te konačno pomoći u postizanju smanjenja emisija CO_2 do 2030. godine. Trenutno u Republici Hrvatskoj ne postoji institucija koja raspolaže podacima o pokrovu i korištenju zemljišta te upravljanju zemljištem i to podacima za sve kategorije zemljišta. CROLIS će povećati broj relevantnih institucija koje će biti uključene u *Land Parcel Identification System* (LPIS), to jest hrvatski ARKOD, omogućit će bolje planiranje mjera ublažavanja klimatskih promjena i bolje upravljanje područjem mreže NATURA2000 u Republici Hrvatskoj na taj način pomažući očuvanje bioraznolikosti. Bit će moguća izrada planskih dokumenata na nacionalnoj, regionalnoj i lokalnoj razini, dokumenata prostornog uređenja, zahvaljujući po-

boljšanoj kvaliteti prostornih podataka o zemljištu u Republici Hrvatskoj (URL 9).

Projekt NATURAVITA "Razminiranje, obnova i zaštita šuma i šumskog zemljišta u zaštićenim i Natura 2000 područjima u dunavsko-dravskoj regiji" je jedan od najvećih projekata zaštite prirode u Republici Hrvatskoj, a koji je sufinanciran sredstvima EU. Na dijelu Parka prirode Kopački Rit izvode se složena hidrogeološka istraživanja koja uključuju i mjerenja uz podršku geodeta pri čemu su uz batimetrijska mjerenja močvarnog područja korištene i druge geodetske metode (URL 10). Projekt VEPAR (vodno ekološko praćenje, analize i rješenja) usmjeren je na provedbu mjera za unaprjeđenje upravljanja rizicima od poplava, a sufinancira se EU sredstvima. Provodi se na cijelom području RH. Provedbom Projekta osiguravaju se i sistematiziraju hidrološki i morfološki podaci o slivovima koji nedostaju, vodotocima, regulacijskim i zaštitnim vodnim građevinama, modernizira se i dograđuje mreža hidroloških mjernih postaja, poboljšavaju prognostički modeli itd. (URL 11). Iz navedenih projekata razvidno je da su hidro struke one koje brinu o COR 6, a ostale struke među kojima se posebno ističe geodetska struka pružaju podršku. Budući da nema sustavnih mjerenja opsega vodenih ekosustava tijekom vremena, a monitoring opsega vodenih ekosustava tijekom vremena se tek uspostavlja, stoga će se tek u budućnosti pokazati mijenja li se površina ekosustava ovisnih o vodama i za koliko. Ukoliko će se površina tijekom vremena smanjivati sve naše aktivnosti neće doprinijeti smanjenju utjecaja klimatskih promjena, odnosno CO_2 će se više emitirati što neće pridonijeti postizanju cilja COR 6.6.1. Budući da nema preciznih mjerenja, odnosno ona su u tijeku, kao i praćenja tih promjena može se samo uz pomoć usporedbe arhivskih karata i današnjih snimaka utvrditi da se te površine tijekom vremena smanjuju ili povećavaju ovisno o poplavama ili sušama. Navedenim usporedbama se zasada dolazi do općih zaključaka smanjenja ili povećanja opsega vodenih ekosustava tijekom vremena (URL 12), ali nije moguće precizno utvrditi za koliko. Po završetku navedenih projekata biti će moguće doći do točnih podataka o promjenama u opsegu vodenih ekosustava tijekom vremena.

5. Zaključak

Ciljevi održivog razvoja prilika su za holistički pristup uz integrirani način rješavanja izazova vezanih za zaštitu močvarnih područja. Oni omogućavaju da se brojne obaveze iz sporazuma o okolišu Ramsar, Okvirna konvencija Ujedinjenih naroda o klimatskim promjenama (UNFCCC), Konvencija za borbu protiv dezertifikacije (UNCCD i Konvencija o biološkoj raznolikosti (CBD) koriste za potrebe postizanja COR-a. Do sada je u Hrvatskoj uspostavljeno sustavno praćenje površinskih i podzemnih voda odnosno ekosustava povezanih s vodom i njihovih fizikalno-kemijskih parametara koje se nalaze u bazi podataka Hrvatskih voda i Ministarstva gospodarstva i održivog razvoja. Međutim sustavnog praćenja promjena u opsegu vodenih ekosustava tijekom vremena do sada nije bilo. Iz primjera koje smo naveli u ovome radu vidljivo je da se na tome intenzivno radi i da se dio aktivnosti se sufinancira EU sredstvima. Kontinuiranom suradnjom hidro struka i geodeta te mjerenjima na terenu moguće je uspostaviti sustavni monitoring i bazu podataka. Prvi rezultati mjerenja neće odmah dati promjene površina ekosustava u vremenu, ali dugoročno će biti vrlo interesantni naročito znanstvenicima koji se bave zaštitom prirode. Razlog tome je što su i prirodni i antropogeni procesi koji utječu na promjenu opsega površina spori, u smislu da mogu trajati više godina pa i desetljeća. Kako su zadnjih desetljeća klimatske promjene sve intenzivnije vjerojatno će se i njihov utjecaj brže odraziti na osjetljive ekosustave kao što su močvarna područja i što će biti vidljivo i mjerljivo kroz promjenu u opsegu vodenih ekosustava tijekom vremena. Rezultati će biti korisni za potrebe izvještavanja cilja održivog razvoja 6.6.1.

ZAHVALA. Zahvaljujemo na pomoći i informacijama voditeljima projektnih timova gospodinu Ivanu Totu, voditelju projekta NATURAVITA i gospodinu Domagoju Stjepanu Krnjaku, voditelju projekta LIFE CROLIS.

Literatura

Convention on Wetlands (2021a): Ramsar global guidelines for peatland rewetting and restoration, Ramsar Technical Report No. 11, Secretariat of the Convention on Wetlands, Gland, Switzerland.

Convention on Wetlands (2021b): Global Wetland Outlook: Special Edition 2021, Secretariat of the Convention on Wetlands, Gland, Switzerland.

Convention on Wetlands (2021c): Update on the status of Sites on the List of Wetlands of International Importance, SC59 Doc. 23 Rev. 1, 59th Meeting of the Standing Committee, Secretariat of the Convention on Wetlands, Gland, Switzerland.

Davidson, N. C., van Dam, A. A., Finlayson, C. M., Mc Innes, R. J. (2019): Worth of wetlands: revised global monetary values of coastal and inland wetland ecosystem services, Marine and Freshwater Research.

UN SDG (2018): Scaling up wetland conservation, wise use and restoration to achieve the Sustainable Development Goals, RAMSAR Convention on wetlands.

Weise, K., Höfer, R., Franke, J., Guelmami, A., Simonson, W., Muro, J., O'Connor, B., Strauch, A., Flink, S., Eberle, J., Mino, E., Thulin, S., Philipson, P., van Valkengoed, E., Truckenbrodt, J., Zander, F., Sánchez, A., Schröder, C., Thonfeld, F., Fitoka, E., Scott, E., Ling, M., Schwarz, M., Kunz, I., Thürmer, G., Plasmeijer, A., Hilarides, L. (2020): Wetland extent tools for SDG 6.6.1 reporting from the Satellite-based Wetland Observation Service (SWOS), Remote Sensing of Environment, Volume 247.

URL 1: Sustainable development goals, https://sdgs.un.org/goals, (20.6.2022.).

URL 2: RH portal indikatora Ciljeva održivog razvoja (SDG), https://croatianbureauofstatistics.github.io/sdg-indicators/, (20.6.2022.).

URL 3: Wetlands for a sustainable Mediterranean region, https://medwet.org/publications/wetlands-and-the-sdgs, (20.6.2022.).

URL 4: LIFE CROLIS – Hrvatski zemljišni informacijski sustav LIFE19 GIC/HR/001270, https://lifeprogramhrvatska.hr/hr/life-crolis-hrvatski-zemljisni-informacijski-sustav-life19-gic-hr-001270, (20.6.2022.).

URL 5: United Nations, Climate Actions,

https://www.un.org/en/climatechange/net-zero-coalition, (21.6.2022.).

URL 6: Grad Velika Gorica Javni portal za građane, webGIS, https://gis.gorica.hr/gis?c=1792373%2C5734115&l=jezero-cice&so=&z=15.9, (21.6.2022.).

URL 7: Grad Velika Gorica Javni portal za građane, webGIS, https://gis.gorica.hr/gis?c=1784731%2C5735340&l=donja_lomnica_grid_3857&so=&z=16.2, (21.6.2022.).

URL 8: Grad Velika Gorica Javni portal za građane, webGIS, https://gis.gorica.hr/gis?c=1798025%2C5735054&l=vg_jezero_ribnica&so=&z=20.0, (22.6.2022.).

URL 9: CROLIS projekt, https://lifeprogramhrvatska.hr/hr/life-crolis-hrvatski-zemljisni-informacijski-sustav-life19-gic-hr-001270/, (22.6.2022.).

URL 10: NATURAVITA projekt, https://naturavita-project.eu/, (22.6.2022.).

URL 11: Projekt VEPAR, https://vepar.voda.hr/o-projektu, (25.6.2022.).

URL 12: UN Progress on Water-Related Ecosystems, https://www.sdg6data.org/indicator/6.6.1, (25.6.2022.).

Change in the Extent of Aquatic Ecosystems over Time

Abstract

According to the global indicator Goal 6 of the Agenda for Sustainable Development until 2030, which refers to "Ensuring access to drinking water for all, sustainable water management and ensuring hygienic conditions for all" through sub-goal 6.6. "Change in the extent of aquatic ecosystems over time" and Indicator 6.6.1 "How and why ecosystems change over time" defined by the United Nations Statistical Commission, it is necessary to protect and restore water-related ecosystems, including mountains, forests, wetlands, rivers, aquifers and lakes. In this paper we discuss the cooperation of the geodetic and hydrogeological professions for the purpose of monitoring the percentage of water-related ecosystem changes over time. Such information is important for the development of a database that enables decisions to be made on the protection and restoration of water-related ecosystems. In Croatia, to this day, there has been no systematic monitoring and recording of such changes. However, systematic monitoring is necessary and will contribute to the assessment of climate changes impact on the ecosystems. This paper shows how an integrated and holistic approach of different professions can contribute to the goal of sustainable development 6.6.1.

Keywords: *Agenda for Sustainable Development until 2030, geodesy, hydrogeology*

Računalne simulacije i analize površinskog tečenja

Dubravko Gajski[1], Katarzyna Dzięgielewska-Gajski[2]

[1] Geodetski fakultet Sveučilišta u Zagrebu, Zagreb, R. Hrvatska, e-mail: kdzgajski@geof.hr

[2] Državna geodetska uprava, Zagreb, Gruška 20, R. Hrvatska, kdzgajski

Sažetak

Praćenje kretanja vode po Zemljinoj površini ima važnu ulogu u mnogim područjima ljudske djelatnosti, kao npr.: agronomiji, urbanizmu i prostornom planiranju, vodoopskrbi i odvodnji, ekologiji, predviđanju i zaštiti od prirodnih katastrofa (klizišta i poplave) te energetici (optimalne lokacije hidrocentrala te njihov energetski potencijal). U radu se donosi pregled algoritama računalnih simulacija površinskog tečenja prikladnih za primjenu u GIS-u. Analize tečenja pretpostavljaju utjecaj Zemljine gravitacije na tečenje ravnomjerne oborine po terenu opisanom digitalnim modelom reljefa. Rezultat ovih analiza su: vodozahvatna područja, linije koncentriranog otjecanja (vodotoci), količina i prostorna razdioba nakupljene oborine te lokalne depresije. Na kraju su prikazane neke mogućnosti upotrebe ovih analiza u praktičnim zadacima.

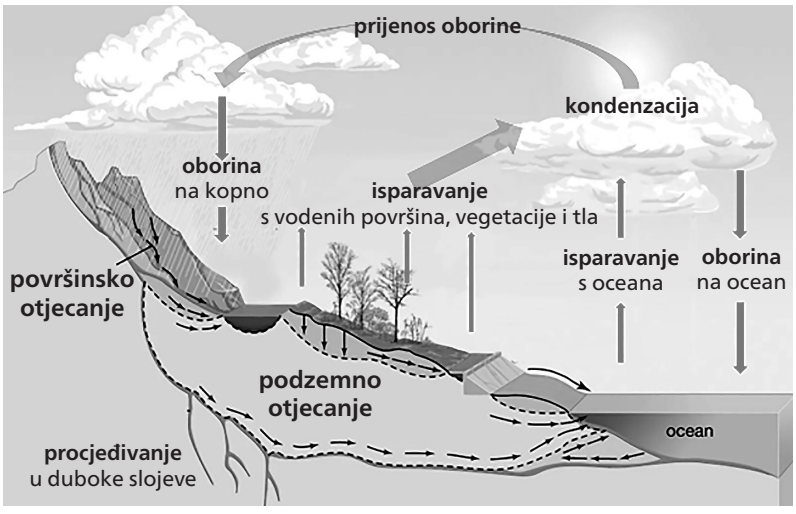
Ključne riječi: *DMR, GIS, hidrologija, površinsko tečenje*

1. UVOD

1.1 Hidrološki procesi i kruženje vode u prirodi

Voda je najzastupljenija tvar na površini Zemlje. Ukupna količina vode u tekućem i smrznutom obliku procjenjuje se na oko 1,386 milijarde kubičnih kilometara i obuhvaća vodu u atmosferi i litosferi, u oceanima, morima, jezerima, rijekama i močvarama te vječni snijeg i led (URL 1). Osim toga, ukupna površina vode na Zemlji obuhvaća oko 71 posto Zemljine površine, odnosno oko 510 miliona km^2. Taj sveukupni vodeni pokrivač Zemlje naziva se hidrosfera. Voda u hidrosferi je u neprekidnom kruženju različitim putevima u okviru hidrološkog ciklusa, mijenjajući agregatna stanja.

Godišnje isparava otprilike 496 tisuća kubičnih kilometara vode s površine kopna i oceana i ostaje u atmosferi oko 10 dana prije nego ponovno padne u obliku kiše, snijega ili leda (Slika 1). Količina potrebne energije za ovaj proces iznosi pola energije Sunčevog zračenja, koje obasjava Zemljinu površinu. Oko trećina oborina na kopno dolazi vodotocima do oceana, a tek 0.6% ukupnog otjecanja podzemnim otjecanjem. Relativno mala količina oborine ostaje privremeno pohranjena u rijekama i jezerima. Preostala oborina na kopno, oko 73 tisuće kubičnih kilometara godišnje, isparavanjem se vraća u atmosferu. Kod oceana isparavanje s njihove površine premašuje količinu oborina koja padne na njih. Tu razliku čini prijenos vodene pare s oceana na kopno, gdje se kondenzira i pada u obliku različitih oborina te se vraća u oceane rijekama i podzemnim otjecanjem. (URL 2)



Slika 1: Procesi kruženja vode u prirodi (URL 2)

1.2 Utjecaj reljefa na geomorfološke procese

Granična ploha između hidrosfere i pedosfere/litosfere je reljef. On čini prostorni kontinuum, a oblikovan je djelovanjem geomorfoloških procesa, koji djeluju na tu graničnu plohu u različitim vremenskim i prostornim rasponima. Stoga reljef posjeduje dualni karakter. On je s jedne strane rezultat djelovanja geomorfoloških procesa, koji oblikuju reljef. S druge strane je regulator pojavljivanja, snage, opsega i dinamike recentnih geomorfoloških procesa. Oblik terena igra temeljnu ulogu u moduliranju geomorfoloških procesa, što se posebno odnosi na hidrološke i atmosferske procese (Wilson & Gallant, 2000). Na geomorfološke procese uvelike utječe gravitacijski raspored, a time i topografija terena. Stoga su topografska svojstva, utjecaj geomorfoloških procesa i tipovi sedimenata u njihovoj prostornoj distribuciji snažno povezani. Sunčevo zračenje je najvažniji izvor energije, kako za atmosferske procese tako i za procese na površini Zemlje. Izravno Sunčevo zračenje je funkcija u globalnom smislu zemljopisne širine i godišnjih doba. Gravitacijsko tečenje vode po površini reljefa posebno jasno pokazuje izravan utjecaj topografije, jer na njega presudno utječu nagib i zakrivljenost terena.

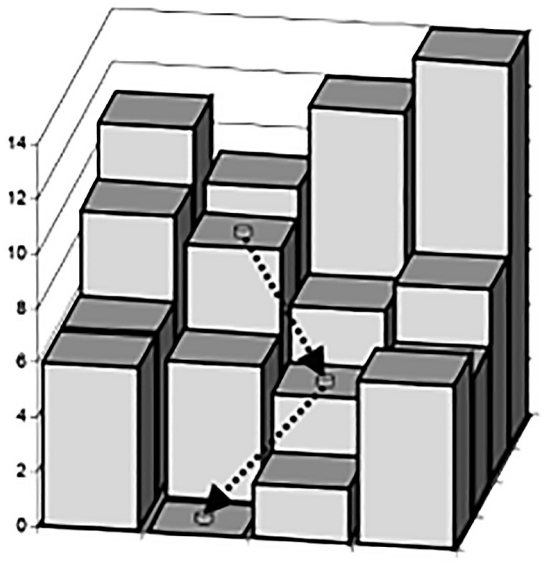
Proučavanje značajki topografije terena može olakšati razumijevanje mnogih geomorfoloških procesa, u različitim prostornim i vremenskim opsezima (Hutchinson & Gallant, 2000). Geomorfološke analize terena obuhvaćaju metode za kvantitativno opisivanje oblika površine terena, te uključuju znanja iz različitih znanstvenih disciplina, kao što su geoznanosti, matematika, inženjerstvo i računarstvo. U literaturi se mogu naći i drugi nazivi za geomorfološke analize terena, kao što su geomorfometrija, modeliranje terena i kvantitativna geomorfologija. Rezultati geomorfoloških analiza terena koriste se u mnogim znanstvenim disciplinama, posebice u hidrologiji, analizi geohazarda, tektonici, ekologiji itd. Iako su prva saznanja o geomorfološkim analizama terena bila poznata već u 19. stoljeću, one su se počele učinkovito koristiti tek nakon pojave odgovarajućih računala u posljednjim desetljećima prošlog stoljeća.

2. Računalne simulacije površinskog tečenja

Hidrološki relevantni parametri te strukturne linije (vododjelnice, vodoslivnice, kao i slivna područja) tradicionalno su se određivali korištenjem topografskih karata uz puno manualnog rada i utrošenog vremena. Šezdesetih godina prošlog stoljeća počele su se razvijati metode i algoritmi određivanja vodnih tokova korištenjem računala. Te rane metode su još uvijek zahtijevale znatan ljudski angažman. Ipak, brzi razvoj računalne tehnologije doveo je do razvoja algoritama hidroloških analiza uz vrlo visok stupanj automatizacije. Iako su prvi algoritmi koristili vektorske strukture podataka, zbog neposrednog korištenja slojnica pri izračunu hidroloških parametara, vrlo brzo se prešlo na rastersku podatkovnu strukturu (Gallant i Wilson, 2000). Prije svega, zbog jednostavnijeg razvoja algoritama i veće efikasnosti njihove implementacije. Stoga će se i u ovom radu pojasniti samo algoritmi bazirani na rasterskoj strukturi podataka. U tom slučaju se najprije računalno simulira jedinična oborina na svaku rastersku ćeliju, koja je potpuno jednoliko raspoređena diljem čitavog područja izvođenja hidroloških analiza. Radi izvođenja parametara reljefa, koji se baziraju na gravitacijskom tečenju, od odlučujućeg značaja su metode simulacije površinskog otjecanja. Već prema tome, da li se simulira otjecanje s promatrane rasterske ćelije prema susjednim ćelijama linijski ili plošno razlikujemo:

- jednodimenzionalne modele otjecanja i
- dvodimenzionalne modele otjecanja.

2.1. Jednodimenzionalni model otjecanja



Slika 2: Princip jednodimenzio-nalnog modela otjecanja (Gajski, 2009)

Kod ovog modela koncentrira se ukupna količina vode jedne ćelije u njenom središtu, zatim se simulira otjecanje cjelokupne količine vode prema relativno

a)

11	9	12
9	8	6
6	5	4

b)

2.1	1.0	2.9
1.0		-2.0
1.4	-3.0	-2.9

c)

0	0	0
0		0.25
0	0.38	0.37

Slika 3: Princip određivanja dijelova otjecanja; a) Isječak iz matrice visina; b) Submatrica s vrijednostima nagiba; c) Dijelovi otjecanja prema susjednim ćelijama (Gajski, 2009)

najnižoj susjednoj ćeliji (Slika 2). Tromost i uspor u kretanju vode po površini terena se ovdje zanemaruje. Stoga analiza otjecanja rezultira sljedećim ograničenjima jednodimenzionalnih modela:

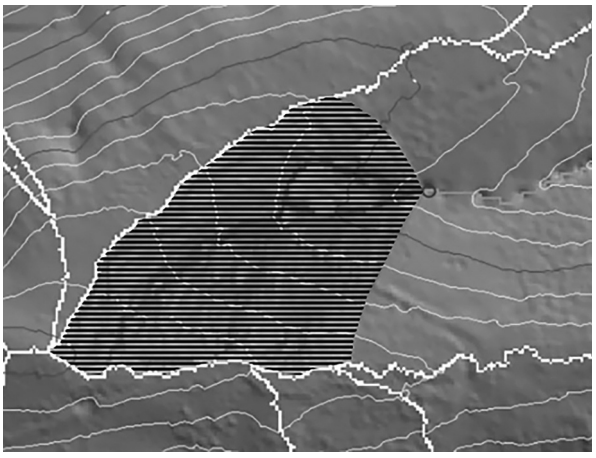
- Ne postoji način da se modelira divergirano otjecanje s jedne rasterske ćelije.
- Mogući smjerovi protoka ograničeni su na osam smjerova susjednih ćelija u rasterskom DTM-u.

Prednost je da je otjecanje s promatrane ćelije uvijek dodijeljeno točno jednoj (najnižoj) od susjednih ćelija. Stoga se ćelija mreže uvijek može jasno dodijeliti slivnom području. Jednodimenzionalni modeli otjecanja prvi put su opisani u "Deterministic 8" algoritmu (O'Callaghan i Mark, 1984). Kako bi pogreška uzrokovana ograničenjem na osam smjerova protoka bila što manja, razvijene su modifikacije: "Rho8" (Fairfield i Leymarie, 1991) i "Kinematički algoritam usmjeravanja" (Lea, 1992).

2.2 Dvodimenzionalni model otjecanja

Ograničenja jednodimenzionalnih modela mogu se izbjeći primjenom dvodimenzionalnih modela otjecanja. Cjelokupna količina vode nije više koncentrirana u središnjoj točki svake rasterske ćelije, već je jednolično raspoređena diljem čitave njene površine. Na taj način se može simulirati otjecanje na više susjednih ćelija, koje imaju manju visinu od upravo promatrane ćelije. Jedan od prvih objavljenih algoritama, koji koristi dvodimenzionalni model otjecanja je Multiple-Flow Direction (MFD) metoda. Dijelovi otjecanja do svake susjedne ćelije, niže od promatrane se računaju proporcionalno nagibima ka tim ćelijama od promatrane ćelije (Slika 3).

2.3 Određivanje vodotoka



Slika 4: Dio sliva (šrafirano), koji otječe kroz ćeliju označenu bijelim krugom. Vododjelnice su obilježene bijelim linijama.

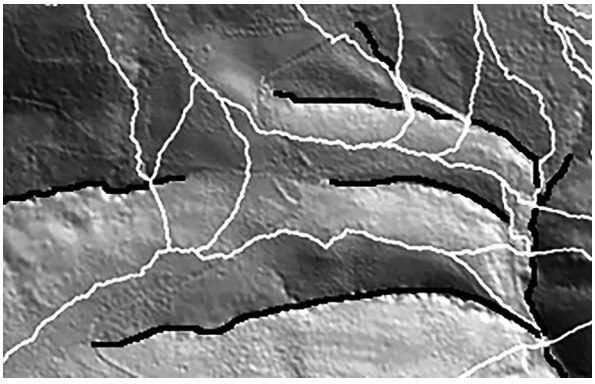
Linije koncentriranog otjecanja (vodotoci) nastaju tamo gdje se u udolinama tijekom kiše prikupi dovoljna količina vode (Rieger, 1992), kako bi se ostvarilo površinsko, usmjereno i koncentrirano otjecanje. Stoga je neophodno na temelju implementiranog modela otjecanja odrediti područje, a time i količinu vode koja protječe kroz neku rastersku ćeliju. Ako se uzme površina ćelije za jedinicu protoka vode, dovoljno je zbrojiti sve ćelije iznad promatrane ćelije, koje pripadaju njenom slivnom području i ako je taj protok veći od zadane vrijednosti, detektira se vodotok. Rezultat ovog postupka je površina slivnog područja, koja u potpunosti otječe kroz upravo promatranu ćeliju.

2.4. Određivanje slivnih područja

Svi algoritmi za određivanje slivnih područja pretpostavljaju prethodno određene vodotoke, prema ranije objašnjenom principu. Svakom slivnom području pripada pojedini dio vodotoka, kroz koji otječe voda s tog sliva. Stoga algoritam za određivanje sliva počinje uvijek od najniže točke razmatranog vodotoka, odnosno njegovog dijela. Prvi i najjednostavniji algoritam za određivanje slivnih područja objavili su Marks i dr. 1984. godine, pri čemu se koriste trajektorije jednodimenzionalnog modela otjecanja. Ove se trajektorije prate do njihove najviše točke, koja se zatim obilježava kao točka vododijelnice (Slika 4). Osim ovog postupka, postoji nekoliko modifikacija, ovisno o primijenjenom modelu otjecanja, no i dalje je zadržan isti princip.

3. Primjeri upotrebe

3.1 U hidrologiji



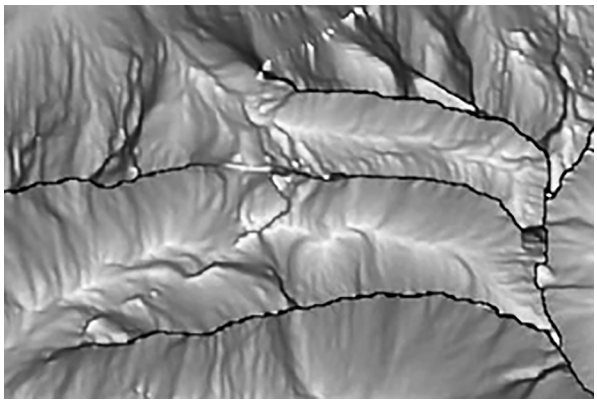
Slika 5: Slivna područja (ograničena vododjelnicama u bijeloj boji) te linije koncentriranog otjecanja (crne linije) dobiveni simulacijom iz DMR-a.

Sve navedene simulacije imaju značajnu primjenu. One omogućuju da kvantitativno procjenjujemo utjecaj reljefa na fluvijalne procese, ali i oblikovanje reljefa pod utjecajem fluvijalnih procesa, posebno vodne erozije. Nadalje, neki manji povremeni vodotoci nisu prepoznatljivi i ne daju se pouzdano detektirati metodama daljinskih istraživanja. Stoga nam ovakve simulacije mogu pomoći da predvidimo pojavu ovakvih vodotoka na osnovi simulacija (Slika 5)

3.2 Pri procjeni i predviđanju geohazardnih događaja

Energija vode koja teče niz neku površinu važan je faktor u procjeni opasnosti od pojave klizišta. Posebno ukoliko se radi o ekscesivnoj oborini. Na slici

6 je prikazana simulacija prostorne razdiobe protoka vode po nekoj površini u situaciji kontinuiranog, jednoličnog kišenja. Ovakva situacija dosta često nastaje posebno pri ekscesivnim oborinama, kada je količina oborine koja padne u jedinici vremena prevelika da bi je tlo moglo u značajnijoj količini upiti. Upravo ekscesivne oborine su vrlo često neposredan uzrok geohazardnih događaja, kao što su klizišta i poplave.



Slika 6: Simulacija intenziteta protoka vode.

3.3 U geodeziji

Kod interpolacije digitalnih modela reljefa (DMR-a) na temelju točaka dobivenih neselektivnim i visokoautomatiziranim metodama, kao što je lasersko skeniranje, vrlo često u dolinama dolazi do grubih pogrešaka u interpolaciji (Slika 7a). Uvođenjem linija koncentriranog otjecanja kao strukturnih linija u interpolaciju DMR-a, mogu se bitno smanjiti navedene pogreške (Slika 7b). Valja napomenuti da ovaj postupak daje pouzdane rezultate samo u područjima, koja su pretežno oblikovana fluvijalnim geomorfološkim procesima.

4. Zaključak

Površinsko otjecanje, glavni proces u hidrološkom ciklusu, povezuje količinu oborine s površinom sliva. Promjene u vegetaciji, vlažnosti tla, meteorološkim komponentama i površinskim uvjetima utječu na otjecanje. Simulacije površinskog otjecanja mogu nam pomoći razumjeti kako promjene u okolišu utječu na otjecanje i hidrološki ciklus. Poznavanje i što vjernije simuliranje procesa u prirodi, koji oblikuju reljef može nam i u geodetskoj operativi puno pomoći da na pravilan način interpretiramo mjerene podatke i dođemo do što boljih rezultata, posebno u modeliranju plohe terena. Nadalje, ta ploha terena je važan parametar pri simulaciji različitih geomorfoloških procesa, koji koriste DMR kao jedan od ključnih parametara, pri procjeni utjecaja prirodnih procesa na različite vidove ljudske djelatnosti.

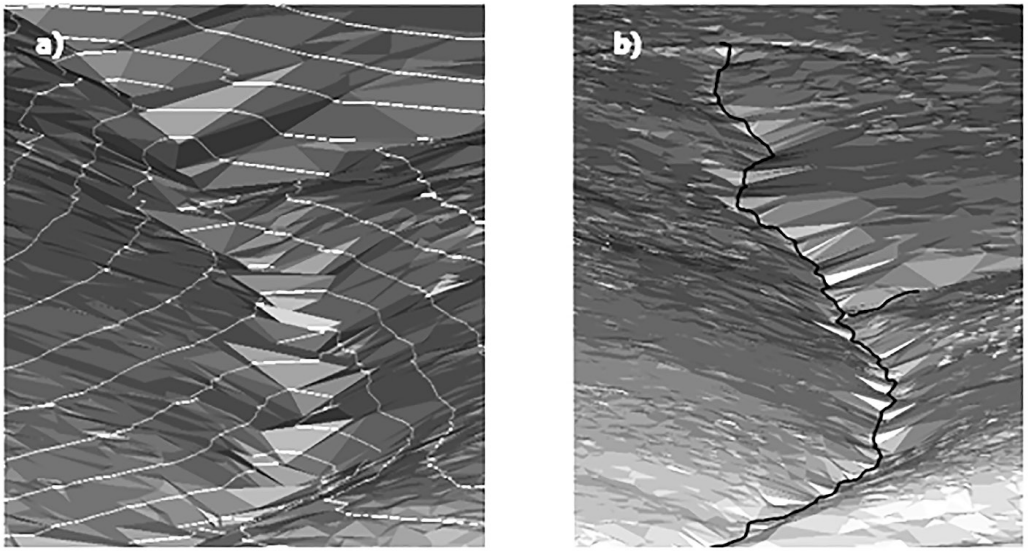
Literatura

Fairfield, J., Leymarie, P. (1991): Drainage networks from grid digital elevation models, Water resources research, sv. 27, br. 5., 709-717.

Gajski, D., (2009): Rasterbasierte Geländeoberflächeanalysen zwecks Ableitung der Strukturlinien im digitalen Geländemodell, Saarbrücken, Germany, Südwestdeutscher Verlag für Hochschulschriften Aktiengesellschaft & Co., 93-109.

Gallant, J.C. and Wilson, J.P. (2000): Digital Terrain Analysis, u Wilson, J.P. and Gallant, J.C., ur., Terrain Analysis: Principles and Applications, John Wiley & Sons, New York, 29-49.

Hutchinson, M.F., Gallant, J.C., (2000): Digital elevation models and representation of terrain shape, u Wilson, J.P. and Gallant, J.C., ur., Terrain Analysis: Principles and Applications, John Wiley & Sons, New York, 1-27.



Slika 7: DMR jedne udoline; a) iz originalnih podataka laserskog skeniranja; b) s uvedenim linijama koncentriranog otjecanja kao strukturnim linijama (Gajski, 2009)

Lea, N.L. (1992): An aspect driven kinematic routing algorithm. u Parsons, A.J. & Abrahams, A.D.: Overland flow: hydraulics and erosion mechanics, London, 147-175.

Marks, D., Dozier, J., Frew, J., (1984.): Automated basin delineation from digital elevation data. Geo-Processing, 2, 299-311.

O'Callaghan, J.F., Mark, D.M., (1984): The extraction of drainage networks from digital elevation data, Computer Vision, Graphics and Image Processing, sv.28, br.3/4, 323-344.

Rieger, W., (1992): Hydrologische Anwendungen des digitalen Geländemodelles. Dissertation, Geowissenschäftliche Mitteilungen Heft 39, TU Wien

URL 1: Hrvatska enciklopedija, mrežno izdanje. Leksikografski zavod Miroslav Krleža, 2021. http://www.enciklopedija.hr/Natuknica.aspx?ID=25432 (22. 6. 2022.)

URL 2: Hydrosphere - Origin and Evolution of the Hydrosphere, Britannica.https://www.britannica.com/science/hydrosphere/The-water-cycle. (22. 6. 2022.)

Computer Simulations and Surface Flow Analysis

Abstract

Monitoring the movement of water on the Earth's surface plays an important role in many areas of human activity, such as: agronomy, urbanism and spatial planning, water supply and drainage, ecology, forecasting and protection against natural disasters (landslides and floods) and energy hydropower plants and their energy potential. The paper presents an overview of algorithms for computer simulations of surface flow suitable for application in GIS. Flow analyses assume the influence of the earth's gravity on the flow of uniform precipitation over the terrain described by the digital relief model. The result of these analyses are: water catchment areas, lines of concentrated runoff (watercourses), the amount and spatial distribution of accumulated precipitation and local depressions. Finally, some possibilities of using these analyses in practical tasks are presented.

Keywords: *DMR, GIS, hydrology, surface flow*

Application of GNSS Technology in the Geodetic Auscultation of the High Dams

Zlatko Srbinoski[1], Zlatko Bogdanovski[2], Filip Kasapovski[3], Tome Gegovski[4]

[1] Faculty of Civil Engineering, Chair for advanced geodesy, Skopje, Republic of North Macedonia, srbinoski@gf.ukim.edu.mk

[2] Faculty of Civil Engineering, Chair for advanced geodesy, Skopje, Republic of North Macedonia, bogdanovski@gf.ukim.edu.mk

[3] Faculty of Civil Engineering, Chair for advanced geodesy, Skopje, Republic of North Macedonia, kasapovski@gf.ukim.edu.mk

[4] Faculty of Civil Engineering, Chair for advanced geodesy, Skopje, Republic of North Macedonia, gegovski@gf.ukim.edu.mk

Abstract

Geodetic auscultation of dams is a geodetic activity that provides information on the geometric stability of dams during their exploitation period. Since these are objects of crucial importance, a serious approach is required when monitoring them, i.e., high precision geodetic measurements are required. According to current practice and given the technology available, we usually used classical methods and instruments. But for their use, there is a need for visibility between the network points and the measuring points of the dam. The geodetic auscultation of the high dam "Topolnica" of the copper mine "Bucim" is one of the geodetic activities where the aforementioned condition of physical visibility between the points is impossible due to its dimensions and configuration of the terrain. Therefore, GNSS technology was used to fully satisfy the accuracy requirements for the positional deformations shown in this paper, while vertical deformations were determined on the basis of precise geometric leveling.

Keywords: *geodetic auscultation, GNSS, high dams*

1. Introduction

Dams are hydro-technical structures of great importance and due to their complexity in construction are a challenge for many engineers in many fields. During the construction of this type of facilities, it should be noted that not all engineering activities are completed. There are activities that are intensified due to the susceptibility of these facilities to constant external influences during the exploitation, which requires their continuous monitoring. For that purpose, one of the basic activities for monitoring the geometric condition of the dams is the geodetic auscultation which is of special importance besides the technical auscultation (Begović, 1990).

Geodetic auscultations are activities with a series of precise geodetic measurements aimed at determining the position of the measuring points placed along the body of the dam. By comparing the position of the measuring points in different time period, the displacements of the measuring points in horizontal and vertical sense can be determined. The determination of the coordinates of the measuring points is done by the micro-trigonometric and leveling network, which are placed outside the dam and are designed specifically for this purpose, allowing comparability of measurements from different time periods (Srbinoski and Bogdanovski, 2017).

Tailings dams are a special type of dams that are in function of the mines and are formed by depositing flotation tailings. These dams are constantly being over-built and often afforested, making them look like mountains. This seriously complicates geodetic activities if the classical methods and instruments are used in monitoring their exploitation condition. Thanks to the GNSS technology, which already occupies an important place in the geodetic science and in these facilities where the physical visibility of the points from the micro-trigonometric network and the measuring points along the body of the dam is impossible, accurate measurements can be performed to determine the positional deformations.

This paper presents geodetic measurements made on the high dam "Topolnica" which is in operation of the copper mine "Buchim" in the vicinity of the town of Radovish in the eastern part of Macedonia.

2. Technical data for dam "Topolnica"

The tailings dam "Topolnica" is built on the river flow from the river Topolnica, 8 km northwest of the town of Radovish (Figure 1).



Figure 1: Tailings dam "Topolnica" (Srbinoski et al., 2016–2021).

The construction of the dam started in 1979, when the Buchim mine was put into operation. The basic technical characteristics of the tailings dam "Topolnica" are (Nikolov et al., 2012):

- Type: sand dam;
- Length of the crown: 900 m;
- Maximum height above the ground: 134 m;
- Elevation of the crown: 654 m above sea level;
- Accumulation: over 3 mil. m^3 of water.
- Spread direction: east – west;
- Area: 48 hectares (38 hectares on the downstream side, 2 hectares on the crown and 8 hectares on the sedimentary lake.

First, an initial dam with a height of 40 m was built on the river Topolnica, then the dam was upgraded in three stages, reaching the maximum height above the terrain of 134 m (Figure 2).

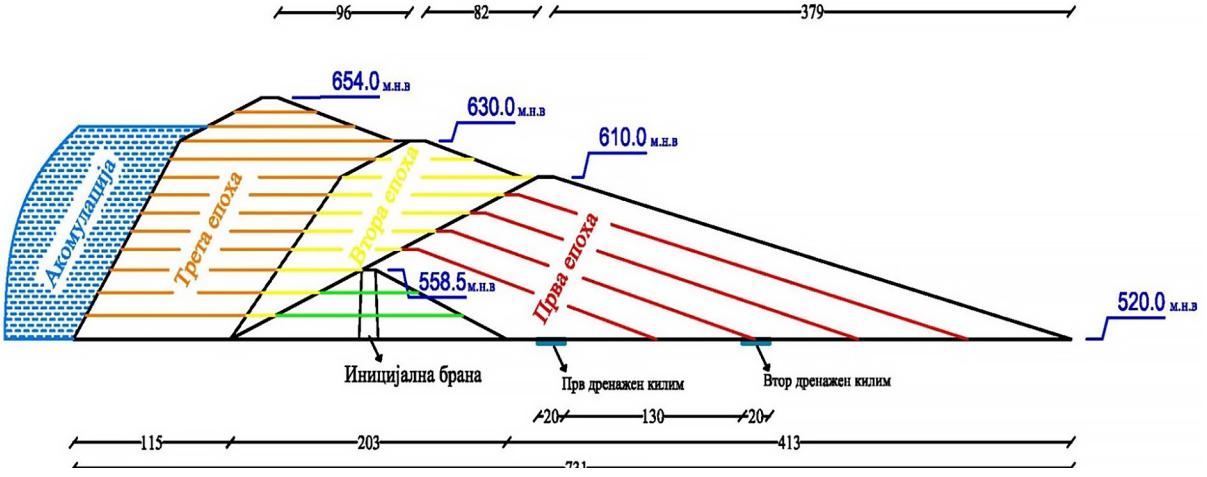


Figure 2: Graphic representation of the stages of dam (Nikolov et al., 2012).

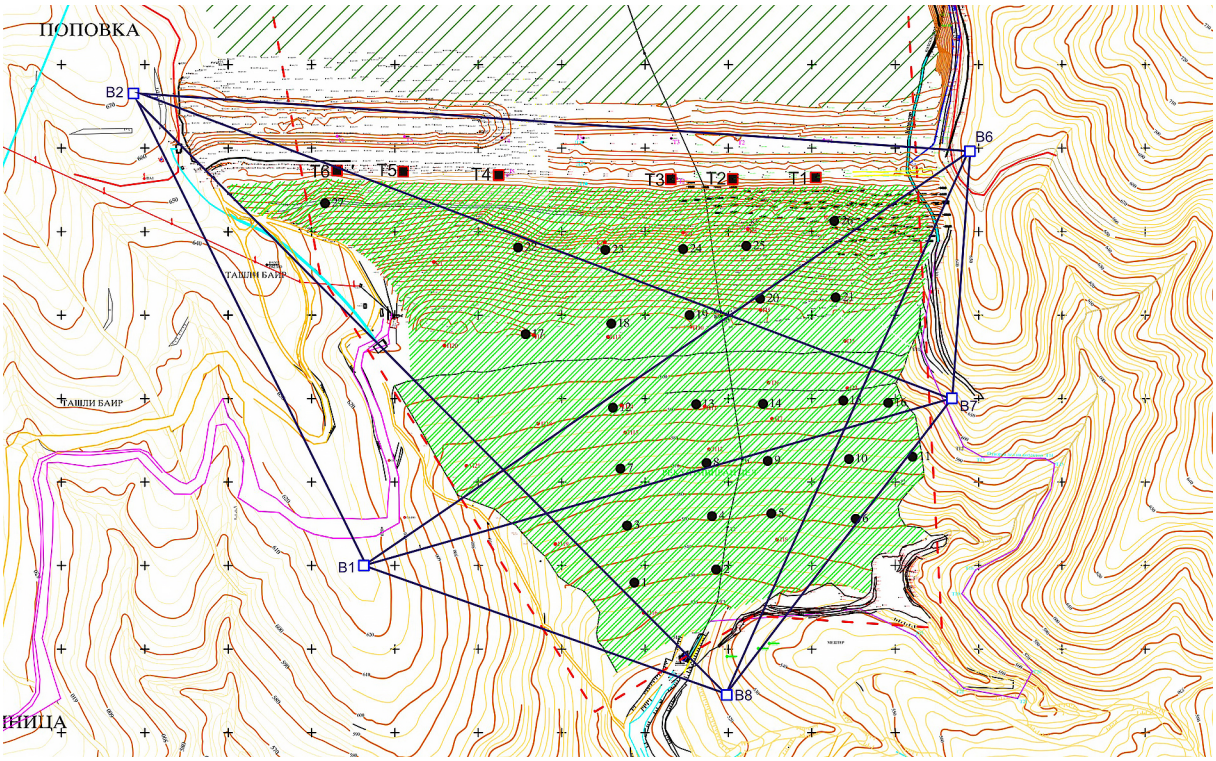


Figure 3: Micro-trigonometric network of the tailings dam "Topolnica".

3. Geodetic networks for dam auscultation

The geodetic basis for auscultation of the tailings dam "Topolnica" consists of:

- *Micro-trigonometric network*, which is a geodetic basis for determining the horizontal deformations of the dam and consists of five points B_1, B_2, B_6, B_7 and B_8 (Figure 3).
- *Leveling network*, which is the basis for determining the vertical deformations of the dam and it consists of 3 basic benchmarks: R_1, R_2, R_3 and two points of the micro-trigonometric network: B_2 and B_7.
- *Network of measuring points* in the body of the dam – is a network that approximates the body of the dam, and in those points the positional and height deformations are registered (the network of measuring points in this dam consists of 32 points, from T1 to T6 and from 1 to 27 without point no. 8).

The points of the micro-trigonometric network and the measuring points of the dam are stabilized with the same standardized concrete marks with dimensions 25 cm x 25 cm x 80 cm (Srbinoski et al., 2016–2021).

The three basic benchmarks are stabilized by cylindrical marks placed horizontally and vertically in solid rocks or concrete platforms outside the dam body (Figure 4) (Srbinoski et al., 2016–2021).



Figure 4: Stabilization of the basic leveling points R_1 (left) and R_3 (right).

4. Geodetic measurements for auscultation of the tailing dam "Topolnica"

The first more serious geodetic measurements of the tailings dam "Topolnica" were made in October 2016. They are a "zero" series of measurements to compare measurements obtained with future geodetic results.

The paper presents the results of 5 geodetic GNSS studies conducted in 2016 (zero series) and four series from 2017 up to 2020.

The geodetic auscultation included two activities, one of which was aimed at determining the positional deformations of the measuring points, and the other for determining the vertical component of the deformations.

The positional coordinates of the points in the body of the dam were determined on the basis of simultaneous GNSS observations of the points of the micro-trigonometric network with the measuring points of the dam, using a total of 6 two-frequency GNSS receivers. Since the base vectors between the points of the micro-trigonometric network and the measuring points of the dam did not exceed 2 km, a modification of the method for relatively static positioning with phase measurements was used during the 10-minute observation of each of the measuring points (Srbinoski et al., 2016–2021). After processing the measurements, the coordinates of the points of the micro-trigonometric network with an accuracy of ±0.5 mm and the coordinates of the measuring points of the dam with an accuracy of ±2 mm were obtained.

The levelling measurements were performed on the principle of closed polygons, using a precise leveling instrument that has a declared accuracy of ±0.3 mm/km and two barcoded invar rods.

5. Positional and height deformations of the dam

The positional deformations of the measuring points from the body of the dam are determined by comparing the adjusted positional coordinates of the eponymous points between two series of measurements.

Table 1: Excerpt from the tabular presentation of the positional deviations in the three series of measurements (Gegovski, 2018).

Point	Series	Date	Coordinates and coordinate deviations				Total positional deviation
			Y [m]	fy [mm]	X [m]	fx [mm]	fd [mm]
T1	(0)		615304.734		4614765.096		
	(1)	10.2017	.716	*–18*	.118	*+22*	**28**
	(2)	11.2018	.703	*–31*	.130	*+34*	**46**
	(3)	11.2019	.692	*–42*	.139	*+43*	**60**
	(4)	11.2020	.685	*–49*	.140	*+44*	**66**
T2	(0)	10.2016	615205.065		4614763.327		
	(1)	10.2017	.060	*–5*	.359	*+32*	**32**
	(2)	11.2018	.053	*–12*	.377	*+50*	**51**
	(3)	11.2019	.051	*–14*	.389	*+62*	**64**
	(4)	11.2020	.035	*–30*	.396	*+69*	**75**
T3	(0)	10.2016	615130.916		4614762.887		
	(1)	10.2017	.916	*0*	.918	*+31*	**31**
	(2)	11.2018	.921	*+5*	.935	*+49*	**49**
	(3)	11.2019	.919	*+3*	.946	*+60*	**60**
	(4)	11.2020	.915	*–1*	.955	*+69*	**69**
T4	(0)	10.2016	614924.507		4614768.051		
	(1)	10.2017	.518	*+11*	.066	*+15*	**19**
	(2)	11.2018	.527	*+20*	.072	*+21*	**29**
	(3)	11.2019	.530	*+23*	.088	*+37*	**44**
	(4)	11.2020	.532	*+25*	.088	*+37*	**45**

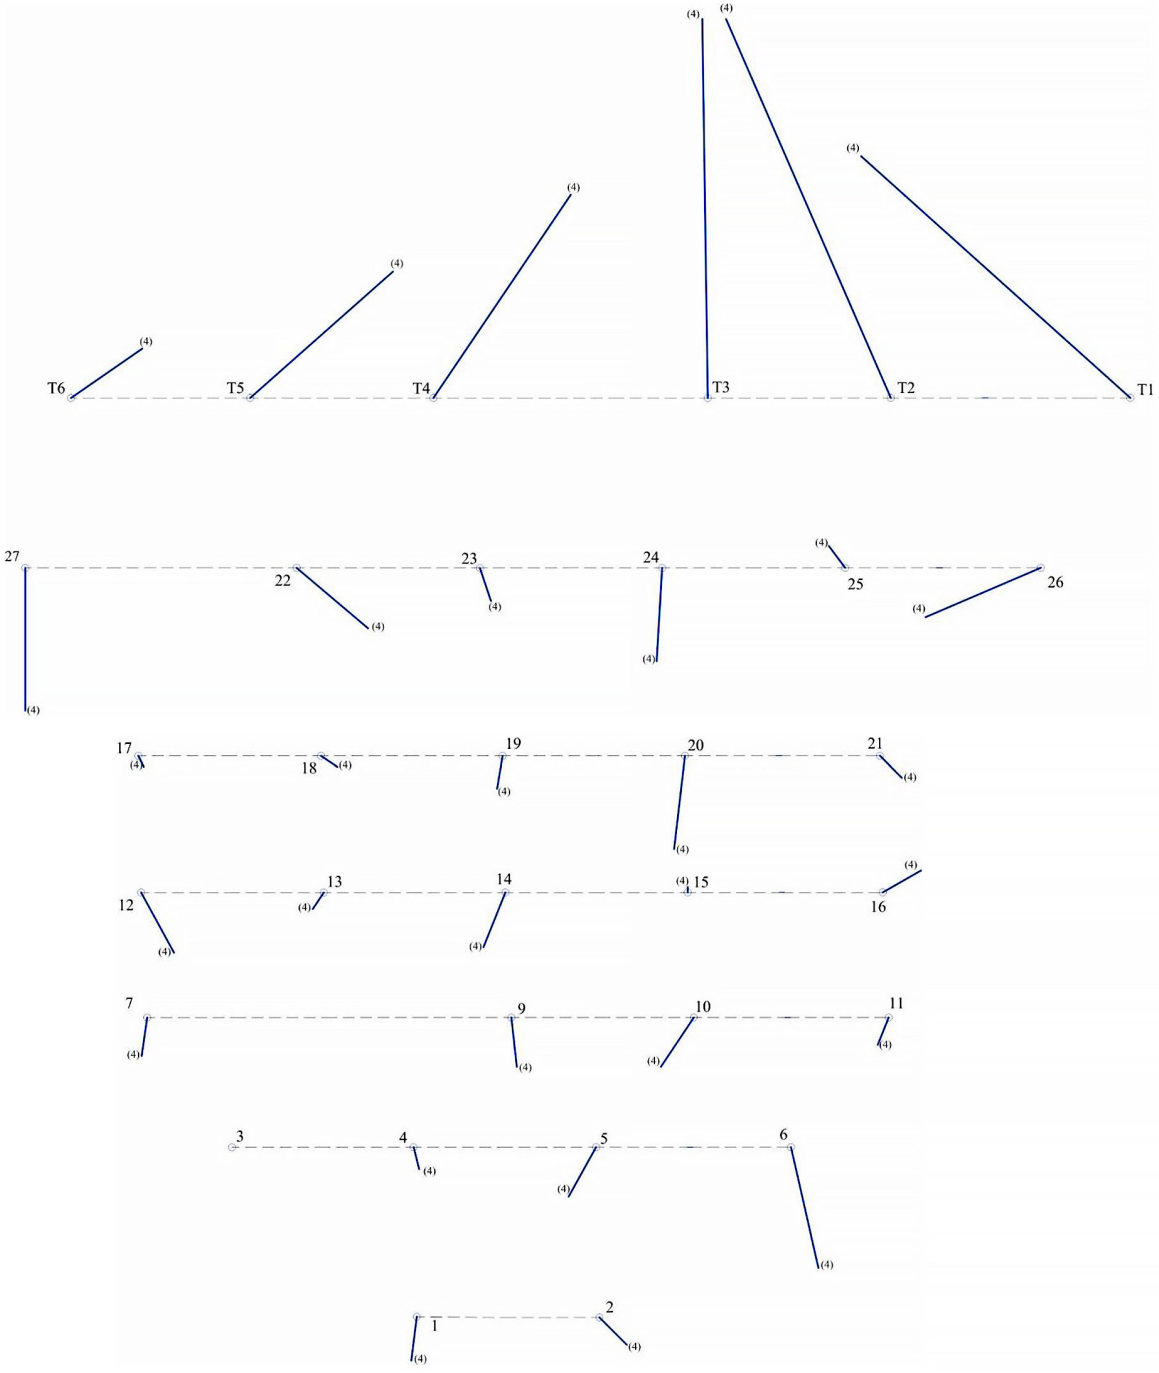


Figure 5: Graphic representation of the positional deformations of the tailings dam "Topolnica" for the period October 2016 – November 2020.

In this case, a total of five series of measurements were available, from which a detailed deformation analysis of the last series was made in relation to the penultimate and the first, which is already defined as a "zero" series. The obtained displacements are also shown through graphic interpretation (Figure 5).

The vertical components of the deformations are very important. When monitoring this type of objects with the precise geometric leveling, the subsidence and the excess of the measuring points are obtained, through which the vertical deformations of the object that is observed are determined. From here, the vertical deformations obtained with this geodetic method are used to control and confirm the results for the horizontal deformations obtained with other geodetic methods including the GNSS method. The determination of vertical deformations of the tailings dam "Topolnica", as previously mentioned is based on the measurements made by the precise geometric leveling in the five series of measurements through which results are obtained and a comparison is made. The following is an excerpt from the tabular presentation of the vertical deformations registered at the measuring points for the period October 2016 – November 2020 (Table 2).

Table 2: Excerpt from the tabular representation of the vertical deformations from the three series of measurements.

Point	Series	Date	Height	Vertical deformation
			H [m]	f_h [mm]
T1	(0)	10.2016	645.426	
	(1)	10.2017	.390	**–36**
	(2)	11.2018	.363	**–63**
	(3)	11.2019	.346	**–80**
	(4)	11.2020	.331	**–95**
T2	(0)	10.2016	644.792	
	(1)	10.2017	.743	**–49**
	(2)	11.2018	.707	**–85**
	(3)	11.2019	.684	**–108**
	(4)	11.2020	.663	**–129**
T3	(0)	10.2016	644.363	
	(1)	10.2017	.317	**–46**
	(2)	11.2018	.283	**–80**
	(3)	11.2019	.259	**–104**
	(4)	11.2020	.237	–126

From the previous graphic and tabular representations it can be noticed that the dam had the biggest deformations in the eastern part of the northernmost berm, i.e. in points T1, T2 and T3 where annually there is a positive displacement in the direction of the sedimentary lake of about 30 mm and subsidence of the dam in the vertical sense up to 50 mm.

These results can be freely stated that they are within the expectations according to which, for this type of facilities, larger displacements may occur in absolute value, and the main reason should be sought in the structure of the sediment material from which they are built.

6. Conclusion

The paper presents some of the results of three consecutive geodetic auscultations of the high dam "Topolnica". A novelty in these geodetic auscultations is that the GNSS technology is included in the determination of the positional deformations. The application of this modern technology in the geodetic results of the tailings dam "Topolnica" and the selection of the most rational methodology for measuring this huge object is a work that is attributed to the members of the Department of Advanced Geodesy at the Faculty of Civil Engineering – Skopje.

The need for continuous geodetic auscultations at the dams is confirmed once again by this paper, because the presented results for the registered deformations in the horizontal sense are determined with an accuracy of ±2 mm, which is an exceptionally good result for this type of facilities.

This paper is a confirmation that in dams where the physical visibility of the points is impossible, and the terrain configuration allows the application of GNSS technology, accurate GNSS measurements can be performed in order to monitor their stability in a horizontal position.

The application of precise geometric leveling to determine the vertical components of the deformations in engineering structures remains indisputable in terms of the accuracy provided in their determination.

References

Begović, A. (1990): Inženjerska geodezija 2, Naučna knjiga, Beograd.

Gegovski, T. (2018): Primena na globalnite navigaciski satelitski sistemi za opredeluvanje na 2D deformaciite kaj jalovišnite brani, Magisterski trud, Gradežen fakultet, Skopje.

Nikolov, N., Konzulov, G., Gocev, Z. (2012): Biomelioraciska revitalizacija na hidrojalovišteto Topolnica vo rudnikot Bučim – Radoviš, Konferencija: Hidrojalovištata vo Republika Makedonija, Ohrid, 76–83.

Srbinoski, Z., Bogdanovski, Z. (2017): Geodetic auscultation of dam Matka, MACOLD, Skopje.

Srbinoski, Z., Bogdanovski, Z., Kuzmanov, D., Spasovski, I., Gegovski, T. (2016–2021): Geodetski elaborati za geodetska oskultacija na branata Topolnica vo rudnikot Bučim – Radoviš, Gradežen fakultet, Skopje.

Primjena GNSS tehnologije u geodetskoj oskultaciji visokih brana

Sažetak

Geodetska oskultacija brana je geodetska djelatnost koja daje podatke o geometrijskoj stabilnosti brana u razdoblju eksploatacije. Budući da se radi o objektima od presudne važnosti, potreban je ozbiljan pristup njihovu praćenju, odnosno potrebna su geodetska mjerenja visoke preciznosti. Prema dosadašnjoj praksi i s obzirom na raspoloživu tehnologiju, najčešće smo koristili klasične metode i instrumente. No za njihovu uporabu potrebno je dogledanje između točaka geodetske mrežne i mjernih točaka brane. Geodetska oskultacija visoke brane "Topolnica" rudnika bakra "Bucim" jedna je od geodetskih aktivnosti gdje je zbog dimenzija i konfiguracije terena nemoguće osigurati uvjet dogledanja između točaka. Stoga je primijenjena GNSS tehnologija kako bi se u potpunosti zadovoljili zahtjevi točnosti za pozicijske deformacije prikazane u ovom radu, dok su vertikalne deformacije određene na temelju preciznog geometrijskog niveliranja.

Ključne riječi: *geodetska oskultacija, GNSS, visoke brane*

SESIJA 2

Geodezija i more

Otvoreni podaci u službi održivog upravljanja vodama i morskim okolišem Hrvatske

Andrea Miletić[1], Karlo Kević[2], Ana Kuveždić Divjak[3]

[1] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, andrea.miletic@geof.unizg.hr

[2] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, karlo.kevic@geof.unizg.hr

[3] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, ana.kuvezdic.divjak@geof.unizg.hr

Sažetak

Republika Hrvatska obiluje vodenim površinama. Utjecajem čovjeka, ali i klimatskim promjenama vode i morski okoliš doživljavaju stalne promjene. Svijest o važnosti očuvanja prirode i ispravnog gospodarenja, posebno voda i morskog okoliša, rezultirala je velikom količinom podataka koje prikupljaju brojne nacionalne, ali i međunarodne organizacije, primjerice program Copernicus. Pojavom inicijativa otvorenih podataka koje zagovaraju otvaranje podataka vladinih, ali i nevladinih organizacija, dio podataka vezanih uz vode i morski okoliš u Hrvatskoj postao je dostupan širokoj javnosti. Ono što nedostaje je cjelovita analiza njihove količine i stupnja primjerenosti za ponovnu uporabu. U radu su analizirani različiti skupovi podataka vezani uz vode i morski okoliš u Hrvatskoj koji su dostupni kao otvoreni vladini podaci. Osim toga, istraženi su podaci proizvodâ programa Copernicus za područje hrvatskog Jadrana i dan je osvrt na primjere ponovne uporabe promatranih podataka u Europskoj uniji. Rezultati pokazuju kako u nacionalnim okvirima postoji svijest o važnosti otvorenosti podataka, ali i da su potrebni dodatni napori kako bi se omogućila njihova ponovna uporaba. Analizom proizvoda Copernicusa utvrđeno je kako spomenuti program predstavlja važan izvor podataka za gospodarenje Jadranskim morem, a broj primjera ponovne uporabe podataka na razini Unije sugerira kako postoji određena svijest o iskorištavanju prednosti otvorenih podataka.

Ključne riječi: *Copernicus, otvoreni podaci, portali otvorenih podataka, vode i morski okoliš*

1. Uvod

Dostupnost podataka i informacija vezanih uz vodu od ključne je važnosti za upravljanje vodnim resursima na svim geografskim razinama, od globalne do lokalne. Poznato je da 71% Zemljine površine prekriva voda, od čega iznimno mali dio, 3,5%, otpada na slatku vodu rijeka i jezera. Voda, slatka ili slana, preduvjet je životu na Zemlji zbog čega se posebna pažnja pridaje njenom održivom gospodarenju. U jeku borbe protiv klimatskih promjena, dionici u sustavu gospodarenja vodom diljem svijeta suočavaju se sa sve zahtjevnijim strategijama upravljanja koje zahtijevaju informacije dobivene iz podataka o vodama – od administrativnih zapisa, do rezultata in-situ mjerenja, modeliranja, analize i procjene.

Republika Hrvatska (RH) obiluje vodenim površinama i vodnim resursima. Prema službenim statističkim podacima površina obalnog mora RH iznosi 31.067 km^2 što predstavlja približno 35% njezinog ukupnog teritorija (URL 1). Osim toga, UNESCO-va istraživanja iz 2003. godine svrstavaju Hrvatsku na peto mjesto u Europi po dostupnosti i bogatstvu vodenih izvora (Hrvatski sabor, 2008). Temeljem toga može se reći kako Hrvatska spada u skupine vodom relativno bogatih zemalja zbog čega je nužno raspolagati kvalitetnim podacima koji će poduprijeti proces donošenja odluka i osigurati adekvatno gospodarenje vodama i okolišem.

Službene podatke o vodama i morskom okolišu u Hrvatskoj prikupljaju i vode različite vladine organizacije na nacionalnoj razini. Prema europskoj Direktivi o otvorenim podacima i ponovnoj uporabi podataka javnog sektora (EU 2019/1024), takvi podaci bi trebali biti otvoreni i dani na korištenje široj javnosti. Iako je Hrvatska tek nedavno Direktivu u potpunosti implementirala u svoje zakonodavstvo (Hrvatski sabor, 2022), raniji zamah inicijativa otvorenih podataka doveo je do otvorenosti velikog broja podataka u nadležnosti javnog sektora. U te podatke ubrajaju se i podaci o vodama i morskom okolišu koji su u određenoj mjeri dostupni kroz web stranice (portale) institucija javnog sektora. Osim vladinih podataka, otvoreni podaci o vodama i morskom okolišu dostupni su i od strane nekih međunarodnih institucija. Primjer su podaci Copernicus programa Europske unije. Copernicus, program za promatranje Zemlje i njezina okoliša (URL 3), korisnicima nudi šest uslu-

ga među kojima i uslugu praćenja morskog okoliša (CMEMS) s referentnim informacijama o fizičkom i biogeokemijskom stanju, promjenjivosti i dinamici oceanskih i morskih ekosustava (URL 3). Prema ideji otvorenih podataka, vladinih ili nevladinih, primjena postojećih podataka u nove svrhe, npr. visina valova za turističke aktivnosti, bi trebala stvoriti bolje ekonomske i socijalne uvjete života npr. dovesti do većeg broja turista u nekom području. U državama predvodnicama na području otvorenih podataka, podaci se već koriste u nove svrhe čime se ostvaruju određeni ciljevi povezani s inicijativama otvorenih podataka, primjerice bolja informiranost građana. Iako su službeni vladini podaci o vodama i morskom okolišu u Hrvatskoj u određenoj mjeri već otvoreno dostupni, pokazuju različita ograničenja primjene. Dostupnost istih podataka od strane različitih institucija, na različitim platformama, pod različitim licencama, između ostalog, otežava otkrivanje izvornih podataka i posljedično korištenje u svrhe različite od primarnih za koje su prikupljeni (Colohan i Onda, 2022). U ovom istraživanju namjera je steći uvid u postojeće prakse s kojima se susrećemo u kontekstu tri kategorije: 1) *identificirati izvore i skupove otvorenih vladinih podataka o vodama i morskom okolišu u Hrvatskoj: odrediti koliko skupova podataka postoji dostupno te istražiti njihovu razinu primjerenosti za ponovno korištenje, 2) istražiti dostupnost i karakteristike podatka servisa Copernicus za opažanje mora na području Hrvatske 3) dati osvrt na odnos broja primjera ponovne upotrebe i količine dostupnih otvorenih podataka o vodi i morskom okolišu u Europskoj uniji*. Dobiveni rezultati pokazat će razinu dostupnosti otvorenih podataka o vodama i morskom okolišu u Hrvatskoj te ukazati koliko se takvi dostupni podaci trenutno koriste u praksi na području Europske unije.

2. Metodologija

Istraživanje je podijeljeno u tri cjeline pa stoga i metodologija prati predloženu strukturu.

Prema ideji o otvorenim podacima u kojoj svatko može pronaći i koristiti podatke bez ograničenja, identifikacija skupova i otvorenosti vladinih podataka o vodama i morskom okolišu u ovom radu vezana je uz perspektivu korisnika, a korišten pristup sastoji se od tri osnovna dijela: identifikacija izvora podataka, identifikacija skupova otvorenih podataka vezanih uz vode i morski okoliš te analiza pripadajućih metapodataka. Izvori podataka pronađeni su internetskim pretraživanjem, na dva načina. Prvi način vezan je uz perspektivu korisnika nestručnjaka koji ciljano traži podatke internetskim pretraživačem prema ključnim riječima. U ovom radu korištene su ključne riječi *vode otvoreni podaci, more otvoreni podaci* i *morski okoliš otvoreni podaci*. Drugi način vezan je uz perspektivu korisnika znanstvenika s predznanjem o mogućim izvorima takvih podataka. S ciljem sveobuhvatne analize, ovdje je primijenjen pristup pretrage web stranica „odozgo prema dolje", od nadležnog Ministarstva gospodarstva i održivog razvoja prema resornim agencijama i institucijama koje pružaju tražene podatke. Izvori su birani tako da zadovoljavaju apriori postavljene uvjete: podaci dostupni u otvorenom obliku i vezani uz prirodu – tijela vode, morski okoliš i s njima povezano upravljanje. Ukupno je identificirano devet izvora podataka (Tablica 1) od čega samo jedan isključivo pretragom po ključnim riječima.

Identificirani izvori pokrivaju različite tematske kategorije podataka (npr. promet, stanovništvo) i različite načine pristupa istima (npr. pregledavanje, preuzimanje) pa su formirani dodatni kriteriji za odabir koji skupovi podataka ulaze u istraživanje. S obzirom da su prema definiciji otvoreni podaci podaci koje svatko može slobodno koristiti, mijenjati i dijeliti u bilo koje svrhe, autori u ovom radu definiraju da otvoreni podaci ne smiju biti dostupni samo za pregledavanje, već mora postojati mogućnost pristupa preuzimanjem ili web servisima. Na taj način podaci se nedvosmisleno mogu mijenjati što doprinosi iskorištavanju potencijala njihove ponovne upotrebe. Drugi kriterij je da se istovrsni podaci s različitom vremenskom odrednicom smatraju različitim skupovima podataka. Konačno, posljednji kriterij odnosi se na tematiku podataka i usmjeren je na četiri osnove kategorije podataka od interesa:

- unutarnja svojstva vode – (fizikalne) karakteristike vodenih masa (npr. temperatura, salinitet, vrsta vode),
- vanjska svojstva tijela vode – geometrijska svojstva (npr. oblik, površina, smjer pružanja),
- upravljanje vodama i okolišem – politika upravljanja vodenim površinama i okolišem (npr. karte rizika od poplava, izvješća o kvaliteti),
- okoliš – okolina vodenih površina (npr. plaže, …).

Tablica 1: Izvori podataka

Naziv izvora	Naziv izvora
ENVI Atlas okoliša	Nacionalni portal otvorenih podataka
Bioportal	Portal otvorenih podataka grada Rijeke
Vrtlac	Geoportal Hrvatske vode
Baltazar (More)	Vinkovački vodovod i kanalizacija*
Geoportal Hrvatski hidrografski institut	

*isključivo pretragom po ključnim riječima

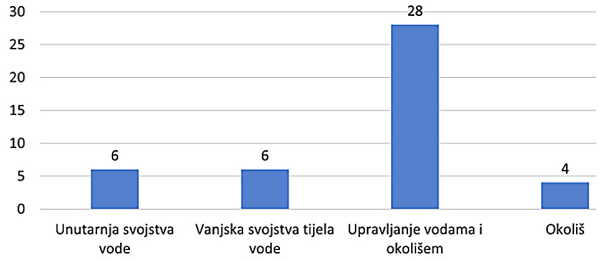
Temeljem postavljenih kriterija, a unutar devet identificiranih izvora, ukupno je pronađeno 44 različita skupova podataka. Kako bi se ocijenila mogućnost njihove ponovne upotrebe, za svaki skup prikupljeni su specifični metapodaci: institucija nadležna za vođenje (prikupljanje) podataka, licenca pod kojom su dostupni, na koji način i u kojem formatu su podaci dostupni te period ažuriranja i datum zadnjeg ažuriranja skupa (jesu li podaci ažurni).

Drugi dio istraživanja usmjeren je na otkrivanje Copernicus usluga i podataka vezanih uz vodu i morski okoliš za područje hrvatskoj Jadrana. Podacima se pristupa internetskom stranicom Copernicus Marine Service preko kataloga koji sadrži ukupno 195 proizvoda oceanskih podataka. Katalog proizvoda može se filtrirati po odabranim kriterijima; regionalnoj domeni, datumu prikupljanja podataka, praćenim parametrima ili dostupnom protokolu. Kako ne postoji opcija pretraživanja proizvoda za područje Jadrana, za regionalnu domenu postavljen je kriterij Sredozemno more. Temeljem postavljenog uvjeta, dobiveno je ukupno 39 proizvoda oceanskih podataka, a kako bi se dobio bolji uvid u njihove mogućnosti, napravljena je analiza po načinu opažanja, vremenskom obuhvatu te, prostornoj i vremenskoj rezoluciji.

Primjeri ponovne uporabe podataka o vodama i morskom okolišu pretraživani su na službenom portalu za europske podatke (URL 4). Službeni portal za europske podatke je središnji portal za pristup otvorenim podacima Europske unije, zemalja članica i partnerskih država (URL 4) koji uz podatke daje i uvid u primjere načina ponovnog korištenja istih. U smislu ovog rada od interesa su samo primjeri koji ponovno koriste podatke (engl. *reuse*) vezane uz vodu i morski okoliš, a otkriveni su filtriranjem po ključnim riječima *water, sea* i *marine* uz ograničenje na *re-use* vrstu korištenja i sektor okoliša (engl. *environment*). Osim toga, korištenjem istih ključnih riječi te uzimajući u obzir isključivo podatke iz kategorija okoliša (engl. *environment*), pretraženi su i skupovi otvorenih podataka, a dobiveni rezultati dovedeni u međusobnu vezu.

3. Rezultati

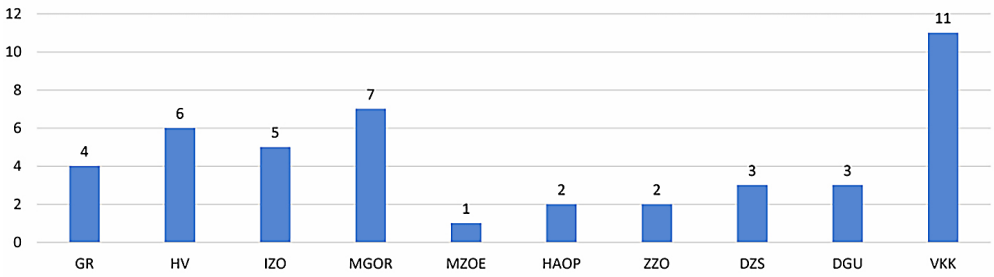
Nakon obavljene analize prikupljenih metapodataka, s obzirom na kategorije podataka od interesa, može se reći da je najviše dostupnih skupova podataka vezano uz upravljanje vodama (Slika 1). Iz Slike 1 vidljivo je da je udio takvih podataka u uzorku istraživanja značajan, odnosno da čak 28 skup pripada toj kategoriji. U takve podatke klasificirana su primjerice područja slivova, osjetljiva područja ili karte rizika od poplave, uglavnom podaci regulatorne ili informativne prirode.



Slika 1: Dostupnost otvorenih podataka po kategorijama interesa

Pronađenih 44 skupova podataka na javno korištenje dalo je ukupno deset institucija javnog sektora (Slika 2). Iz Slike 2 vidljivo je da u najvećoj mjeri (80%) svoje podatke otvaraju državne institucije (ministarstva, agencije, instituti, zavodi i tvrtke) dok su jedinice lokalne samouprave zastupljene samo s dvije institucije, Gradom Rijekom i gradskom tvrtkom Vinkovački vodovod i kanalizacije.

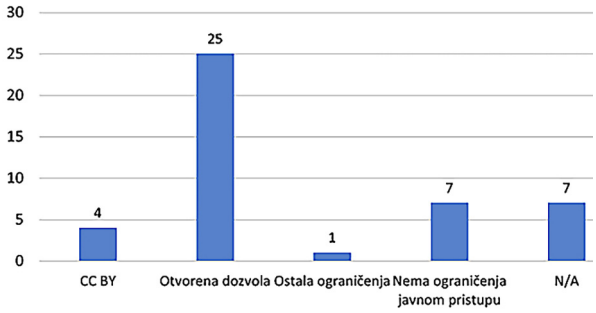
Odnos rezultata se mijenja ako se promatra količina otvorenih podataka od strane navedenih institucija. Iako samo dvije, institucije s lokalnim djelovanjem na otvoreno korištenje pružaju oko 35% ukupno pronađenih skupova podataka. Taj udio značajno raste ako se institucije gledaju pojedinačno. Vinkovački vodovod i kanalizacije pružaju ukupno najviše otvorenih skupova podataka, njih 11, a Grad Rijeka četiri, što je i dalje više nego polovica promatranih državnih institucija. Hrvatske vode, kao nacionalna tvrtka koja upravlja slatkovodnim resursima, nakon Ministarstva i održivog razvoja, otvara najviše skupova podataka među državnim institucijama, ukupno šest. Rezultati pokazuju i da među pružateljima podataka postoji svijest o licencama podataka, jednom od odlučujućih čimbenika ponovne upotrebe (Slika 3). Prema Slici 3 vidljivo je da većina skupova podataka (29) ima jasno specificiranu licencu. Bitno je napomenuti da licenca, osim o instituciji, ovisi i o izvoru (platformi) na kojoj su podaci dostupni. Primjerice, Plan upravljanja pomorskim dobrom za 2019. je dostupan na Portalu otvorenih podataka grada Rijeke pod Creative Commons Attribution licencom (CC BY) dok je na Nacio-



GR - Grad Rijeka • HV - Hrvatske vode • IZO - Institut za oceanografiju • MGOR - Ministarstvo gospodarstva i održivog razvoja • MZOE - Ministarstvo zaštite okoliša i energetike • HAOP - Hrvatska agencija za okoliš i prirodu • ZZO - Zavod za zaštitu okoliša • DZS - Državni zavod za statistiku • DGU - Državna geodetska uprava • VKK - Vinkovački vodovod i kanalizacije

Slika 2: Pružatelji otvorenih podataka o vodama i morskom okolišu

nalnom portalu otvorenih podataka dostupan pod Otvorenom dozvolom. Iako različite, licence se mogu smatrati jednakovrijednima. Iz Slike 3 vidljivo je i da dio skupova podataka nema jasno pridružene uvjete korištenja pa gotovo trećina uzorka (34%) zbog nejasne licence ima smanjenu mogućnost ponovnog korištenja.

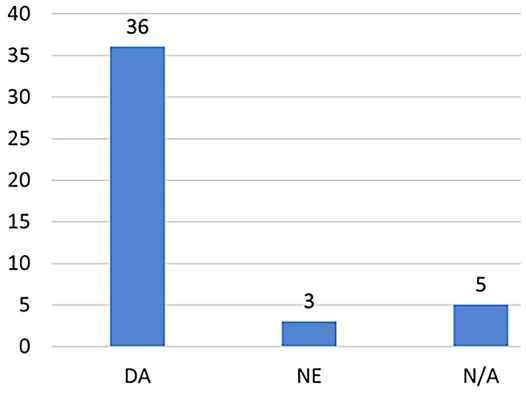


Slika 3: Licence dostupnih skupova podataka

Analiza dostupnosti podataka za korištenje (Slika 4) otkriva kako su podaci po načinu pristupa većim dijelom dostupni u obliku web servisa (WMS i WFS), a manje za direktno preuzimanje (Slika 4a).

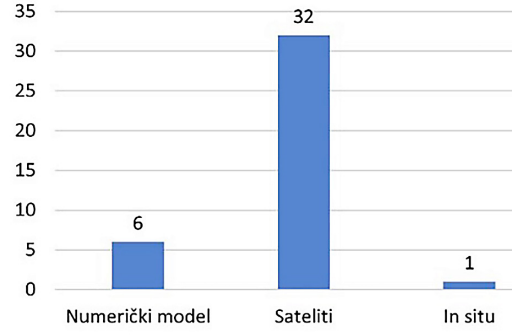
Od ukupno 44, 22 skupa podataka je dostupno barem za preuzimanje, a 13 u obliku WFS usluge (Slika 4a). Iz slike je također vidljivo kako broj načina pristupa premašuje broj skupova podataka što znači da su određeni skupovi podataka dostupni na više načina. Prema slici 4b, podaci koji su dostupni za preuzimanje najčešće su strukturirani u .pdf formatu (46%), a značajan je i broj podataka koji su dostupni tablično (.xsls) ili tekstualno (.csv i .txt). S druge strane, samo jedan promatrani skup podataka je dostupan u vektorskom .shp formatu. Isto kao i kod načina pristupa, frekvencija formata podataka veća je od ukupnog broja skupova podataka što znači da su određeni podaci dostupni u više formata.

Uz licencu i dostupnost podataka, odlučujući čimbenik ponovne uporabe je ažuriranost podataka. Analizom uzorka (Slika 5) utvrđeno je kako je preko 80% skupova podataka ažurno. Za pet skupova podataka nije pronađena informacija o predviđenom periodu ažuriranja ili kad su podaci zadnji put ažurirani pa se za takve podatke ne može sa sigurnošću reći odgovaraju li trenutnom stanju. Ono što je zanimljivo jest da za velik dio podataka nije predviđeno ažuriranje zbog čega su oni kategorizirani kao ažurni.

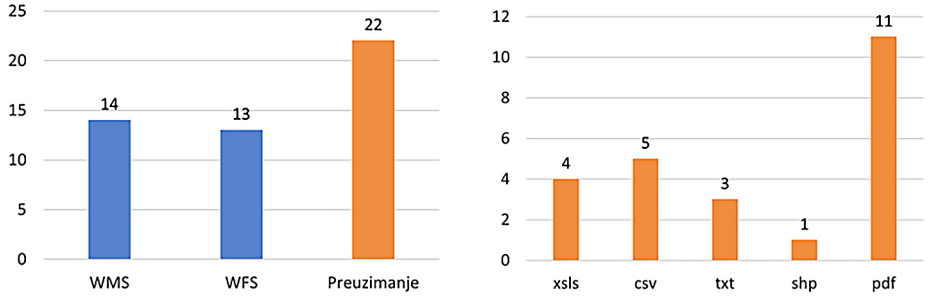


Slika 5: Ažurnost skupova podataka

Analizom 39 oceanskih proizvoda Copernicus Marine Service-a, ustanovljeno je da 30 proizvoda pruža podatke isključivo za područje Sredozemnog mora, dok je preostalih devet vezano za globalni ocean[1]. Od 30 proizvoda za Sredozemlje, 15 pruža podatke o fizičkom stanju (npr. temperatura mora, salinitet), 12 o biogekeomijskom stanju (npr. količina klorofila, zamućenje, refleksija), a preostala tri o promjenjivosti i dinamici morskih ekosustava (npr. visina i smjer vala). Ako se uzmu u obzir svih 39 Copernicus proizvoda i podaci koje ti proizvodi pružaju, proizlazi da 32 proizvoda sadrže podatke prikupljene pomoću satelita, jedan proizvod sadrži podatke dobivane od in-situ sustava (zemaljskih postaja), dok su tri proizvoda rezultat matematičkog modeliranja (Slika 6).



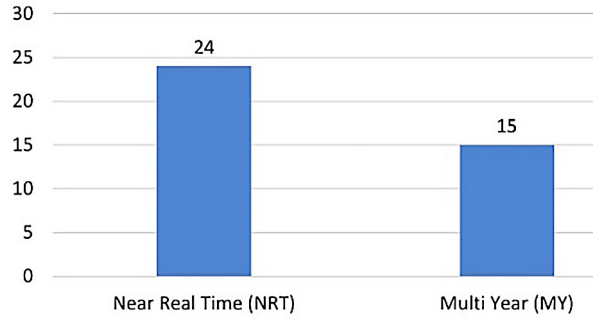
Slika 6: Način opažanja mora



Slika 4: Dostupnost podataka: a) način pristupa, b) vrste formata za preuzimanje

[1] Copernicus Marine, Data: https://resources.marine.copernicus.eu/products, (25.6.2022.).

Svaki proizvod obuhvaća određeno vremensko razdoblje za koje su podaci dostupni. Proizvode se tako može podijeliti u dvije glavne vremenske kategorije (Slika 7).



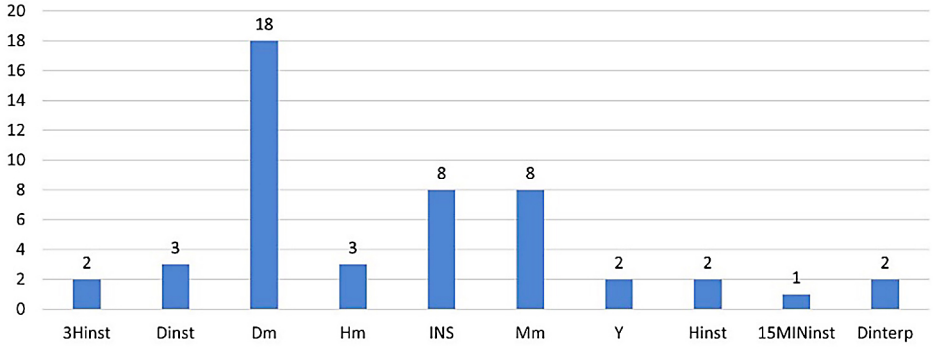
Slika 7: Vremenski obuhvat proizvoda

Near real time (NRT), koja pruža informacije iz sadašnjosti i budućnosti te multi year (MY), koja pruža informacije o oceanu iz prošlosti s vremenskim obuhvatom podataka od 10, 20, 30 ili više godina. Iz Slike 7 može se vidjeti kako je s obzirom na vrstu vremenskog obuhvata 24 proizvoda u kategoriji NRT, a 15 proizvoda u MY kategoriji. Sljedeća komponenta po kojoj su analizirani proizvodi je njihova vremenska rezolucija. Copernicus nudi različite vremenske rezolucije, a proizvodi koji pružaju podatke o Jadranu, tj. Sredozemnom moru, dostupni su u njih deset. Neki od proizvoda pružaju samo jednu, a neki i četiri različite vrste vremenskih rezolucija.

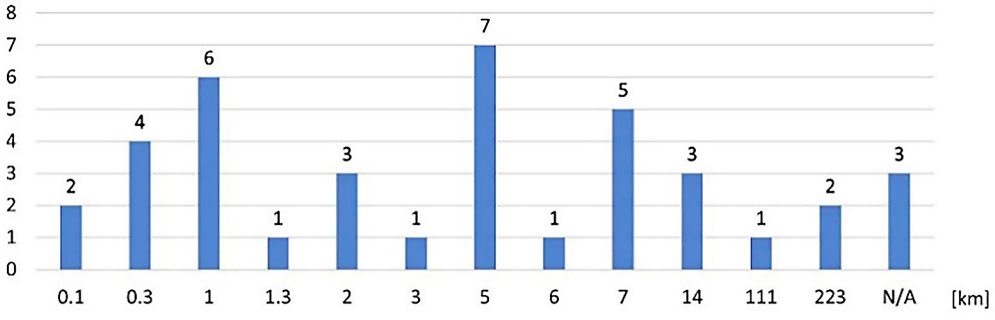
Iz Slike 8 se može vidjeti kako je s obzirom na vremensku rezoluciju najzastupljenija dnevna srednja vrijednost (Dm) s 18 proizvoda; zatim slijede trenutna (INS) i mjesečna srednja vrijednosti (Mm) s osam proizvoda, dnevna trenutna (Dinst) i srednja vrijednost po satu (Hm) s tri proizvoda; trenutna po satu (Hinst), tri puta trenutna po satu (3Hinst), godišnja (Y) i dnevna interpolirana (Dinterp) s dva proizvoda te 15 minutna trenutna vremena rezolucija (15MINInst) s jednim proizvodom.

Za kraj, podaci su analizirani i po prostornoj rezoluciji. Proizvodi su dostupni u različitim rezolucijama, od 100 m pa sve do 223 km, dok je najčešće dostupna rezolucija od 5 km. Lošija rezolucija vezana je uz globalne oceanske proizvode.

Konačno, na službenom portalu za europske podatke istražena je dostupnost otvorenih podataka o vodama i morskom okolišu te primjeri ponovne upotrebe tih podataka. Filtriranjem po ključnim riječima *water, sea* i *marine* te ograničavanjem pretrage po kategoriji okoliš (*environment*), dobiveno je 21 208 skupova podataka. Kada su ti isti kriteriji pretrage primijenjeni na pokazane primjere ponovne uporabe podataka, dobivena su samo 24 takva primjera. Ti se primjeri ponovne upotrebe uglavnom odnose na praćenje razina mora, kvalitete vode te procjene rizika od poplava. Jedan od primjera upotrebe je i aplikacija *Waterovelast: Wolk*, koja daje pregled sustava odvodnje i ugroženih poplavnih područja u slučaju velikih poplava u nizozemskoj općini Assen. S obzirom na to da poplave mogu uzrokovati prometne gužve i štete na zgradama, vizualizacijom tih podataka na karti jednostavnije je doći do rješenja problema (URL 4). Također postoje i primjeri korištenja podataka od strane znanstvenih organizacija. Španjolski



Slika 8: Frekvencija proizvoda s obzirom na vremensku rezoluciju



Slika 9: Frekvencija proizvoda s obzirom na prostornu rezoluciju

institut za oceanografiju (IEO) prikuplja, pohranjuje i distribuira podatke različitih znanstvenih organizacija i to za potrebe praćenja morske bioraznolikosti te održivosti ribarskih resursa i morskog okoliša (URL 4).

4. Diskusija i zaključak

Provedeno istraživanje je prvi korak u analizi otvorenih podataka vezanih uz vode i morski okoliš u Hrvatskoj. Dobiveni rezultati su preliminarni, ali indikativni te mogu koristiti javnom sektoru u budućem otvaranju podataka. Na osnovu dobivenih rezultata može se zaključiti da većina pronađenih skupova podataka spada u kategoriju upravljanje vodama, a nekad se u pozadini kriju zakoni, pravilnici i regulative koji nisu primarna djelatnost institucije pružatelja podatka. Uočeno je i kako su podaci često dostupni na različitim mjestima, ponekad i od strane različitih institucija. Analizirajući metapodatke, uočeno je kako podaci često nemaju jasno naznačenu licencu ili su pak dodijeljene dvije, da za većinu podataka nisu planirana ažuriranja te da je iznenađujuće mali broj skupova podataka za preuzimanje dostupan u strojno obradivom, otvorenom formatu. Temeljem toga može se reći da podaci o vodama i morskom okolišu u Hrvatskoj nisu u velikoj mjeri otvoreno dostupni niti su pogodni za ponovnu uporabu. Kvalitetniji metapodaci, u smislu jasnije naznačene licence te navođenja perioda i datuma zadnjeg ažuriranja, uz dostupnost podataka u otvorenijim formatima značajno bi doprinijeli ponovnom korištenju podataka. Copernicus podaci za područje hrvatskog Jadrana dostupni su u 39 Copernicus proizvoda te su uglavnom dobiveni satelitskim opažanjima. Većinom u skoro realnom vremenu, podaci su dostupni u različitim vremenskim rezolucijama s, za morska prostranstva, prihvatljivom površinskom rezolucijom. Temeljem toga, Copernicus proizvodi mogu se smatrati važnim izvorom podataka za praćenje i gospodarenje Jadranskim morem. Broj dostupnih primjera ponovne upotrebe na stranicama portala otvorenih podataka Europske unije je jako malen u odnosu na broj ukupno identificiranih skupova podataka. To može implicirati dvojaku interpretaciju: nisu svi primjeri upotrebe uključeni u Portal ili se potencijal velikog broja otvorenih podataka ne iskorištava dovoljno.

Napomena: Ovo istraživanje dio je projekta Twinning Open Data Operational koji je financiran iz programa istraživanja i inovacija Europske unije Horizon 2020 u okviru Ugovora o dodjeli bespovratnih sredstava broj 857592 – TODO.

Literatura

Colohan, P., Onda, K. (2022): Water data for water science and management: Advancing an Internet of Water (IoW), PLOS Water, 1, 3, 1-4.

Hrvatski sabor (2008): Strategija upravljanja voda, Narodne Novine, 91.

Hrvatski sabor (2022): Zakon o izmjenama i dopunama Zakona o pravu na pristup informacijama, Narodne Novine, 69.

URL 1: Općenito o RH – Migracije, https://migracije.hr/opce-informacije/, (25.6.2022.).

URL 2: Water statistics - Statistics Explained, https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Water_statistics, (25.6.2022.).

URL 3: Copernicus, https://www.copernicus.eu/en, (12.7.2022.).

URL 4: The official portal for European data, https://data.europa.eu/en, (12.7.2022.).

Open Data for Sustainable Water and Marine Environment Governance in Croatia

Abstract

The Republic of Croatia is rich in water areas. Due to human influence and climate change, the water and marine environment are subject to constant changes. Awareness of nature conservation, especially in the field of water and marine environment, has led to a large amount of data collected by national and international organizations. The Open Data Initiative, which advocates the opening of governmental and non-governmental data, resulted in a large quantity of data related to the water becoming available to the public. A comprehensive analysis of their quantity and suitability for reuse has yet to be conducted. This paper analyzes various water and marine environment datasets that are available to the public as open data. Copernicus Marine Services data and ocean products were also examined. Finally, an overview of open data and its use cases in the water domain in the European Union was provided. The results show that there is an awareness of openness within the national framework, but also those additional efforts are needed to achieve its re-use. Analysis showed that Copernicus is an important source of data, and the number of use cases in the EU suggests that there is some awareness of open data benefits.

Keywords: *Copernicus, open data, open data portal, water and marine environment*

Od jednog snopa do lepeze

Eleonora Kučić[1]

[1] Geodetski zavod Rijeka d.o.o., Ulica Dr. Frana Kresnika 33, Rijeka, Hrvatska, eleonorak@gzr.hr

Sažetak

Od davnina postoji potreba za nautičkim kartama s točno i precizno definiranim područjima opasnih pličina, podrtina ili drugih opasnih mjesta čije je poznavanje od iznimne važnosti za sigurnu plovidbu morima, rijekama i jezerima. U početku je metoda određivanja dubina spuštanjem lanca s utegom i određivanje pozicije presjecima davala dovoljno dobre rezultate za definiranje takvih područja, no povećanjem vodnog prometa pojavljuje se potreba za efikasnijim načinima određivanja dubina. Pojavom prvih ultrazvučnih dubinomjera (engl. echo sounder) značajno se razvija batimetrija i pojednostavljuje identificiranje opasnih mjesta, međutim tek pojavom GNSS tehnologije (engl. Global Navigation Satellite Systems) i njezinom civilnom upotrebom ostvaruje se šira primjena određivanja dubina jednosnopnim ultrazvučnim dubinomjerima (engl. single beam echo sounder). Nadalje, razvojem društvenih, ekonomskih, gospodarskih i ekoloških aspekata stvara se potreba za naprednijim pristupom u mjerenju dubina. Pojavom višesnopnih ultrazvučnih dubinomjera (engl. multibeam echo sounder), koji odašilju lepezu snopova, realistični trodimenzionalni prikazi vodnog dna postali su neophodni, kako za plovidbu, tako i za planiranje, projektiranje, gradnju te praćenje nastalih promjena uzrokovanih ljudskim ili prirodnim djelovanjem, a sve u cilju učinkovitog upravljanja vodama. U ovom radu daje se pregled razlika prikaza dobivenih jednosnopnim i višesnopnim dubinomjerom na istom morskom području. Također, pokazat će se koliko nam vjerno ti prikazi dobiveni mjerenjem višesnopnim dubinomjerom mogu predočiti oblik i veličinu objekata koji se nalaze na morskom dnu.

Ključne riječi: *batimetrija, jednosnopni dubinomjer, trodimenzionalni prikazi, višesnopni dubinomjer*

1. Uvod

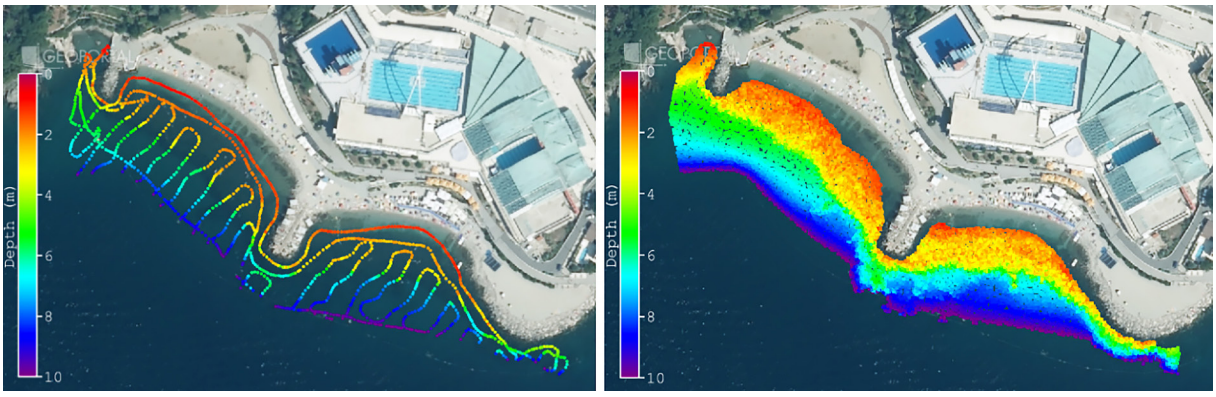
Od samih početaka plovidbe pojavila se i potreba za informacijom o poziciji plovila i dubini vode na području kretanja. Udaljenost trupa plovila od mogućih prepreka koje se nalaze u moru, rijekama i jezerima važan je čimbenik za ostvarivanje uspješnog i sigurnog vodnog prometa. Informacije o opasnim lokacijama bilježile su se za buduće plovidbe i tako razvijale nautičke karte. Kao što su topografija i topografske karte omogućile lakše kretanje na kopnu tako su batimetrija i batimetrijske karte olakšale plovidbu vodama.

Batimetrija (iz starogrčkog (bathus) ''duboke'' i (metron) ''mjera'') je grana oceanografije koja mjeri i analizira dubine u moru, jezeru ili rijeci (URL 1). U početcima se dubina mjerila pomoću utega na konopu ili lancu te bi odgovarala duljini uronjenog materijala. Podaci o poziciji izmjerene dubine dobili bi se presjecima. Razvojem tehnologije potom se koriste jednosnopni zvučni dubinomjeri koji mjere dubinu iz povratnog zvučnog signala poznavajući njegovu brzinu i vrijeme kretanja kroz medij. Uz tako dobivenu dubinu i korištenjem GNSS-a za određivanje položajnih koordinata započinje šira primjena zvučne batimetrije. Iako je jednosnopni zvučni dubinomjer znatno unaprijedio mjerenje dubina, daljnjim razvojem, povećana je i pokrivenost zvučnim signalima tako da se jedan snop signala proširio lepezom snopova iz čega se razvijaju višesnopni zvučni dubinomjeri. Lepeza snopova omogućuje veću pokrivenost dna i stupanj detaljnosti koji nije bilo moguće dobiti jednosnopnim dubinomjerom. Sav napredak i poboljšanja osim kroz prikupljanje većeg broja podataka manifestiraju se i u krajnjem rezultatu za korisnika, 2D i 3D modelima, hipsometrijskim prikazima, nautičkim i batimetrijskim kartama, prikazima kota morskog dna itd.

2. Metoda rada ultrazvučnog dubinomjera

Ultrazvučni dubinomjer je uređaj koji služi za mjerenje dubina u morima, rijekama i jezerima oslanjajući se na zakone akustike u vodi. Zvučni signal odašilje se sa sonde i odbija od objekta ili morskog dna i bilježi se vrijeme povratne jeke. Na temelju poznate brzine zvuka u vodi i proteklog vremena dobiva se dubina. Njemački izumitelj Alexander Behm patentirao je izum zvučnog dubinomjera (uređaj za mjerenje dubine mora i udaljenosti i smjera brodova ili prepreka pomoću reflektiranih zvučnih valova) 22. srpnja 1913. (Schneider, 2013). Višesnopni dubinomjer je razvijen ranih 1960-ih godina u SAD-u u vojne svrhe (URL 2).

Osim vremena prolaska zvučnog signala (dubine) neki ultrazvučni dubinomjeri imaju opciju registracije jačine povratnog zvučnog signala te je na taj način moguće dobiti drugačiju sliku vodnog dna u odnosu na dubinski prikaz. Intenzitet odnosno jačina povratnog signala otvara nove mogućnosti klasifikacije vodne podloge o čemu će se više pisati u nastavku.
Određivanje dubine i pozicije ostvaruje se integracijom više senzora i podsustava koji čine jednu složenu



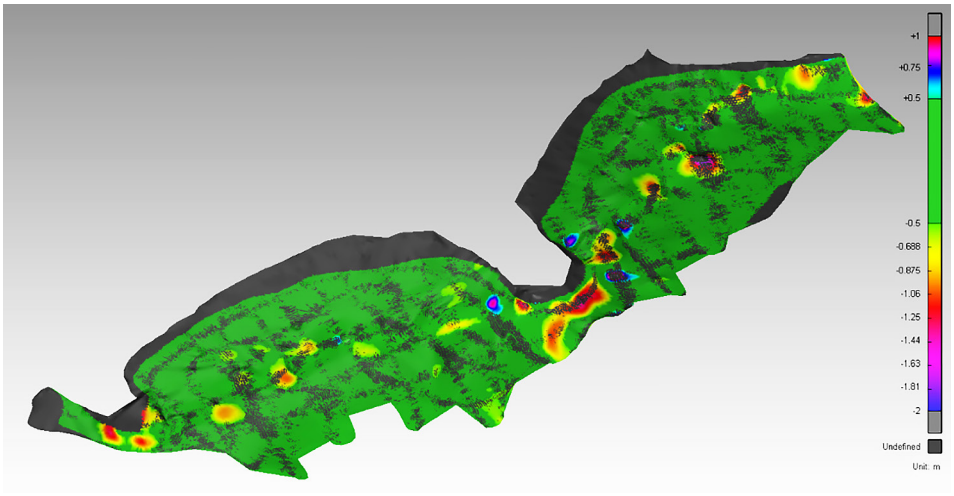
Slika 1: Izmjerene dubine jednosnopnim (lijevo) i višesnopnim dubinomjerom (desno).

cjelinu. Sastavne dijelove čine sustav navigacije, inercijalni sustav, ultrazvučni dubinomjer i procesorska jedinica za obradu i prikupljanje podataka. Kako bi se ostvarila mjerenja dubine potrebno je poznavati i brzinu zvuka u sredstvu kroz koje prolazi. Brzina zvuka u vodi je oko 1500 m/s, no zbog tlaka, saliniteta i temperature ona može varirati (International Hydrographic Organization, 2005). Većoj točnosti i preciznosti podataka doprinosi poznavanje profila brzine zvuka na području izmjere. Profil se dobije iz instrumenta koji se uranja u vodu, spušta do morskog dna i potom izvadi iz vode. Instrument bilježi širenje zvuka u vodi na različitim dubinama i potom formira profil brzine zvuka. Prilikom postavljanja ultrazvučnog dubinomjera, odnosno sonde na plovilo teško je postići da se referentne ravnine sonde podudaraju s referentnim ravninama plovila te se kao rezultat tog neslaganja pojavljuju linearne i kutne fiksne vrijednosti u smjeru sve tri osi (CARIS HIPS and SIPS 11.3 2020). Njihove vrijednosti dobivaju se kalibracijom dubinomjera te se uzimaju u obzir kod korekcije mjerenja. Također, potrebno je u svakom trenutku registracije dubina poznavati položaj plovila u odnosu na idealan vertikalni položaj u polju sile teže što se isto prikazuje kutovima otklona: valjanje, ljuljanje i posrtanje (Kongsberg Maritime AS, 2021). Navedene korekcije bitno je spomenuti za nastavak ovog rada, no potrebno je primijeniti i druge redukcije na mjerene dubine kako bi se dobile reducirane dubine.

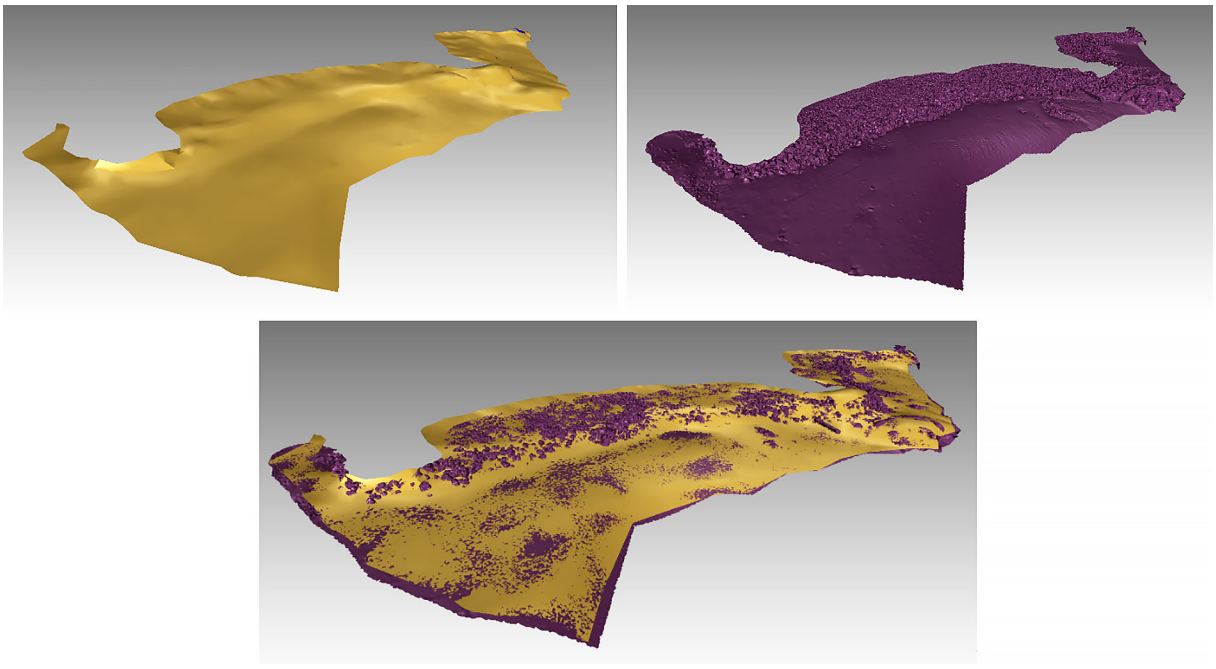
3. Jednosnopni i višesnopni ultrazvučni dubinomjeri

Osnovna razlika jednosnopnog i višesnopnog dubinomjera je broj snopova zvučnih valova koji su emitirani iz sonde prema vodnom dnu i čija će se jeka registrirati na povratku. Posljedično, višesnopni dubinomjer istovremeno mjeri dubine na širem zahvatu u obliku lepeze. Jednosnopni dubinomjer mjeri dubine neposredno ispod sonde i kao rezultat dobiva u svakom trenutku jednu dubinu, dok višesnopni dubinomjer dobiva više kolinearnih dubina (domet ovisan o dubini vode, mogućim preprekama i odabranoj širini snopa) okomitih na smjer kretanja, odnosno na trajektoriju (Slika 1).

Kako bi se izveo zadani projekt i zadovoljilo zadano mjerilo krajnjih prikaza morskog dna, kod jednosnopnog dubinomjera potrebno je pomno isplanirati trajektoriju na način da dijelovi trajektorije na kojima su izmjerene dubine nisu udaljeni više od zadane rezolucije. Za razliku od jednosnopnog, kod višesnopnog dubinomjera raspolažemo širokim snopom podataka u svakom trenutku registracije mjerenja. Međutim, u slučaju velikih dubina, bržeg kretanja plovila i zahtijevanih krupnih mjerila (npr. na 50 m dubine rezolucije 0,5 m) treba imati na umu ograničenja višesnopnog dubinomjera. Zbog velike razlike



Slika 2: Razlika ploha dobivenih iz dva neovisna mjerenja jednosnopnim dubinomjerom.



Slika 3: 3D plohe podmorja plaže Ploče dobivene iz jednosnopnih mjerenja (žuta ploha) i višesnopnih mjerenja (ljubičasta ploha).

u količini dobivenih podataka detaljnost vodnog dna na prikazima je neusporediva. U svakom trenutku jednosnopni dubinomjer dobiva jedan podatak dok višesnopni i do 1024 podataka o dubini.

3.1 Jedan snop

Jednosnopnim dubinomjerom Teledyne Odom izmjerene su dubine u priobalju plaže Ploče na području Kantride u Rijeci. Dobiveni podaci rezultat su registracije dubina za fiksna GNSS rješenja RTK. Mjerenja su obavljena više puta u sklopu projekta „Održiva gradnja plaža – gradnja novih i povećanje kapaciteta postojećih plaža (Beachex)“ u suradnji Geodetskog zavoda Rijeka d.o.o. s građevinskim fakultetima iz Rijeke i Zagreba. Iz navedenih neovisnih mjerenja se može lako uočiti jedan od glavnih nedostataka jednosnopnog dubinomjera. Dubine koje su izmjerene direktno su vezane za trajektoriju plovila obzirom da su mjerene u uskom snopu u smjeru vertikale na morsku površinu. Na taj način dobivamo lokalnu informaciju o dubini.

Usporedimo li ova mjerenja, primjećujemo i neke znatne razlike u dubinama na kreiranim plohama morskog dna što prikazuje Slika 2. Uzrok tome je različita putanja plovila tijekom mjerenja i posljedično identifikacija drugačijih detalja na morskom dnu. Razlike u dubinama, odnosno kreiranim prikazima morskog dna najviše su izražene na područjima gdje se dubina izražajnije mijenja – podvodne kosine, područja velikog, grubog materijala, grebeni itd., dok na relativno ujednačenom, homogenom morskom dnu nema velikih razlika između mjerenja.

3.2 Lepeza snopova

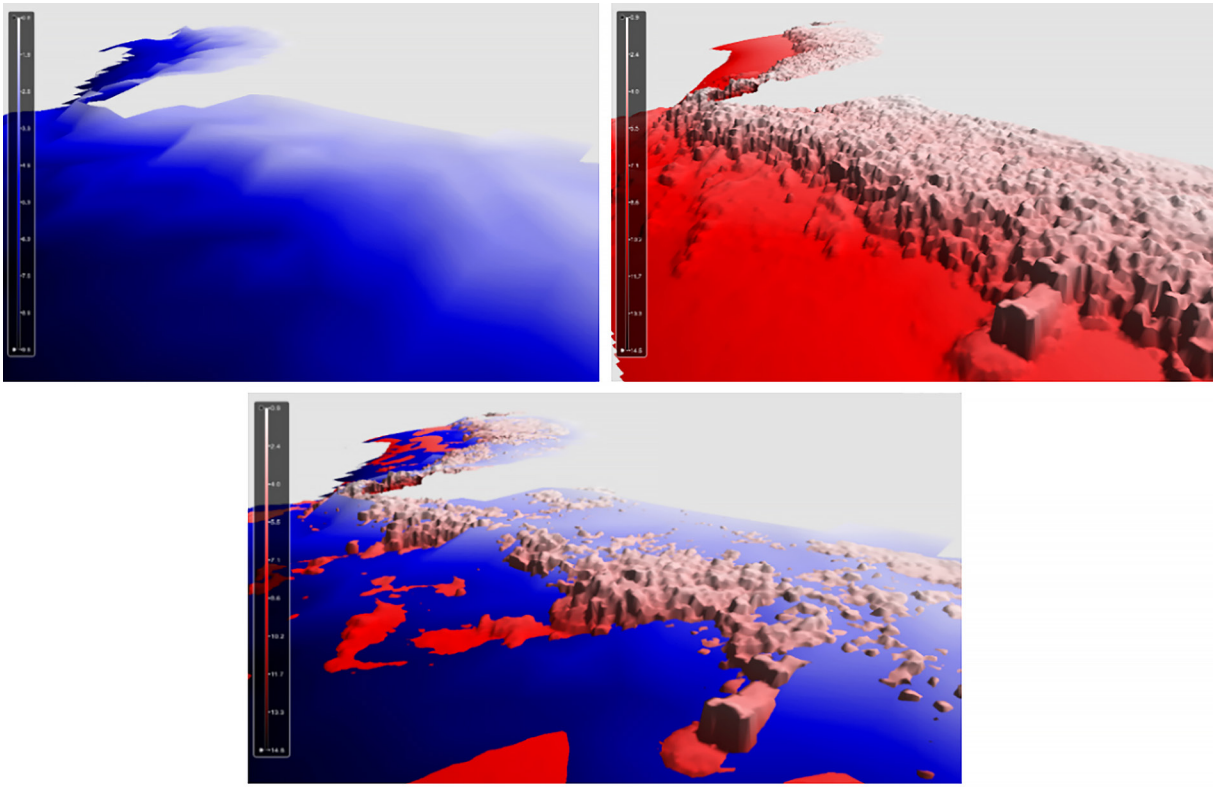
Na istom području izvršena je hidrografska izmjera višesnopnim dubinomjerom s jednom sondom tvrtke Kongsberg. Slika 3 prikazuje plohe (engl. Mesh) koje predstavljaju izgled morskog dna plaže. Lijevi prikaz (žuta ploha) je ploha nastala iz mjerenja jednosnopnim dubinomjerom dok je desna (ljubičasta ploha) ploha nastala iz podataka višesnopnog dubinomjera.

Iz slika se jasno vidi koliko je razvoj višesnopnog dubinomjera pridonio realnosti prikaza dok je ploha dobivena iz podataka jednosnopnog dubinomjera grublja aproksimacija morskog dna. Osim toga, puno objekata na morskom dnu uopće nisu vidljivi na žutoj plohi što je posljedica jednog vertikalnog snopa i velikih ''rupa'' u podacima između trajektorije kod jednosnopnog dubinomjera. Slika 4 prikazuje dvije plohe od kojih je plavom bojom označena ploha jednosnopnog, a crvenom višesnopnog dubinomjera. Upravo je tu vidljivo kako osim grube aproksimacije kamenitog, razvedenog dijela dna na lijevoj slici nedostaje i detalj – podvodni ispust vidljiv na prikazu višesnopnog dubinomjera.

Pojam ''sjena'' u jeziku sonara odnosi se na dijelove bez podataka koji su nastali zbog prepreka na putu sonda-objekt izmjere. Kroz obradu se manifestira kao nedostatak podataka odnosno ''rupa'' kod jednog snopa kao i kod lepeze snopova ukoliko zvučni signal naiđe na prepreku (umjetna prepreka ili dio morskog dna) te onemogući detekciju dijela morskog dna.

3.3 Široka lepeza

Višesnopni dubinomjer danas je osnova za izvođenje geodetskih radova u sklopu hidrografske izmjere te ovjeru službenih hidrografskih elaborata. Razvoj višesnopnog dubinomjera omogućio je postavljanje strožih zahtjeva u okviru preciznosti i točnosti prikaza vodnog dna. Osnovni standard koji se mora zadovoljiti prilikom izrade službenih hidrografskih produkata



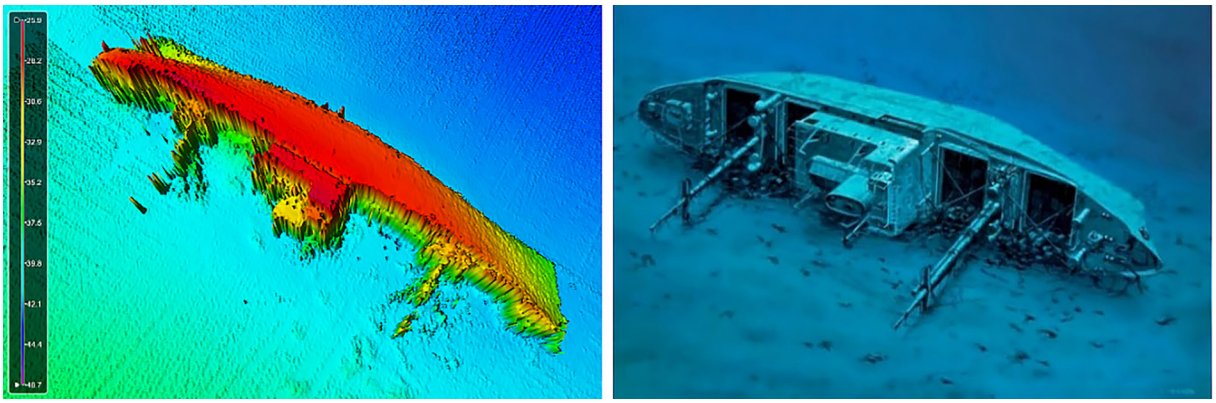
Slika 4: 3D plohe podmorja plaže Ploče dobivene iz jednosnopnih mjerenja (plava ploha) i višesnopnih mjerenja (crvena ploha) – prikaz detalja.

je IHO S-44 (International Hydrographic Organization, 2020). Velik broj podataka daje opsežne informacije, no treba prepoznati krive podatke zbog nepravilne disperzije zvučnih signala, pojave šumova ili detekcije podvodnih elemenata koji nisu morsko dno. Eliminacija ovih utjecaja vrši se uslijed obrade 3D oblaka točaka mjerenja primjenom raznih operacija nad podacima u programima za obradu. U ovom radu korišten je program za obradu i prikaz hidrografskih mjerenja HIPS and SIPS tvrtke CARIS (URL 3).

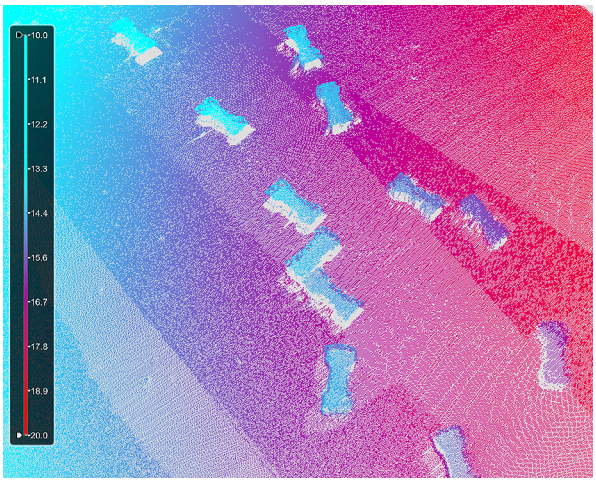
Trodimenzionalni prikazi našli su svoju primjenu i u identifikaciji podmorskih olupina. Slika 5 predstavlja realističan prikaz olupine broda Elhawi Star potonulog 12. listopada 1982. godine. Brod je potonuo zbog neravnomjernog utovara tereta (keramičkih pločica i drvene građe) na oko 35 metara dubine u akvatoriju ispred sušačkog dijela Luke Rijeka Porto Baroša. Skalom boja od crvene do ljubičaste prikazana je dubina gdje crvena predstavlja pliće dijelove. Pored 3D plohe olupine i morskog dna nalazi se ilustracija (URL 4) istog broda.

Poznavanje položaja i pripadajuće dubine objekata pod vodom ključni su u procesu planiranja, gradnje i praćenja izvedenih radova te u održavanju podmorske lučne infrastrukture. Slika 6 prikazuje položene sidrene blokove unutar akvatorija Luke Rijeka u 3D oblaku točaka u rasponu boja od cijan (10 m dubine) do crvene (20 m dubine).

Slika 7 sadrži različite poglede na podvodne stupove mola. Stupovi su prikazani sivom bojom jer su to dijelovi 3D oblaka točaka (mjerenja) koji su isključeni iz računanja plohe morskog dna. Na istoj slici crnim ravnim linijama prikazana je izgrađena obala dok za-

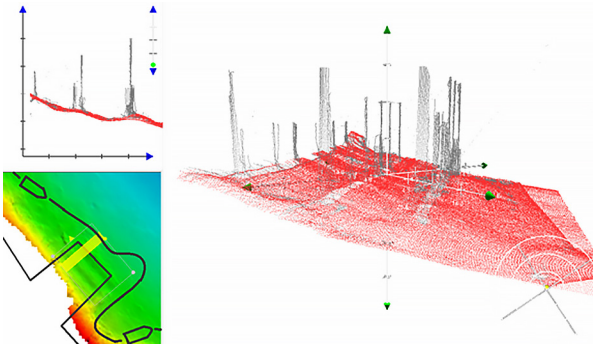


Slika 5: Olupina broda Elhawi Star u akvatoriju ispred luke Porto Baroš – 3D ploha (lijevo) i ilustracija (desno).



Slika 6: Sidreni blokovi prikazani u 3D oblaku točaka.

krivljena linija označena simbolom plovila predstavlja trajektoriju plovidbe. Na ovom primjeru je jasno vidljiva prednost širokog dometa više snopova. Mjerenje je izvršeno kretajući se pored mola gdje je bilo moguće pristupiti plovilom, a mjerene su dubine čak većeg dijela morskog dna i stupova ispod mola.



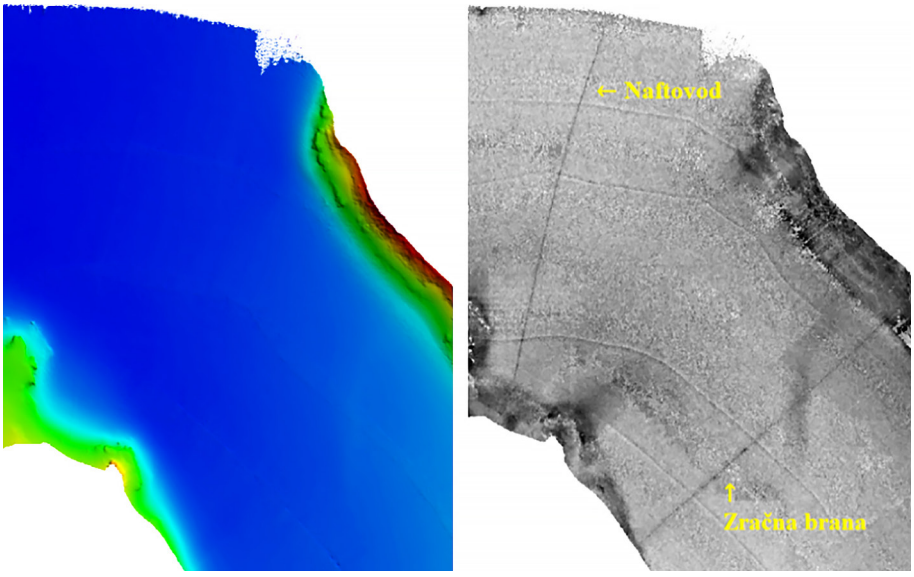
Slika 7: Nosivi stupovi i morsko dno ispod mola prikazani u 3D oblaku točaka.

Navedeno se može vidjeti na tlocrtnom pogledu (lijevo) gdje hipsometrijski prikaz morskog dna presijeca izgrađenu obalu. Osim vremena povratka zvuka (dubina) višesnopni dubinomjer bilježi i jačinu jeke (povratnog vala) te svaka mjerena točka dobiva atribut izražen u decibelima. Na takvim prikazima može se vidjeti ono što je u hipsometrijskim prikazima možda skriveno. Slika 8 prikazuje područje uz JANAF u Omišlju na otoku Krku. Iako su podvodni naftovod i zračna brana označeni na nautičkim kartama, nisu bili jasno vidljivi na lijevom prikazu zbog velikih dubina i teškog razlučivanja objekta od šuma u oblaku točaka. Uključivanjem kanala zabilježenih decibela jasno se vidi položaj podvodnih naftovoda i zračne brane (crna boja). Cijevi su različitog materijala i teksture u odnosu na okolinu i zato imaju različit intenzitet.

Ukoliko se na temelju uzoraka poveže vrsta i materijal morskog dna sa zabilježenim vrijednostima jačine zvuka, moguće je provesti dodatne analize o vrsti materijala, biljnom pokrovu dna, potencijalnim nalazištima plina itd.

4. Zaključak

Pojava jednosnopnog ultrazvučnog dubinomjera dovela je do bitnog napretka kao zamjena za klasične metode, a kao budući naraštaj razvio se višesnopni ultrazvučni dubinomjer. Prikazi nastali iz mjerenja jednosnopnog i višesnopnog dubinomjera su neusporedivi, ali svaki nalazi svoju primjenu. Iako ogromna količina dobivenih podataka iz više snopova osigurava veću pokrivenost podacima i napredni stupanj detaljnosti sve do vrlo sitnih varijacija na morskom dnu, višesnopni sustav ima veću i složeniju konstrukciju te zahtjeva kompliciraniju montažu. Također, mali kutovi otklona i varijacije u brzini zvuka u vodenom stupcu imaju veći utjecaj na snopove koji su pod većim kutom otklonjeni u odnosu na vertikalu te je zbog toga sustav višesnopnog dubinomjera



Slika 8: Hipsometrijski prikaz (lijevo) i prikaz intenziteta povratnog zvuka (desno) na morskom području uz JANAF u Omišlju na otoku Krku.

osjetljiviji. Prikazi dobiveni mjerenjem jednosnopnim dubinomjerom pokazati će svoje prednosti kod zadataka gdje nije potrebna velika detaljnost, gdje je morsko dno vrlo ujednačeno i na područjima miješanja slane i slatke vode. Višesnopni sustav pruža nam realističan, detaljan i potpun prikaz morskog dna i kao današnji standard za precizna hidrografska mjerenja omogućuje efikasno upravljanje priobaljem i dnom ispod voda koje čine 71% površine planete na kojoj živimo.

Literatura

International Hydrographic Organization (2005): Manual on hydrography Publication C-13, 1st Edition Chapter 3, Monaco.

International Hydrographic Organization (2020): Standard for Hydrographic Surveys S-44 Edition 6.0.0, Principauté de Monaco.

Kongsberg Maritime AS (2021): Seafloor Information System Reference Manual Release 5.6 429004/E.

Schneider, W. (2013): Alexander Behm und 100 Jahre Echolotpatente, Hydrographische Nachrichten, 96, 11–14.

Teledyne CARIS (2020): Single Head Multibeam Data Calibration CARIS HIPS and SIPS 11.3 Manual.

URL 1: Batimetrija DGU,

https://dgu.gov.hr/geodetsko-informaticki-rjecnik/batimetrija/519, (26.5.2022.).

URL 2: A Note on Fifty Years of Multi-beam, https://web.archive.org/web/20140714230116/http://www.hydro-international.com/issues/articles/id1471-A_Note_on_Fifty_Years_ofMultibeam.html, (2.6.2022.).

URL 3: HIPS and SIPS, Teledyne Geospatial, https://www.teledynecaris.com/en/products/hips-and-sips/, (4.6.2022.).

URL 4: Elhawi Star – potonuće pred očima cijeloga grada,

https://lanterna-magazin.net/2021/06/23/elhawi-star-potonuce/, (9.6.2022.).

From a Single Beam to a Fan

Abstract

From ancient times there has been a need for nautical charts with accurately and precisely defined areas of shoals, ruins or other dangerous places which are extremely important for safe navigation in seas, rivers and lakes. Initially, the method of determining depth by lowering the weight chain and determining the position using intersections gave good enough results to define such areas, but increasing water traffic created a need for more efficient ways of determining depths. The emergence of the first echo sounders drastically developed bathymetry and simplified the identification of dangerous places, but wider application of single-beam echo sounders started with civilian use of GNSS technology (Global Navigation Satellite Systems). Furthermore, the development of social, economic and environmental aspects has created a need for a more advanced approach in measuring depths. With the invention of multi-beam echo sounders, which emit a range of beams, realistic three-dimensional representations of the seabed have become unavoidable for navigation, as well as for planning, design, construction and monitoring of changes caused by human or nature and for effective water management. This paper provides an overview of the differences in the views created from data acquired by single-beam and multi-beam echo sounders in the same sea area. Also, it will be shown how faithfully these images generated from data acquired by multi-beam echo sounder can represent the shape and size of objects located on the seabed.

Keywords: *bathymetry, multi-beam echo sounder, single-beam echo sounder, three-dimensional views*

Batimetrijska izmjera za potrebe sigurnosti plovidbe

***Ljerka Vrdoljak*[1]**

[1] Hrvatski hidrografski institut, Zrinsko-Frankopanska 161, Split, Hrvatska, ljerka.vrdoljak@hhi.hr

Sažetak

Hidrografska djelatnost primarno je usmjerena na sigurnost pomorskog prometa u vidu očuvanja ljudskih života, okoliša i materijalnih dobara te je također osnova svih aktivnosti vezanih uz gospodarenje i istraživanje mora. Hidrografska djelatnost pravno je definirana zakonima i standardima kako bi podaci prikazani na pomorskim kartama kvalitetom zadovoljili zahtjeve sigurnosti. U radu je dan pregled zakona i standarda na međunarodnom i nacionalnom nivou te je analiziran status hidrografske izmjere. Navedeni su instrumenti i tehnologije koje Hrvatski hidrografski institut koristi za izmjeru dubina te detekciju prirodnih i umjetnih objekata na morskom dnu. Napravljen je osvrt na nove tehnologije koje se koriste pri izmjeri i obradi batimetrijskih podataka.

Ključne riječi: *akustični batimetrijski sustavi, GeoAdriatic, hidrografski standardi, Hrvatski hidrografski institut, nove tehnologije*

1. Uvod

More i morsko dno izvor su prirodnih bogatstava, dok se na površini odvija transport ljudi i dobara koji obuhvaća velik dio svjetske trgovine. Hidrografska djelatnost osnova je svih aktivnosti na moru, ispod površine mora i u podzemlju, uključujući sigurnost plovidbe, obranu i sigurnost na moru, ribarenje, zaštitu okoliša, određivanje pomorskih granica, trgovinu na moru, turizam i znanstvena istraživanja.

Obalne države zadužene su za sigurnost plovidbe pri čemu posebnu važnost imaju plovni putovi i lučka područja. Hidrografsku djelatnost potrebno je pravno definirati zakonima i standardima kako bi podaci prikazani na pomorskim kartama zadovoljili uniformnu razinu kvalitete na međunarodnoj razini. Republika Hrvatska kao članica Međunarodne hidrografske organizacije (engl. International Hydrographic Organization - IHO) i potpisnica međunarodne Konvencije o zaštiti ljudskih života na moru (engl. International Convention for the Safety of Life at Sea - SOLAS) dužna je u sklopu hidrografske djelatnosti prikupljati, obrađivati i pohranjivati podatke za izradu nautičkih pomorskih karata te iste održavati ažurnima. Podaci trebaju biti globalno dostupni i u skladu s međunarodnim standardima.

2. Pravni okvir

Standardi i zakoni koji definiraju hidrografsku djelatnost donose se na dva nivoa različita po sadržaju, namjeni i provođenju, međunarodnom i nacionalnom.

2.1. Sveobuhvatni međunarodni standardi

Međunarodna pomorska organizacija (engl. International Maritime Organization - IMO) razvija međunarodni regulatorni okvir za morsku plovidbu, dok Međunarodna hidrografska organizacija (IHO) ima isti zadatak na području hidrografske djelatnosti. Republika Hrvatska član je obiju organizacija i razvija svoj nacionalni pravni okvir u skladu s međunarodnim i europskim konvencijama, standardima i preporukama.

Republika Hrvatska (RH) je kao članica IMO-a potpisnica međunarodne konvencije o zaštiti ljudskih života na moru (SOLAS) (IMO, 1974). SOLAS, poglavlje 5, regulativa IX, odnosi se na hidrografske ustanove i servise, odnosno dužnosti zemalja potpisnica da iste omoguće. Dužnost RH je da u sklopu hidrografske djelatnosti prikuplja, obrađuje i pohranjuje podatke potrebne za izradu nautičkih pomorskih karata te da iste izdaje i održava ažurnima. Podaci bi trebali biti globalno dostupni i standardizirani sukladno međunarodnim standardima.

Najviši nivo općih standarda za hidrografiju su oni standardi koje izdaje Međunarodna hidrografska organizacija (IHO). Standardi IHO-a su osnova iz koje svaka država, na temelju svojih specifičnih potreba, definira nacionalne standarde. Smisao IHO - ovog standarda je osigurati globalnu uniformnu kvalitetu hidrografskih podataka na nautičkim pomorskih kartama. IHO-ovi međunarodni standardi za hidrografiju dostupni su na njihovim internetskim stranicama (URL 1). Standard za hidrografske izmjere S-44 postavlja minimalne uvjete koje moraju zadovoljiti mjerenja u svrhu sigurne površinske navigacije, koji se tamo gdje je potrebno mogu pooštriti (IHO, 2020) (Tablica 1). Najnoviji S-44, verzija 6.0.0., izdan je 2020. godine.

Tablica 1: Kategorije izmjere prema S-44 v. 6.0.0. standardu (IHO, 2020)

Kategorija	2	1b	1a	Posebni uvjeti	Izuzetni uvjeti
THU	20 m + 10%d	5 m + 5%d	5 m + 5%d	2 m	1 m
TVU	a=1.0 m b=0.023	a=0.5 m b=0.013	a=0.5 m b=0.013	a=0.25 m b=0.0075	a=0.15 m b=0.0075
Pretraga morskog dna	Neobavezno	Neobavezno	100%	100%	200%
Preciznost otkrivanja objekata	Nedefinirano	Nedefinirano	Kubični objekti > 2m, do 40 m dub. inače 10% d	Kubični objekti > 1m	Kubični objekti > 0.5 m
Gustoća izmjere [%]	5%	5%	≤100%	100%	200%

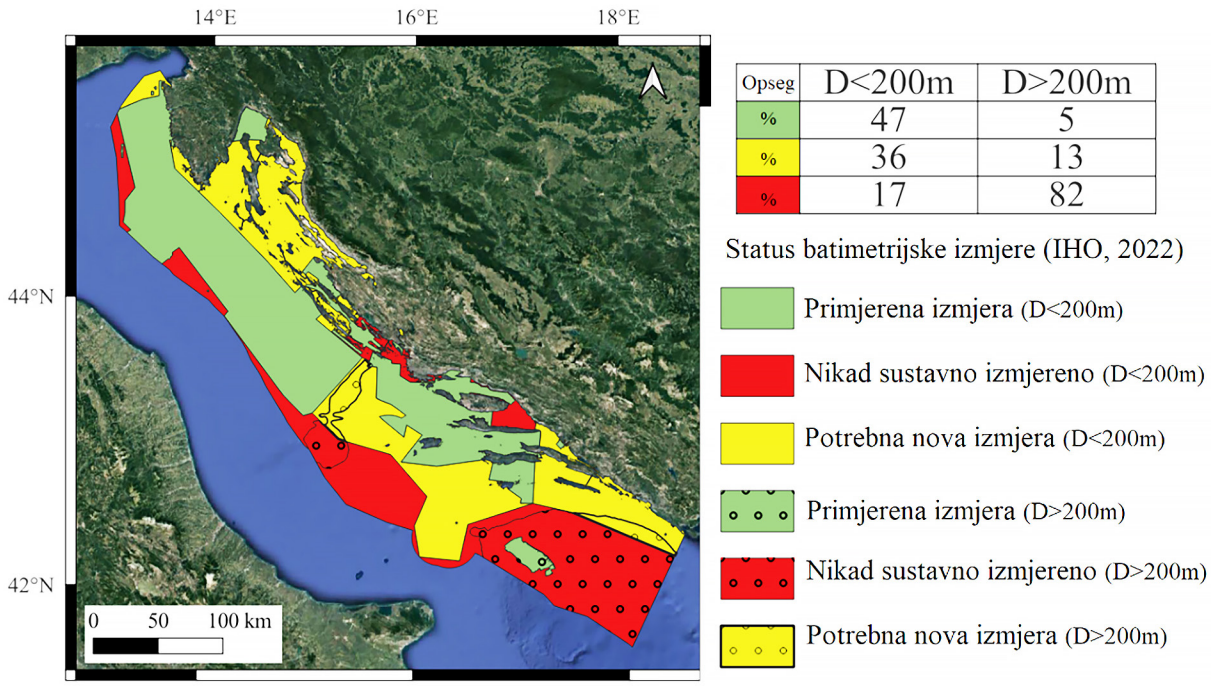
***THU** Ukupna horizontalna nesigurnost, **TVU** Ukupna vertikalna nesigurnost $TVU = \sqrt{(a^2+(bxd)^2}$

2.2. Nacionalni pravni okvir

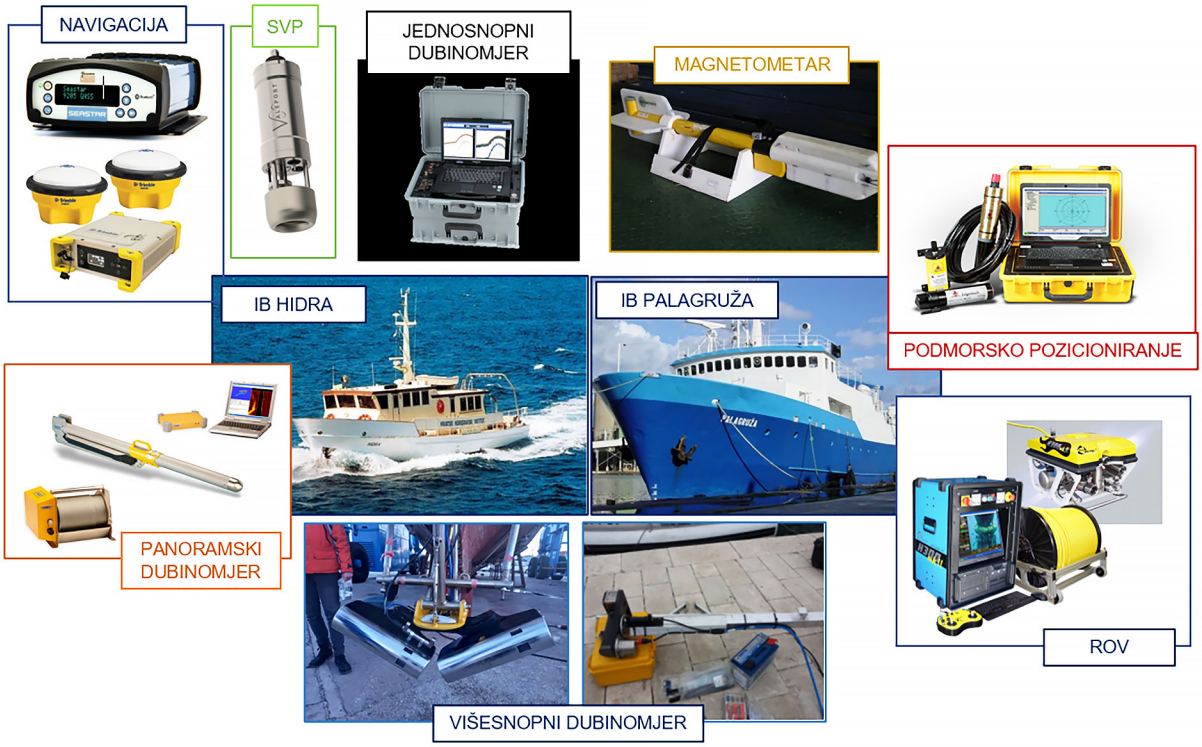
Hidrografska djelatnost u Republici Hrvatskoj je regulirana Zakonom o hidrografskoj djelatnosti, NN 71/2014. Zakon propisuje sadržaj, uvjet i način obavljanja hidrografske djelatnosti te određuje Hrvatski hidrografski institut pravnom osobom za obavljanje hidrografskih djelatnosti od interesa za Republiku Hrvatsku. Hidrografska djelatnost u smislu ovog zakona, obuhvaća izmjeru dubine mora, rijeka i jezera, geodetska i druga snimanja objekata u priobalju, u moru, na morskome dnu i podmorju, marinsku geodeziju, oceanologiju, geologiju i geofiziku mora, zaštitu okoliša, obradu i pohranjivanje podataka prikupljenih izmjerom, snimanjem i istraživanjem te njihovu objavu u svrhu navigacijskog osiguranja plovidbe morem, rijekama i jezerima te obavljanje istraživačkih, gospodarskih i drugih radova. Svrha hidrografskog istraživanja je osigurati sigurnost plovidbe s ciljem zaštite ljudskih života i imovine na moru te zaštitu okoliša, istraživanje i gospodarenje morem.

Hrvatski hidrografski institut (HHI) hidrografsku djelatnost od interesa za Republiku Hrvatsku obavlja kao javna ustanova. Djelatnosti HHI-a, među ostalim, obuhvaćaju hidrografsku izmjeru (batimetrijska snimanja, geologija i geofizika mora) od značaja za sigurnost plovidbe te izradu, izdavanje i održavanje službenih pomorskih navigacijskih karata u skladu s preporukama Međunarodne hidrografske organizacije (IHO) i Međunarodne pomorske organizacije (IMO). Podaci koje prikupi i obradi HHI su službeni podaci.

Podaci hidrografske izmjere koje prikupe i obrade pravne osobe ovlaštene za obavljanje poslova hidro-



Slika 1: Status batimetrijske izmjere u hrvatskom dijelu Jadranskog mora (IHO, 2022)



Slika 2: Istraživački brodovi i oprema Hrvatskog hidrografskog instituta za potrebe batimetrijske izmjere (URL 3)

grafske izmjere postaju službeni kada ih pregledaju i ovjere ovlaštene osobe HHI-a. Postupak stjecanja ovlaštenja i razine ovlaštenja, sadržaj, pregled i ovjera hidrografskih elaborata definirani su Pravilnikom o uvjetima i načinu obavljanja djelatnosti hidrografske izmjere ovlaštenih pravnih osoba, NN 120/2018.

3. Izmjera morskog dna

Obalne države zadužene su za sigurnost plovidbe teritorijalnim morem, pri čemu posebnu važnost imaju plovni putovi i lučka područja. Podaci prikupljeni batimetrijskom izmjerom koriste se za izradu i ažuriranje pomorskih karata što u konačnici dovodi do povećanja sigurnosti na moru, bolje zaštite okoliša i općenitog doprinosa svim aktivnostima vezanim uz more. Hrvatski portal prostornih podataka o moru – GeoAdriatic pruža usluge pretraživanja i pregleda prostornih podataka o moru i e-usluga iz područja nadležnosti Hrvatskog hidrografskog instituta, uključujući Preglednik službenih hidrografskih izmjera i Registar hidrografskih izmjera ovlaštenih pravnih osoba (URL 2). Na Slici 1 prikazan je status izmjere hrvatskog dijela Jadranskog mora prema podacima IHO-a (IHO, 2022).

3.1. Istraživački brodovi i oprema Hrvatskog hidrografskog instituta

Hrvatski hidrografski institut ima dva istraživačka broda i manje brodice, namijenjene za kvalitetno obavljanje poslova hidrografske izmjere koja uz batimetrijsku izmjeru obuhvaća geološko istraživanje podmorja, magnetometrijsku detekciju i oceanografska istraživanja. Manji istraživački brod Hidra (duljina 22 m) upotrebljava se za obalne i priobalne radove u međuotočnom i teritorijalnom dijelu hrvatskog dijela Jadranskog mora. Istraživački brod Palagruža (duljina 45,50 m) upotrebljava se za radove na otvorenom moru u hrvatskom dijelu Jadranskog mora (URL 3). Brodovi ispunjavaju zahtjeve i potrebe hidrografske, kartografske i oceanološke djelatnosti HHI-a, što je neophodno za praćenje stanja i održavanje baze podataka za hrvatski dio Jadrana. Pregled prostornih podataka i usluga iz nadležnosti HHI-a moguć je putem Hrvatskog portala prostornih podataka o moru, GeoAdriatic (URL 2). Oprema koja se koristi na brodovima, prati najsuvremenije trendove razvoja računalne i instrumentalne mjerne tehnologije u svijetu na području istraživanja mora i podmorja (Slika 2).

U Tablici 2 je dan pregled modernih uređaja za snimanje morskog dna koje koristi Hrvatski hidrografski institut za izmjeru dubina i detekciju prirodnih i umjetnih objekata na morskom dnu, a čiji su podaci kvalitetom u mogućnosti zadovoljiti najvišu kategoriju izmjere prema S-44 pravilniku (Tablica 1).

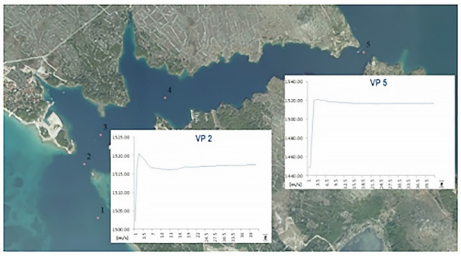
3.2. Digitalni batimetrijski model morskog dna

Moderni višesnopni dubinomjeri (engl. Multibeam echosounder - MB) su instrumenti za mjerenje dubina koji omogućuju potpunu pretragu morskog dna, a kvalitetom podataka dubine zadovoljavaju uvjete najviše kategorije izmjere definirane S-44 standardom. Digitalni batimetrijski model (engl. Digital bathymetric model - DBM) nastao na temelju podataka izmjere višesnopnim dubinomjerom je temeljni izvor

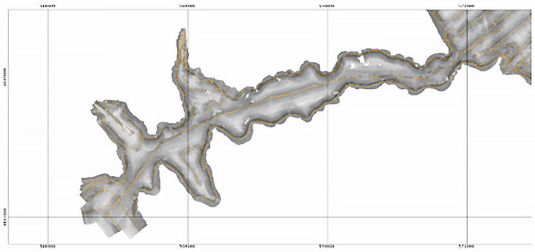
Tablica 2: Oprema HHI-a za batimetrijsku izmjeru

	Instrument	Model	Svrha/Produkt
1	Diferencijalni GPS (DGPS)	DGPS System Fugro SeaSTAR 9205	Navigacija
2	RTK GNSS prijamnik	Trimble MPS 865 RTK	Navigacija; Korekcija za morsku mijenu
3	Sonda za određivanje brzine zvuka (SVP)	Valeport SWiFT SVP Profiler	Brzina zvuka u stupcu mora
4	Jednosnopni dubinomjer	Echotrac CVM – Teledyne Odom Hydrographic	Dubina
5	Višesnopni dubinomjer	Reson SeaBat T20-P Reson SeaBat T50-R	Digitalni batimetrijski model
6	Panoramski dubinomjer	Side Scan Sonar CM2 C-Max	Slika morskog dna; detekcija objekata
7	Magnetometar	Cesium Marine Magnetometer – Geometric Model G-882	Promjena u magnetskom polju; detekcija metalnih objekata
8	Podmorsko vozilo na daljinsko upravljanje	ROV – H300 MK II – ECA Hytech	Pregled objekata
9	Sustav za povodno pozicioniranje	Underwater Positioning System – USBL Edgetech Bats	Pozicioniranje ROV-a, SSS-a i sl.

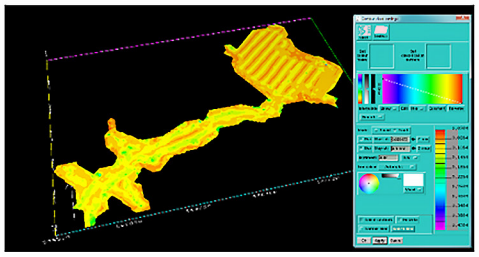
I kalibracija i priprema sustava za izmjeru



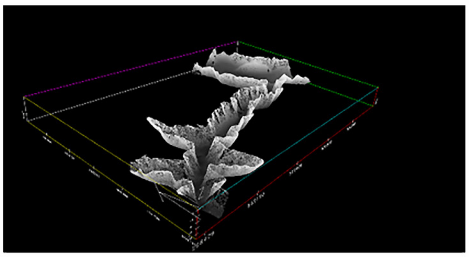
II Izmjera



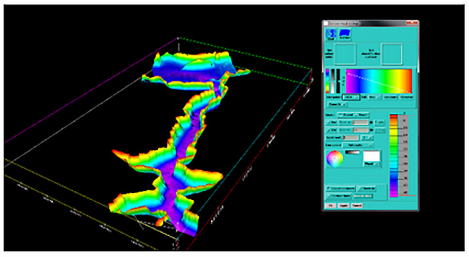
III Obrada podataka



IV Rezultat – oblak točaka



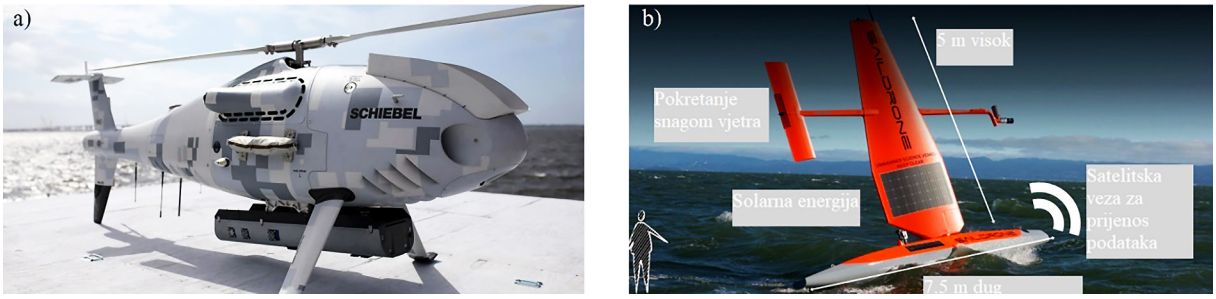
V Digitalni batimetrijski model



VI Pomorska navigacijska karta



Slika 3: Koncept batimetrijske izmjere u svrhu sigurnosti plovidbe (HHI, 2013, URL 3)



Slika 4: (a) Bespilotni helikopter (UAS) opremljen Fugro RAMMS batimetrijskim LiDAR sustavom (URL 6), (b) Saildrone autonomna brodica (URL 8)

podataka o dubina morskog dna za potrebe izrade pomorskih karata. Primjer područja batimetrijske izmjere za potrebe izrade pomorske karte je Kanal sv. Ante na ulazu u luku Šibenik.

Kanal sv. Ante je dužine 2700 m i širine od 120 m do 300 m te omogućava nesmetanu plovidbu i uplovljavanje u luku Šibenik brodovima do 50 000 DWT. S obzirom da je to prilazni plovni put putničkoj i teretnoj luci s dubinama do 47 metra prema S-44 standardu spada u područje posebne kategorije batimetrijske izmjere. Batimetrijska izmjera Kanala sv. Ante provedena je u prosincu 2013. godine s konačnim ciljem izrade prilazne pomorske karte: Šibenski kanal (Slika 3). Prilikom izmjere korišten je MB sustav Kongsberg EM 3002 postavljen na istraživačkom brodu Hidra.

4. Nova i nadolazeća rješenja u hidrografiji

Nedostatak modernih akustičnih sustava za izmjeru morskog dna je njihovo dugotrajno vrijeme izmjere, posebice u plitkom obalnom dijelu gdje se širina snopa smanjuje. Klasična hidrografska istraživanja povezana su s brodom kao platformom, s velikim brojem stručnjaka. Specifičnost morfologije morskog dna ili umjetni objekti onemogućavaju automatsku obradu podataka izmjere primjenom različitih statističkih filtera što produžuje vrijeme izrade batimetrijskog modela. Razvoj tehnologije omogućava poboljšanje batimetrijske izmjere i obrade podataka.

LiDAR (engl. Light Detection and Ranging) je sustav za snimanje dubina koji koristi dvije laserske zrake, jednu iz infracrvenog dijela spektra, a drugu iz spektra vidljive svjetlosti. Dubina se određuje na temelju vremena dvostrukog putovanja laserskog signala. Najnoviji modeli LiDAR-skih instrumenata kvalitetom podataka mogu zadovoljiti najviše kategoriju izmjere 1a (Tablica 1) te su ograničeni na područja plitkih mora (maks. 75 m) (URL 4, URL 5). Uglavnom se postavljaju na avion kao platformu. U vojne svrhe razvija se koncept bespilotnih letjelica koje su opremljene vrhunskim LiDAR-skim instrumentima (Slika 4a) (URL 6). Satelitska misija ICESat primjer je početka razvoja satelitskog batimetrijskog LiDAR-skog sustava.

Alternativa klasičnim batimetrijskim metoda u morskim područjima do 30 metara je batimetrija na temelju multispektralnih (MS) satelitskih snimaka. Prostorna rezolucija batimetrijskog modela ovisi o rezoluciji MS snimki s nesigurnošću predviđanja dubine do 10 posto dubine (URL 7).

Posljednjih godina snažno se razvijaju i unaprjeđuju autonomne platforme (brodice i podvodne brodice) koje mogu nositi različite batimetrijske senzore, najčešće višesnopni dubinomjer (Slika 4b) (URL 8).

Primjenom umjetne inteligencije umjesto klasičnih statističkih filtera, pokušava se skratiti vrijeme obrade podataka. CARIS Mira jedno od rješenja (URL 9).

Literatura

Hrvatski hidrografski institut (HHI) (2013): Batimetrijska izmjera Kanala sv. Ante

Međunarodna hidrografska organizacija (IHO) (2020): Standards for Hydrographic Surveys S-44 v.6.0.0., IHO, Monaco.

Međunarodna hidrografska organizacija (IHO) (2022): IHO Publication C55: Status of Hydrographic Surveying and Charting Worldwide, IHO, Monaco

Međunarodna pomorska organizacija (IMO) (1974): International Convention for the Safety of Life at Sea – SOLAS

Narodne novine (2014): Zakon o hidrografskoj djelatnosti (NN 68/98, 110/98, 163/03, 71/14)

Narodne novine (2018): Pravilnikom o uvjetima i načinu obavljanja djelatnosti hidrografske izmjere ovlaštenih pravnih osoba (NN 120/2018)

URL 1: IHO Publication. https://iho.int/en/iho-publications, (25.06.2022.)

URL 2: GeoAdriatic portal. https://geoadriatic.hhi.hr/, (25.06.2022.)

URL 3: Hrvatski hidrografski institut. https://www.hhi.hr/, (25.06.2022.)

URL 4: Teledyne Optech Lida: CZMIL SuperNova. https://www.teledyneoptech.com/en/products/airborne-survey/czmil-supernova/, (25.06.2022.)

URL 5: Hexgon/Leica Geosystems: Bathymetric LiDAR Sensors. https://leica-geosystems.com/products/airborne-systems/bathymetric-lidar-sensors, (25.06.2022.)

URL 6: Fugro news. https://www.fugro.com/media-centre/news/fulldetails/2021/08/09/fugro-answers-geo-data-needs-in-remote-coastal-locations-with-new-uncrewed-capability, (25.06.2022.)

URL 7: IHO SDB Best Practice Project Team. https://iho.int/en/satellite-derived-bathymetry-best-practice-project-team-sdb-pt, (25.06.2022.)

URL 8: Saildrone. https://www.saildrone.com/, (25.06.2022.)

URL 9: CARIS Mira. https://www.teledynecaris.com/en/products/caris-sonar-noise-classifier/, (25.06.2022.)

Bathymetric Survey for Safety of Navigation

Abstract

The primary objective of the hydrography is to ensure safety of navigation, to avoid accidents, preserve environment and goods but also to underpin all activities related to the marine areas. It is necessary to establish a legal frame for hydrography to achieve uniform quality of data represented on nautical charts on international level. In this paper, a review of laws and standards related to hydrography on global and national level is presented as well as status of hydrographic survey in Croatia. A state-of-the-art modern technology for bathymetry mapping from Hydrographic Institute of the Republic of Croatia is presented with a review on forthcoming technology in hydrography.

Keywords: *acoustic bathymetry, GeoAdriatic, hydrographic standards, Hydrographic Institute of the Republic of Croatia, new technology*

Analiza obalnog plavljenja uz pomoć trodimenzionalnih oblaka točaka

Igor Ružić[1], Dado Jakupović[2], Andrea Tadić[3], Vedrana Petrović[4], Gorana Ljubičić[5], Nino Krvavica[6]

[1] Građevinski fakultet Sveučilišta u Rijeci, Radmile Matejčić 3, Rijeka, RH, iruzic@uniri.hr

[2] JU Zavod za prostorno uređenje PGŽ-a, Splitska 2/II, Rijeka, RH, dado.jakupovic@pgz.hr

[3] Građevinski fakultet Sveučilišta u Rijeci, Radmile Matejčić 3, Rijeka, RH, andrea.tadic @uniri.hr

[4] JU Zavod za prostorno uređenje PGŽ-a, Splitska 2/II, Rijeka, RH, vedrana.petrovic@pgz.hr

[5] JU Zavod za prostorno uređenje PGŽ-a, Splitska 2/II, Rijeka, RH, gorana.ljubicic@pgz.hr

[6] Građevinski fakultet Sveučilišta u Rijeci, Radmile Matejčić 3, Rijeka, RH, nino.krvavica @uniri.hr

Sažetak

U ovom radu prezentirani su rezultati istraživanja projekta „Analiza ugroženosti od obalnog plavljenja ranjivih naselja Primorsko-goranske županije (PGŽ)". Istraživanje je provedeno u suradnji Građevinskog fakulteta u Rijeci i JU Zavoda za prostorno uređenje PGŽ-a. Rezultati istraživanja će se koristiti za planiranje obalnog područja istraženih pilot područja. Preciznost i rezolucija dostupnih podloga pokazali su se kao najveći problem za detaljnu, pojedinačnu analizu obalnog plavljenja i obalne ranjivosti. Bez preciznih podataka nije moguće provesti kvalitetne analize obalnog plavljenja, propagacije valova i s time povezanih rizika. U ovom radu detaljno su ispitane ugroženosti naselja Cresa, Raba, Punta i Voloskog. Za odabrana područja su za provedena istraživanja izrađene adekvatne podloge visoke rezolucije (1 točka / 2 cm) i preciznosti (±5 cm). To je višestruko preciznije od predviđenih promjena razine mora (60 ± 15 cm) do kraja 21 st. Iz fotografija snimljenih bespilotnom letjelicom generirani su trodimenzionalni oblaci točaka. Njihova primjena omogućila je precizno kartiranje plavljenja obalnog područja za sadašnje stanje i u slučaju predviđenog podizanja razine mora zbog klimatskih promjena. Oblaci točaka su korišteni i kao podloga za numeričke simulacije valovanja na poplavljenim područjima. Uz pomoć trodimenzionalnih oblaka točaka tako je bilo moguće definirati potencijalne rizike uslijed zajedničkog djelovanja obalnog plavljenja i valovanja, što nije moguće provesti koristeći standardne podloge. Rezultati istraživanja dali su prostornu distribuciju obalnog plavljenja s mjerodavnim dubinama vode i značajnim visinama valova za sadašnje i predviđeno stanje. Korišteni oblaci točaka su i foto-realistični te pružaju mogućnost lakše vizualizacije dosega i dubina plavljenja što će pomoći prilikom prezentacije rezultata projekta lokalnom stanovništvu.

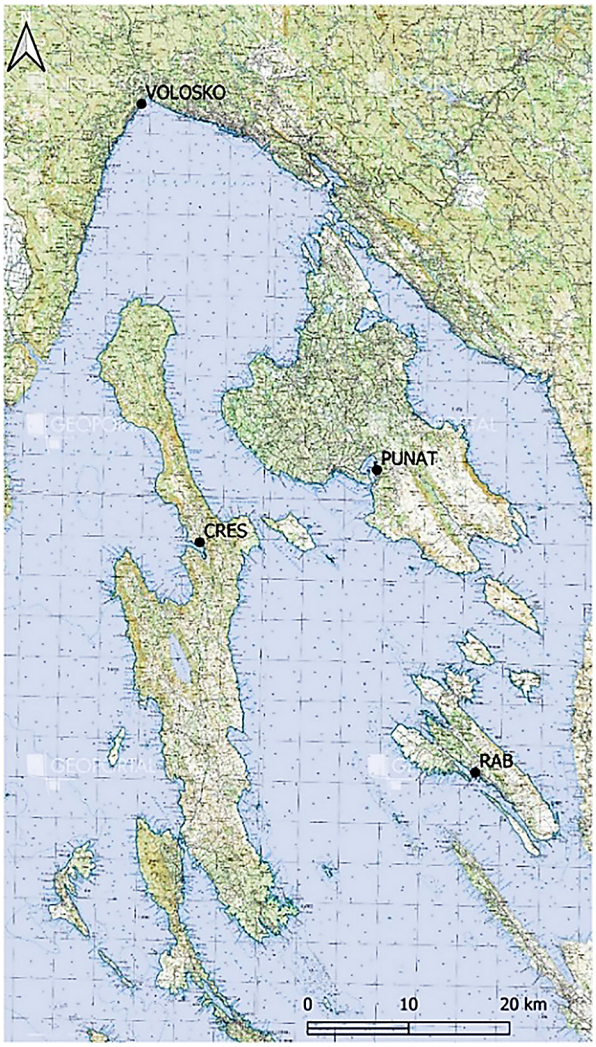
Ključne riječi: *bespilotna letjelica, klimatske promjene, obalno plavljenje, rast razine mora, trodimenzionalni oblak točaka.*

1. Uvod

U ovom radu provedena je analiza ugroženosti od obalnog plavljenja ranjivih naselja Primorsko-goranske županije: Cresa, Raba, Punta i Voloskog (Slika 1) korištenjem trodimenzionalnih (3D) oblaka točaka snimljenih pomoću bespilotne letjelice. Istraživanja su provedena u sklopu projekta „Analiza ugroženosti od obalnog plavljenja ranjivih naselja Primorsko-goranske županije (PGŽ)" (Građevinski fakultet u Rijeci, 2021). Procjena ranjivosti čitavog obalnog područja Primorsko-goranske županije (PGŽ) provedena je u sklopu projekta „Analiza ranjivosti obalnog područja Primorsko-goranske županije zbog podizanja razine mora" 2020. godine, na osnovu koje su detektirana ranjiva naselja.

Provedene su analize ranjivosti za sadašnje stanje i više scenarija podizanja morske razine (MR), koji se mogu prilagoditi i budućim scenarijima podizanja razine mora. Naime, predviđanja podizanja razine mora često se korigiraju zbog niza promjenjivih ulaznih parametara, dostupnosti preciznijih podloga, korištenja različitih modela i sl.

Već danas smo svjedoci sve češćeg i intenzivnijeg plavljenja obalnih naselja u Republici Hrvatskoj (RH), što će u budućnosti biti i puno izraženije s obzirom da se očekuje značajan porast razine mora od 19 – 33 cm do 2065. godine, te 32 – 65 cm do 2100. godine (RH, 2020). Prema nekim istraživanjima mogući su i nepovoljniji scenariji (Barić i dr., 2008). Osobito opasne mogu biti pojave olujnih uspora, ako se koincidiraju s plimom, vjetrovnim valovima i kretanjem mase vode prema plitkoj obali (Penzar i dr., 2001).



Slika 1: Pregledna karta obalnog područja PGŽ-a (URL 1)

Analize plavljenja obalnih naselja za današnje i predviđeno stanje provedene su korištenjem 3D oblaka točaka snimljenih pomoću bespilotne letjelice. To je omogućilo kvalitetne analize površina i dubina vode obalnog plavljenja, te djelovanja valova na plavljenim površinama, što je značajan napredak u odnosu na dosadašnja istraživanja koja su bila ograničena neadekvatnom preciznošću podloga (RH, 2020).

2. Metodologija

Snimanje naselja Cres, Rab, Punat i Volosko provela je tvrtka GEO-VV d.o.o. Rijeka. Snimanje iz zraka obavljeno je bespilotnom letjelicom DJI PHANTOM 4 Advanced (digitalna kamera DJI f = 24 mm). Izrada digitalne ortofoto karte visoke rezolucije i digitalnog modela terena obavljena je pomoću programa PIX4Dmapper (*photogrammetry and drone mapping*). Geodetsko snimanje pomoćnih i kontrolnih točaka izvršeno je pomoću dvofrekventnog satelitskog sustava za kinematiku, GNSS uređaja Trimble R4 i preciznom mjernom stanicom Trimble S8. Izmjera je obavljena u službenom položajnom (HTRS96) i visinskom (HVRS71) sustavu RH.

Analize i prikazi rezultata istraživanja obalnog plavljenja temeljeni su na produktima snimanja bespilotnom letjelicom: digitalnoj ortofoto (DOF) karti visoke rezolucije, digitalnom modelu terena (DMT) i 3D oblaku točaka. Prethodno analizama plavljenja, oblaci točaka su se „očistili" (vozila, plovila, vegetacija i sl.).

Numeričke simulacije valovanja provedene su pomoću numeričkog modela SWAN. Numerički model treće generacije za primjenu u obalnim područjima, *Simulating Waves Nearshore* (SWAN), temelji se na Eulerovoj formulaciji ravnotežne jednadžbe spektralnog valnog djelovanja (Booij i dr. 1999.). Provedene su numeričke simulacije valovanja 50-godišnjeg povratnog perioda za današnju visoku morsku razinu i u slučaju povećanja morske razine za 60, 120, 150 i 180 cm.

Rezultati istraživanja prikazani su u tekstualnom i digitalnom obliku (GIS), kao i u foto-realističnom prikazu u obliku 3D oblaka točaka (mjerilo 1 : 500 do 1 : 1.000), zbog lakšeg korištenja, odnosno razumijevanja lokalnog stanovništva za predviđene promjene.

3. Rezultati

Provedena je analiza plavljenja obalnih naselja Cresa, Raba, Punta i Voloskog (Slika 1) za najveću zabilježenu MR od 1,15 m n. m. i više scenarija podizanja razine mora.

3.1. Plavljenja obalnog područja grada Cresa

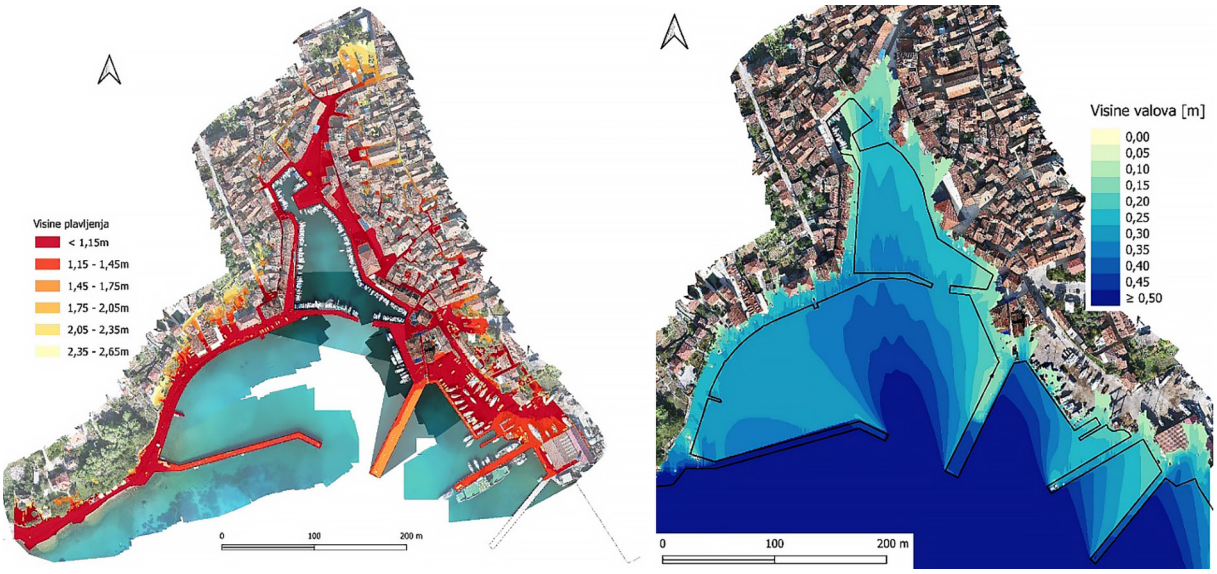
Posljednjih godina sve češće dolazi do plavljenja centra, odnosno stare jezgre grada Cresa. Uzrok tome je podizanje razine mora i slijeganje terena. Od XV. st., kada je formiran grad, do danas došlo je do podizanja srednje razine mora za više od 50 cm (Šegota, 1976).

Na Slici 2 prikazane su površine obalnog plavljenja grada Cresa za MR od 1,15 m n. m. do 2,65 m n. m. i značajne visine vala u slučaju porasta morske razine na 1,75 m n. m.

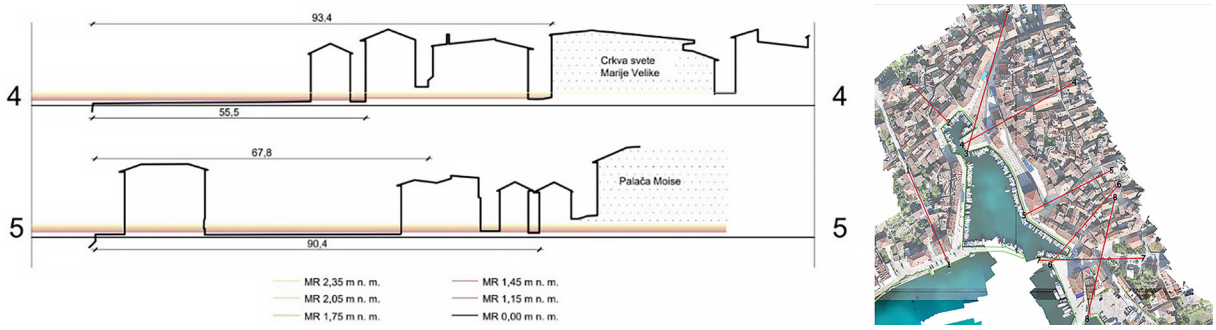
Danas već može doći do plavljenja površine veličine 24.439 m^2 u gradu Cresu, što je velika površina. Međutim, dubine plavljenja su male pa ne dolazi do značajnije materijalne štete. Porastom MR-a za 30, 60 i 90 cm može doći do plavljenja površina od 30.822, 33.758 i 35.763 m^2. Porastom MR-a ne dolazi do značajnog povećanja plavljenih površina zbog povećanja nagiba terena.

U slučaju porasta razine mora tijekom ekstremnih događaja za 60 cm mogu se javiti valovi viši od 30 cm na površinama zahvaćenim obalnim plavljenjem, s dubinama vode većim od 1 m (Slika 2), što dodatno povećava opasnosti i potencijalni nastanak oštećenja.

Kako bi se dobio dodatan i realan uvid u dubine obalnih plavljenja, napravljen je prikaz poprečnih presjeka s građevinama i razinama plavljenja za predviđene scenarije (Slika 3).



Slika 2: Površine obalnog plavljenja grada Cresa za različite MR-ove (lijevo). Značajne valne visine (SE 50-god.PP) za MR 1,75 m n. m. (desno)



Slika 3: Prikaz dubina plavljenja karakterističnih poprečnih presjeka grada Cresa (Građevinski fakultet u Rijeci, 2021).

3.2. Plavljenja obalnog područja grada Raba

Kao i u slučaju grada Cresa u posljednje vrijeme sve češće dolazi do plavljenja centra grada Raba. Primarni uzrok je podizanje razine mora. Na Slici 4 prikazane su površine obalnog plavljenja grada Raba za razine mora od 1,15 m n. m. do 2,65 m n. m. i značajne visine vala u slučaju porasta morske razine za 0,60 m.

Danas već može doći do plavljenja površine od 33.670 m^2 u gradu Rabu, porastom MR-a za 30, 60 i 90 cm može doći do plavljenja površina od 54.370, 62.840 i 67.890 m^2. Porastom MR-a dolazi do značajnijeg povećanja plavljenih površina u odnosu na grad Cres zbog manjih nagiba terena grada Raba.

U slučaju porasta razine mora tijekom ekstremnih događaja za 60 cm mogu se javiti valovi viši od 15 cm na površinama zahvaćenim obalnim plavljenjem (Slika 4), s dubinama vode od 1 m na kritičnim dijelovima obale, što dodatno povećava opasnosti i potencijalni nastanak oštećenja.

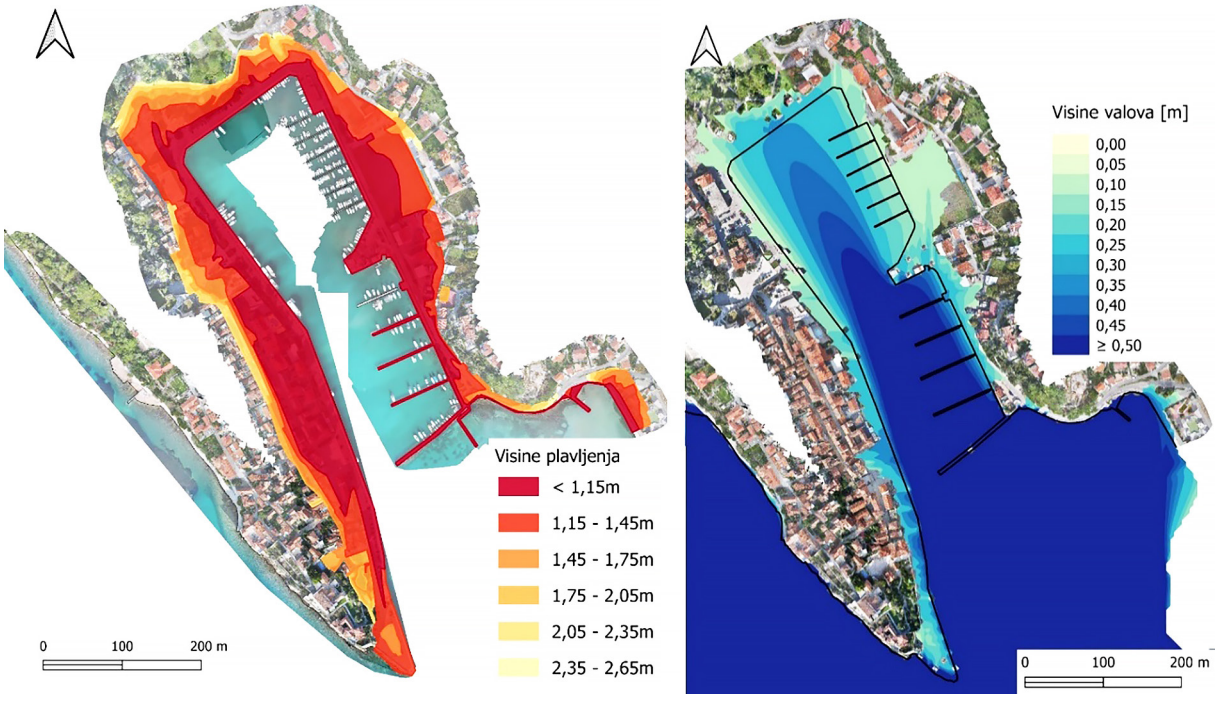
3.3. Plavljenja obalnog područja naselja Punat

Na Slici 5 prikazane su površine obalnog plavljenja naselja Punat za razine mora od 1,15 m n. m. do 2,65 m n. m. i značajne visine vala u slučaju porasta morske razine za 0,60 m.

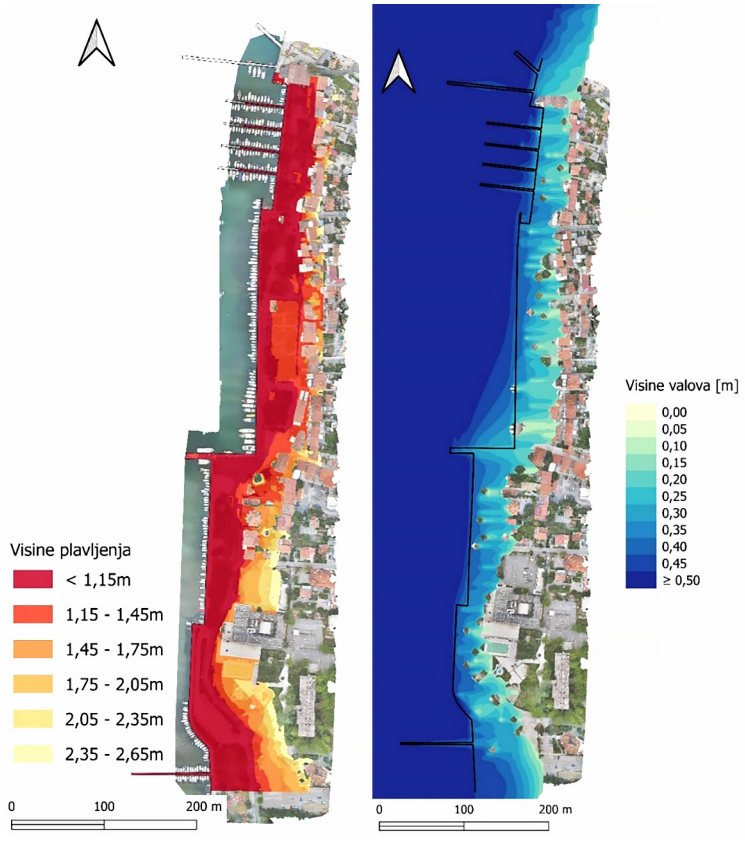
Za postojeće stanje može doći do plavljenja značajnih površina u Puntu (28.320 m^2), no plavljenje većinom ne seže do građevina. Također, dubine plavljenja uglavnom su manje od 30 cm pa ne postoje veći rizici. Daljnjim povećanjem kritičnog MR-a za 30, 60 i 90 cm može doći do plavljenja površina od 35.860, 39.880 i 43.440 m^2. Većina plavljenih površina su površine nasute tijekom posljednjih 50-ak godina, koje nisu izgrađene već su javni prostori poput parkova, tržnice, prometnica i parkinga. U slučaju porasta razine mora tijekom ekstremnih događaja za 60 cm mogu se javiti valovi viši od 50 cm na površinama zahvaćenim obalnim plavljenjem (Slika 5), s dubinama vode od 1 m, što neće izazvati veće opasnosti i materijalne štete iz razloga što se većina plavljenja događa na neizgrađenim površinama.

3.4. Plavljenja obalnog područja naselja Volosko

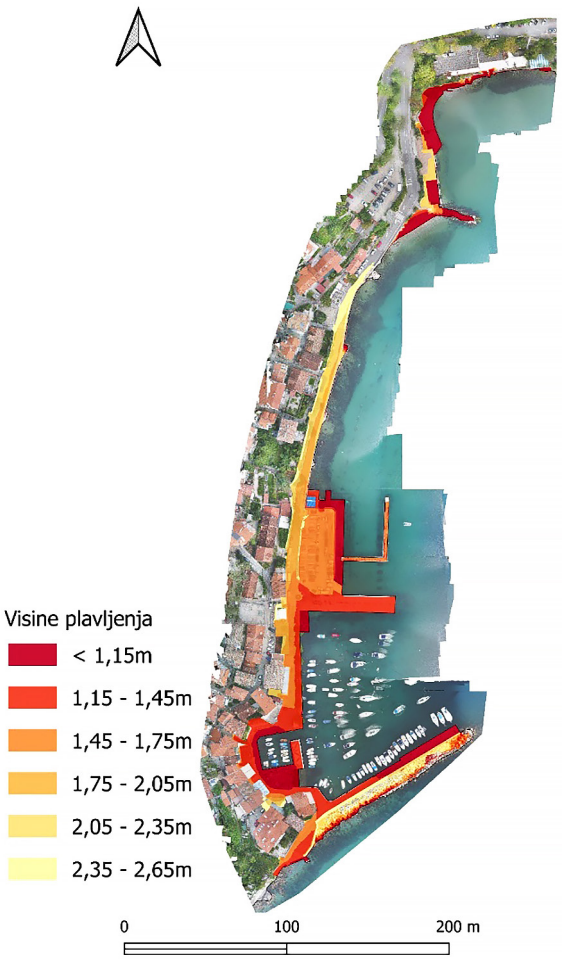
Iako posljednjih godina sve češće dolazi do plavljenja obalnih naselja, u Voloskom ne dolazi do većih obalnih plavljenja, što se neće značajno povećati predviđenim porastom MR-a (Slika 6).



Slika 4: Površine obalnog plavljenja grada Raba za različite MR-ove (lijevo). Značajne valne visine (SE 50-god. PP) za MR 1,75 m n. m. (desno) (Građevinski fakultet u Rijeci, 2021).



Slika 5: Površine obalnog plavljenja naselja Punat za različite MR-ove (lijevo). Značajne valne visine (SE 50-god. PP) za MR 1,75 m n. m. (desno) (Građevinski fakultet u Rijeci, 2021).



Slika 6: Površine obalnog plavljenja naselja Volosko za različite MR-ove (Građevinski fakultet u Rijeci, 2021).

Za postojeće stanje može doći do plavljenja manjih površina (2.030 m^2). Daljnjim povećanjem kritičnog MR-a za 30, 60 i 90 cm može doći do plavljenja površina od 4.270, 6.260, 7.280 m^2. Većina plavljenih površina su na obalnim građevinama poput gatova, obala i lukobrana. U voloskom će biti izražen problem pretjeranog prelijevanja preko tih obalnih građevina, što može izazvati sekundarne negativne posljedice.

4. Zaključak

Adekvatne podloge u obliku trodimenzionalnih oblaka točaka omogućile su provedbu kvalitetnih analiza obalnog plavljenja na četiri lokacije u PGŽ-u: u Cresu, Rabu, Puntu i Voloskom. Rezultati istraživanja dali su prostornu distribuciju obalnog plavljenja s veličinama površina, mjerodavnim dubinama vode i značajnim visinama valova za sadašnje i predviđeno stanje, što je jedan od ulaznih podataka za buduće analize rizika.

Svi dobiveni rezultati prikazani su na digitalnim ortofoto kartama visoke rezolucije čime će se uvelike olakšati i dijeljenje rezultata s korisnicima prostora.

Stare jezgre Raba i Cresa već su danas dosta ugrožene, a u budućnosti će uz povećanja plavljenih površina doći i do povećanja dubina. Moguć je i porast visina valova na poplavljenim područjima što može predstavljati dodatnu opasnost. Koncept obrane starih gradskih jezgri od obalnog plavljenja poprilično je složen. Potrebno ga je temeljiti na analizi cjelokupnog, šireg područja, a ne samo pojedinih (problematičnih) segmenata obale, te bi s planiranjem mjera zaštite trebalo krenuti već sada.

Punat danas nema velikih problema s plavljenjem, iako plave značajne površine. Nasuti dijelovi nakon 60-ih godina 20. stoljeća neizgrađene su javne površine. Građevine ne trpe oštećenja jer postoji dovoljno širok prostor do obalne linije za obranu prvih građevina. Na tim područjima će biti lakše provesti i dodatne mjere za smanjenje budućih plavljenja.

U Voloskom je od obalnog plavljenja ugrožen manji broj građevina u južnom dijelu naselja – u centru i u staroj lučici (Mandrać). Sjeverni dio Ulice Frana Supila ugrožen je djelovanjem valova i visokih razina mora, i tu će biti potrebno provesti proširenje obale kako bi se smanjilo zapljuskivanje.

Dio postojeće obalne infrastrukture (lukobrani, obale) već danas nije funkcionalan tijekom ekstremno visokih razina mora. Takvu infrastrukturu potrebno je prilikom redovnog održavanja i sanacija prilagoditi trenutnom i predviđenom djelovanju mora, te očekivanim morskim razinama.

Literatura

Barić, A., Grbec, B., Bogner, D. (2008): Potential implications of sea-level rise for Croatia, Journal of Coastal Research, 24, 299–305.

Booij, N., Ris, R.C., Holthuijsen, L.H. (1999): A third-generation wave model for coastal regions 1. Model description and validation, Journal of Geophysical Research: Oceans, 104, 7649–7666.

Građevinski fakultet u Rijeci (2021): Analiza ugroženosti od obalnog plavljenja ranjivih naselja Primorsko-goranske županije, Rijeka

Penzar, B., Penzar, I., Orlić, M. (2001): Vrijeme i klima hrvatskog Jadrana, Hrvatski hidrografski institut, Split.

Republika Hrvatska (2020): Strategija prilagodbe klimatskim promjenama u Republici Hrvatskoj za razdoblje do 2040. godine s pogledom na 2070. godinu, Narodne novine, NN 46/2020, 921.

Šegota, T. (1976): Promjena razine Jadranskog mora prema podacima mareografa u Bakru i Splitu, Geografski glasnik, 38, 301–312.

URL 1: Državna geodetska uprava, https://geoportal.dgu.hr/ (23. 6. 2022.)

Analysis of Coastal Flooding Using Three-dimensional Point Clouds

Abstract

This paper presents the results of the research project "Analysis of coastal flood risk of vulnerable settlements in Primorje-Gorski Kotar County (PGŽ)". The research was conducted in cooperation with the Faculty of Civil Engineering in Rijeka and the Institute of Spatial Planning of PGŽ. The results of the research will be used for the planning of the coastal area of the studied pilot areas. The accuracy and resolution of the available maps proved to be the biggest problem for a detailed, individual analysis of coastal flooding and vulnerability. Without accurate data, it is impossible to perform a quality analysis of flooding, wave propagation, and associated risks. In this paper, the hazards for Cres, Rab, Punat and Volosko are studied in detail. For the selected areas, high-resolution (1 point / 2 cm) and precise (± 5 cm) maps were created for the investigations carried out. This is significantly more accurate than the predicted sea level changes (60 ± 15 cm) by the end of the century. Three-dimensional point clouds were created from images taken by an unmanned aerial vehicle. Their application enabled accurate mapping of coastal flooding for the current sea level and for projected rise due to climate change. The point clouds were also used as a basis for numerical wave simulations in flooded areas. Using three-dimensional point clouds, it was thus possible to define potential risks from the interaction of coastal flooding and waves, which is not possible with standard data. The results of the study provided the spatial distribution of coastal flooding with the corresponding water depths and significant wave heights for the current and predicted conditions. The point clouds used are also photorealistic and allow for easier visualization of the range and depth of floods, which is helpful in presenting the project results to the local community.

Keywords: *climate change, coastal flooding, sea level rise, three-dimensional point cloud, unmanned aerial vehicle*

Primjena trodimenzionalnih oblaka točaka za monitoring morfoloških promjena plaže

Igor Ružić[1], Andrea Tadić[2], Marinko Salopek[3]

[1] Sveučilište u Rijeci, Građevinski fakultet, Radmile Matejčić 3, Rijeka, iruzic@uniri.hr

[2] Sveučilište u Rijeci, Građevinski fakultet, Radmile Matejčić 3, Rijeka, andrea.tadic@uniri.hr

[3] Geodetski zavod Rijeka, Dr. Frana Kresnika 33, Rijeka, marinkos@gzr.hr

Sažetak

U ovom je radu opisana primjena trodimenzionalnih oblaka točaka, generiranih iz fotografija snimljenih dvjema bespilotnim letjelicama: Matrice 600 Pro s kamerom Sony ILCE-7M2 i Phantom 4 Pro. Za potrebe projekta *Održiva gradnja plaža – gradnja novih i povećanje kapaciteta postojećih plaža (Beachex)* provedeno je ukupno 19 letova tijekom 2020. i 2021. godine na plaži Ploče (Kantrida, Rijeka). Gustoća oblaka točaka dobivenih fotogrametrijskim postupkom u prosjeku je 5.670 točaka po m^2, a točnosti na kontrolnim točkama za sva su snimanja oko 5 cm. Rezultati točnosti i preciznosti pokazuju da nema značajne razlike između oblaka točaka snimljenih dvjema letjelicama. Slabije performanse Phantoma 4 kompenzirane su nižom visinom i dužim trajanjem leta i većim brojem fotografija. Konzervativna vrijednost točnosti od ± 5 cm usvojena je za procjenu određenih parametara plaže. Oblaci točaka pokazali su se kao vrijedan ulazni podatak pri analizama promjena plaža. Prvenstveno je moguće pratiti visinske promjene žala između uzastopnih mjerenja, koje su na plaži Ploče značajno veće od postignute preciznosti oblaka točaka. Transport materijala unutar promatranog područja može se točno prostorno definirati uz pomoć trodimenzionalnih podloga, a vrlo precizno može se pratiti i pomak obalne linije. Analizirane su i promjene površine i volumena tijela plaže, ali zbog relativno malih varijacija ovih parametara između snimanja, moguće je pratiti samo trend njihovih promjena. Za određivanje točne količine materijala ipak će biti potrebno raspolagati s preciznijim podlogama.

Ključne riječi: *bespilotna letjelica, promjene plaže, SfM fotogrametrija, trodimenzionalni oblak točaka, umjetna plaža*

1. Uvod

Veliki dio plaža duž istočne obale Jadrana čine pretežno šljunčane plaže, tzv. džepne, često omeđene rtovima s triju strana. Istraživanje njihove dinamike počelo je tek nedavno (Faivre i dr., 2011; James i dr., 2013; Pikelj i dr., 2017; Ružić i dr., 2014), ali je i dalje malo studija posvećenih kratkotrajnim promjenama nastalim nakon olujnih situacija. Poate i dr. (2013) naglašavaju da manjak mjerenja morfoloških promjena šljunčanih plaža ograničava istraživanja.

Točna topografska mjerenja visoke prostorne rezolucije sve su bitnija u proučavanju morfoloških promjena i procesa na plažama. Geomorfološka istraživanja posljednjih desetljeća stoga se okreću fotogrametrijskim postupcima, pogotovo SfM (engl. *structure-from-motion*) fotogrametriji. Ovo je relativno jeftina metoda koja se temelji na obradi trodimenzionalnih oblaka točaka generiranih iz niza fotografija (James i Robson, 2012; Westoby i dr., 2012). Osim cjenovne pristupačnosti, ova mjerenja karakterizira i brzina te jednostavnost primjene. Također, na nepristupačnim lokacijama, fotogrametrija uz pomoć bespilotnih letjelica ima značajne prednosti nad laserskim skeniranjem.

SfM fotogrametrija se ipak vrlo rijetko koristila za monitoring geomorfologije plaža. Naime, monitoring je složeniji zbog osjetljivosti na preciznost snimanja. Uspješnost fotogrametrije ovisi i o plimi, valovima, uvjetima osvjetljenja, poziciji kamere, teksturi i hrapavosti snimane površine (Swirad i dr., 2019), što zahtijeva dodatan oprez. Iako se fotogrametrija primjenjivala na plažama u dosta istraživanja (Casella i dr., 2016; Harwin i Lucieer, 2012; James i dr., 2013; Turner i dr., 2016), samo su u nekoliko radova (npr. Brunier i dr., 2016; Tadić i dr., 2022) opisane promjene plaža na temelju ponavljanih mjerenja visoke rezolucije.

U ovom radu opisana je primjena SfM fotogrametrije za praćenje morfoloških promjena na nadmorskom dijelu plaže Ploče u Rijeci. To je umjetna šljunčana plaža na kojoj valovi izazivaju značajnu eroziju, te na kojoj se odvijaju istraživanja u sklopu znanstvenog projekta „Održiva gradnja plaža – gradnja novih i povećanje kapaciteta postojećih plaža (Beachex)“ (URL 1).



Slika 1: Položaj plaže Ploče (izvor: GZR)

1.1. Područje istraživanja

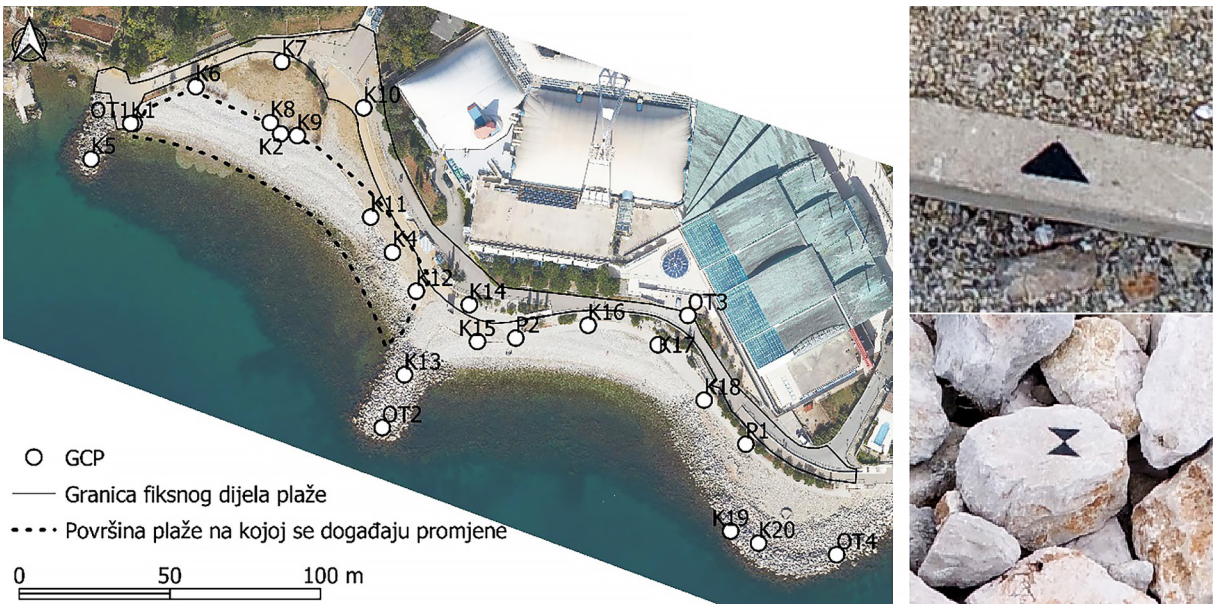
Plaža Ploče (Slika 1) smještena je na sjeverozapadnom dijelu Rijeke – Kantridi i najveća je uređena plaža na riječkom području. Duga je otprilike 350 m, a čine je tri pera između kojih je nasut šljunčani materijal (D_{50} = 32 mm). Srednje pero dijeli je na dvije ćelije – zapadnu i istočnu. Osnovni izazov s kojim se susreće ova plaža jest erozija uzrokovana valovima i to onima koje generira jugo. Najveći problemi javljaju se u zapadnoj ćeliji gdje se materijal ispire u blizini srednjega pera, te se nakuplja na suprotnom kraju ćelije. Najveće migracije sedimenta odvijaju u jesenskim i zimskim mjesecima, pa se svake godine prije sezone kupanja plaža dohranjuje i uređuje.

2. Metodologija

Plaža je snimljena 19 puta u periodu od 17. siječnja 2020. do 26. veljače 2021. (Tablica 1), izvan ljetne sezone i u pravilu nakon olujnih događaja. Prije prvog mjerenja duž šetnice uz plažu i na školjeri označeno je 12 kontrolnih točaka (engl. *ground control points,* GCP; Slika 2), a naknadno je dodano još 16. Njihove koordinate određene su Leica FlexLine TS06plus totalnom stanicom točnosti 1,5 mm (URL 2), a koristile su se u daljnjim analizama preciznosti i točnosti podataka snimljenih bespilotnim letjelicama. Kada su točke bile označene i snimljene, snimanja bespilotnim letjelicama bila su brza – obično bi zahtijevala oko sat vremena.

2.1. Prikupljanje i obrada podataka

Aerofotogrametrijske fotografije prikupljale su dvije institucije pomoću dvaju modela bespilotnih letjelica: Geodetski zavod Rijeka (GZR) s dronom Matrice 600Pro (URL 3) opremljenog kamerom Sony ILCE-7M2 rezolucije 24 MP, i Građevinski fakultet u Rijeci (GradRi) s Phantomom 4 Pro, čija vlastita kamera ima 20 MP (URL 4). Broj snimljenih fotografija varirao je između 208 i 667. Visina leta prilikom GradRi mjerenja iznosila je 19,2 – 29 m, dok je Matrice letio na visinama oko 100 m. Trodimenzionalni oblaci točaka generirani su iz snimljenih fotografija u softveru Agisoft Metashape Professional. Osnovni podaci



Slika 2: Područje istraživanja (lijevo) i oznake GCP-eva (desno) (izvor: Tadić i dr., 2022)

Tablica 1: Podaci o snimanju iz Agisofta

Datum	Oznaka	Snimao	Broj fotografija	Visina leta [m]	Rezolucija [mm/pix]	*Tie Points*	Greška proj [pix]
17.1.2020.	UAV_01	GZR	355	102,0	19,0	115.521	0,897
7.2.2020.	UAV_02	GZR	467	103,0	18,8	233.105	0,767
12.2.2020.	UAV_03	GZR	321	101,5	19,7	268.994	0,693
2.3.2020.	UAV_04	GradRi	602	19,2	4,7	309.557	0,404
3.3.2020.	UAV_05	GradRi	366	28,0	7,1	206.361	0,526
10.3.2020.	UAV_06	GradRi	388	29,0	7,4	207.342	0,508
20.3.2020.	UAV_07	GradRi	613	31,3	7,9	294.521	0,629
29.3.2020.	UAV_08	GradRi	362	27,4	7,0	171.709	0,631
28.4.2020.	UAV_09	GradRi	382	34,7	8,9	239.525	0,708
5.5.2020.	UAV_10	GradRi	383	26,2	6,6	275.779	0,744
1.10.2020	UAV_11	GZR	535	28,1	7,5	300.541	0,772
6.10.2020.	UAV_12	GradRi	492	28,6	7,2	264.272	0,826
13.10.2020.	UAV_13	GradRi	538	28,5	7,1	328.053	0,790
2.11.2020.	UAV_14	GZR	208	103,0	19,5	305.479	0,733
24.11.2020.	UAV_15	GradRi	278	20,5	5,1	154.838	0,515
10.12.2020.	UAV_16	GradRi	600	24,3	6,1	280.890	0,315
14.12.2020.	UAV_17	GZR	269	100,0	19,1	335.580	0,724
14.1.2021.	UAV_18	GradRi	560	26,7	6,6	308.839	0,318
26.2.2021.	UAV_19	GZR	290	101,0	19,6	381.158	0,791

o snimanjima dani su u Tablici 1. Udaljenost točaka je izvorno bila 20 mm, ali je naknadno povećana na 50 mm kako bi se ubrzale analize. Oblaci točaka su u Agisoftu i georeferencirani u HTRS96 koordinatnom sustavu pomoću dijela kontrolnih točaka.

2.2. Točnost snimanja

Analize točnosti izrađene su posebno za svako od 19 provedenih snimanja. Nakon generiranja oblaka točaka, u Agisoftu se automatski uspoređuju koordinate kontrolnih točaka određenih iz georeferenciranih oblaka s koordinatama odgovarajućih točaka određenih GPS-om. Rezultat je podatak o srednjoj kvadratnoj pogrešci (engl. *root mean square error,* RMSE) na kontrolnim točkama (Tablica 2).

Položajne RMSE vrijednosti su u prosjeku 3,4 mm za X koordinatu i 3,7 mm za Y. Najviše vrijednosti zabilježene su za vrijeme 5. snimanja (UAV_05) kada uvjeti za snimanje nisu bili idealni. Vertikalna preciznost (Z) nešto je lošija, s prosjekom svih snimanja od 5,4 mm. Može se primijetiti da su za mjerenja odrađena uz pomoć Phantoma 4 Pro (GradRi) RMSE vrijednosti su nešto niže zbog manje visine leta i većeg broja snimljenih fotografija. Međutim, kvaliteta ovih oblaka točaka za dio plaže ispod morske razine značajno je lošija u odnosu na snimanja Geodetskog zavoda Rijeka. Višim visinama leta smanjen je utjecaj valova.

RMSE vrijednosti mogu se koristiti za procjenu uspješnosti snimanja, ali se za određivanje točnosti preporučuje provesti i dodatne postupke verifikacije (James i dr. 2020). Točnost snimanja je zbog toga provjerena i uz pomoć softvera *CloudCompare*-a (URL 5). Provela se međusobna usporedba svih oblaka točaka na fiksnim, betonskim dijelovima šetnice i stepenica uz plažu (poligon s punom granicom na Slici 2). Detaljan postupak s prikazom rezultata opisan je u radu Tadić i dr. (2022). Na Slici 3 je primjer dobivenih rezultata. Vertikalne udaljenosti su na gotovo cijeloj šetnici između -5 i 5 cm, a više vrijednosti su povezane s vegetacijom i pješacima koji su u trenutku snimanja bili na plaži. Iz toga razloga usvojena je vertikalna točnost od ± 5 cm za sva snimanja.

3. Primjena rezultata

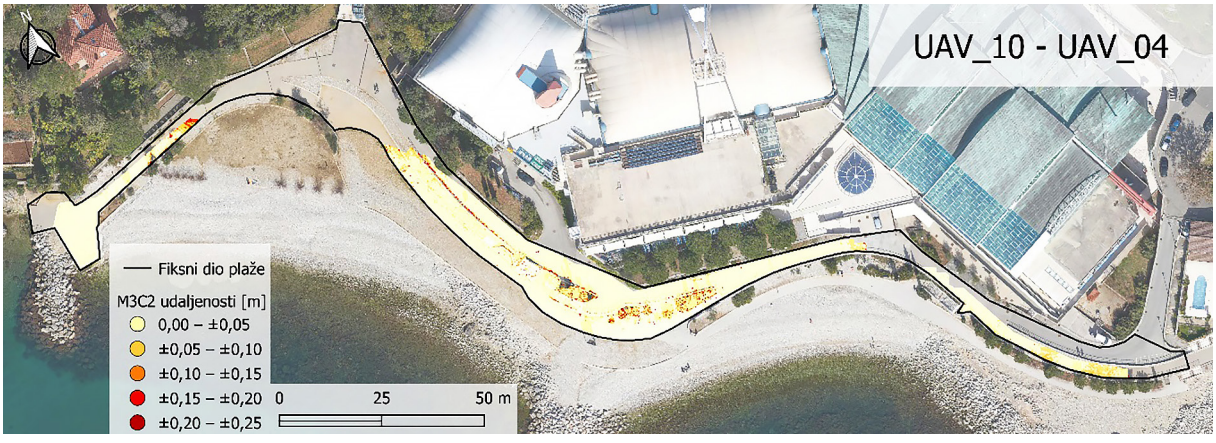
Trodimenzionalni oblaci točaka primijenili su se za praćenje morfoloških promjena nadmorskog dijela plaže Ploče. Procjenjivale su se promjene visina žala između dva mjerenja, usporedbom oblaka točaka pomoću dodatka u *CloudCompare*-u (URL 5). Na ovaj način su se izrazito točno odredile zone erozije na plaži (dio uz srednje pero), te područja na kojima se materijal akumulirao (više kote plaže i zapadni kraj). Promjene manje od ± 5 cm su zanemarene budući da su manje od definirane točnosti.

Tablica 2: RMSE na kontrolnim točkama iz Agisofta

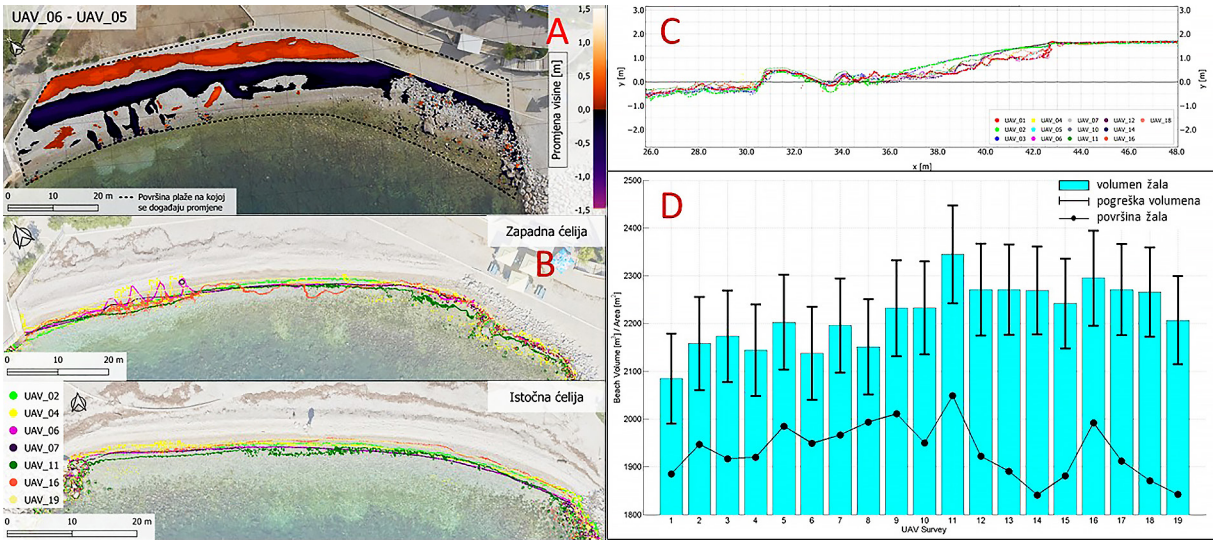
Oznaka	Br. GCP-a	RMSE [mm]				
		X	Y	Z	XY	XYZ
UAV_01	6	2,3	0,7	4,8	2,4	5,3
UAV_02	7	4,3	1,3	10,2	4,5	11,2
UAV_03	6	1,0	4,7	6,2	4,8	7,8
UAV_04	8	3,1	5,2	7,7	6,0	9,8
UAV_05	10	8,3	6,2	5,5	10,3	11,7
UAV_06	6	3,3	3,4	2,1	4,8	5,2
UAV_07	5	3,1	3,2	2,1	4,4	4,9
UAV_08	4	0,7	0,6	0,6	0,9	1,1
UAV_09	4	1,1	0,8	0,9	1,3	1,6
UAV_10	9	3,2	3,4	12,5	4,6	13,4
UAV_11	21	4,0	5,1	9,7	6,5	11,6
UAV_12	23	4,9	4,4	3,5	6,6	7,5
UAV_13	23	3,5	4,7	5,1	5,9	7,8
UAV_14	20	7,4	7,2	5,2	10,3	11,6
UAV_15	8	3,7	3,1	5,0	4,8	6,9
UAV_16	7	2,6	3,4	3,9	4,3	5,8
UAV_17	21	2,3	0,7	4,8	2,4	5,3
UAV_18	13	7,4	5,5	2,3	9,3	9,5
UAV_19	20	4,3	1,3	10,2	4,5	11,2

Iz 3D oblaka točaka izdvojeni su poprečni presjeci na kojima se također uočavaju promjene visina i prati transport sedimenta, formiranje i ravnanje bermi pod djelovanjima mora. Usporedbom presjeka na dijelovima šetnice i školjeri dodatno se potvrdila i točnost snimanja. Primjer jednog takvog presjeka dan je na Slici 4C. Pratio se i pomak obalne linije na koti 0 m n. m. (Slika 4B). U prosjeku su ti pomaci do ± 40 cm, što je manje od mogućih grešaka. Ipak, promjene neposredno nakon oluja i dohranjivanja mogu se odrediti s većom sigurnosti.

S druge strane, proračun volumena žala nije tako jednostavan i potrebno ga je odrediti iz digitalnih modela terena (engl. *digital elevation model,* DEM). DEM-ovi rezolucije 5 cm generirani su u Matlabu, unutar definirane granice žala (poligon s isprekidanom granicom na Slici 2), a volumeni plaže iznad morske razine definirani su integracijom visina DEM-a do referentne kote 0 m n. m. Analiza volumena, kao i ostalih parametara, vezana je uz grešku koja se računa kao umnožak površine plaže i greške visina (± 5 cm). Rezultati su prikazani na Slici 4D. Zabilježene promjene



Slika 3: Usporedba iz *CloudCompare*-a za određivanje točnosti (izvor: Tadić i dr., 2022)



Slika 4: Promjene praćene na plaži Ploče: promjene visina (A), položaj obalne linije (B), poprečni presjeci (C), volumen i površina žala (D) (izvor: Tadić i dr., 2022)

manje su od postignute točnosti za volumene, koja je oko ± 50 m³, ali se određeni trendovi mogu pratiti (npr. povećanje površine i volumena žala zbog dohrane provedene nakon 2. i 10. snimanja).

4. Zaključak

U radu je prikazana tehnologija za praćenje promjena džepnih šljunčanih plaža, koje su izrazito dinamične, prostorno i vremenski. Mjerenja se obavljaju brzo jednom kada se postavi mreža fiksnih kontrolnih točaka. Uspjele su se detaljno zabilježiti promjene visina žala koje su puno veće od usvojene točnosti modela od ± 5 cm. Točnosti na kontrolnim točkama izračunate u Agisoftu par su centimetara manje i ovim istraživanjima potvrđeno je da se ne bi trebalo oslanjati isključivo na te podatke te da su potrebne dodatne, neovisne analize preciznosti mjerenja. Kao dodatna metoda ovdje se koristila usporedba oblaka točaka na nepomičnim dijelovima plaže. Točnost treba uzeti u obzir prilikom procjena svih parametara plaže, a ona ovisi o više čimbenika (rezolucija kamere, visina leta i kut snimanja, meteorološki uvjeti). Najviše greške imala su ona snimanja koja su obavljena tijekom nepovoljnih uvjeta na terenu (svjetlo ili poplave na plaži i šetnici, valovi). Rezultati također ukazuju da nema veće razlike između profesionalne bespilotne letjelice (Matrice 600 Pro) i komercijalne (Phantom 4 Pro). Slabije performanse Phantoma 4 kompenzirane su nižom visinom leta i većim brojem fotografija.

Korištena metodologija omogućuje jako precizan opis promjena na dijelu plaže iznad razine mora. Uočeno je da promjene nisu uniformne i da se odvijaju na različitim dijelovima žala – od manjih promjena uz samu razinu mora do velikih promjena koje zahvaćaju cijelo žalo tijekom velikih oluja. Za dobivanje cijele slike procesa koji se odvijaju na plažama potrebno je istražiti i podmorski dio.

SfM fotogrametrijska metoda uz pomoć bespilotnih letjelica dopušta prikupljanje velike količine prostornih podataka u relativno kratkom vremenu, te se sa zadovoljavajućom točnošću može koristiti za praćenje morfoloških promjena šljunčane plaže.

Literatura

Brunier, G., Fleury, J., Anthony, E.J., Gardel, A., Dussouillez, P. (2016): Close-range airborne Structure-from-Motion Photogrammetry for high-resolution beach morphometric surveys: Examples from an embayed rotating beach, Geomorphology, 261, 76–88.

Casella, E., Rovere, A., Pedroncini, A., Stark, C.P., Casella, M., Ferrari, M., Firpo, M. (2016): Drones as tools for monitoring beach topography changes in the Ligurian Sea (NW Mediterranean), Geo-Marine Letters, 36, 151–163.

Faivre, S., Pahernik, M., Maradin, M. (2011): The gully of Potovošca on the Island of Krk - The effects of a short-term rainfall event. Geologia Croatica, 64, 67–80.

Harwin, S., Lucieer, A. (2012): Assessing the accuracy of georeferenced point clouds produced via multi-view stereopsis from Unmanned Aerial Vehicle (UAV) imagery, Remote Sensing, 4, 1573–1599.

James, M.R., Antoniazza, G., Robson, S., Lane, S.N. (2020): Mitigating systematic error in topographic models for geomorphic change detection: accuracy, precision and considerations beyond off-nadir imagery, Earth Surface Processes and Landforms, 45, 2251–2271.

James, M.R., Ilić, S., Ružić, I. (2013): Measuring 3D coastal change with a digital camera, in: Coastal Dynamics, Coastal Dynamics 2013, 893–904.

James, M.R., Robson, S. (2012): Straightforward reconstruction of 3D surfaces and topography with a camera: Accuracy and geoscience application, Journal of Geophysical Research: Earth Surface, 117, 3

Pikelj, K., Ružić, I., James, M.R., Ilić, S. (2017): Structure-from-Motion (SfM) monitoring of nourished gravel beaches in Croatia, COASTS, MARINE STRUCTURES and BREAKWATERS 2017-The Leading International Conference Highlighting Global Marine Engineering Advance, ICE Publishing, London.

Poate, T., Masselink, G., Davidson, M., McCall, R., Russell, P., Turner, I. (2013): High frequency in-situ field measurements of morphological response on a fine gravel beach during energetic wave conditions, Marine Geology, 342, 1–13.

Ružić, I., Marović, I., Benac, Č., Ilić, S. (2014): Coastal cliff geometry derived from structure-from-motion photogrammetry at Stara Baška, Krk Island, Croatia. Geo-Marine Letters, 34, 555–565.

Swirad, Z.M., Rosser, N.J., Brain, M.J. (2019): Identifying mechanisms of shore platform erosion using Structure-from-Motion (SfM) photogrammetry, Earth Surface Processes and Landforms, 44, 1542–1558.

Tadić, A., Ružić, I., Krvavica, N., Ilić, S. (2022): Post-Nourishment Changes of an Artificial Gravel Pocket Beach Using UAV Imagery, Journal of Marine Science and Engineering, 10, 358

Turner, I.L., Harley, M.D., Drummond, C.D. (2016): UAVs for coastal surveying, Coastal Engineering, 114, 19–24.

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

URL 1: Beachex, http://grad.hr/beachex/ (26. 6. 2022.)

URL 2: SCCS, https://www.sccssurvey.co.uk/leica-flexline-ts06plus-total-station.html, (24. 6. 2022.).

URL 3: DJI, https://www.dji.com/hr/matrice600-pro, (24. 6. 2022.)

URL 4: DJI, https://www.dji.com/hr/phantom-4-pro, (24. 6. 2022.)

URL 5: CloudCompare, https://www.cloudcompare.org/doc/wiki/index.php/M3C2_(plugin), (24. 6. 2022.)

Application of Three-dimensional Point Clouds to Monitor Morphological Changes of the Beach

Abstract

This paper describes the application of three-dimensional point clouds generated from images taken by two unmanned aerial vehicles (UAV): Matrice 600 Pro Matrix with a Sony ILCE-7M2 camera and the Phantom 4 Pro. For the needs of the project *Sustainable construction of artificial gravel beaches – construction of new beaches and an increase of existing capacity* (*Beachex*), a total of 19 surveys were conducted on Ploče beach (Kantrida, Rijeka) in 2020 and 2021. The cloud density of the points obtained by the photogrammetric method is on average 5,670 points per m^2, and the precision at the control points is about 5 cm for all surveys. The accuracy and precision results show that there is no significant difference between the point clouds acquired by the two UAVs. The lower performance of the Phantom 4 is compensated by a lower flight altitude and more photos. A conservative accuracy value of ± 5 cm was assumed for estimating certain beach parameters. Point clouds have proven to be a valuable input for beach change analysis. Primarily, it is possible to monitor elevation changes between successive measurements, which at Ploče beach are significantly higher than the achieved accuracy of point clouds. Material transport within the observed beach area is more accurately described with three-dimensional point clouds, and shoreline displacement can be tracked very precisely. Changes in the surface area and volume of the beach body have also been analyzed, but because of the relatively small variations in these parameters between exposures, it is only possible to follow the trend of their changes. Therefore, more accurate surveying is needed to determine the exact amount of material displaced.

Keywords: *artificial beach, beach changes, structure-from-motion (SfM) photogrammetry, three-dimensional point cloud, unmanned aerial vehicle (UAV)*

Analiza metoda hidrografske izmjere u izgradnji vjetroelektrana u moru

Dino Dragun[1], Matko Raguž[2], Ivan Žokvić[3]

[1] Hidrocibalae d.o.o., Dragutina Žanića Karle 16, Vinkovci, Hrvatska, dino.dragun@hidrocibalae.hr

[2] Hidrocibalae d.o.o., Kožarska ulica 2, Zagreb, Hrvatska, matko.raguz@hidrocibalae.hr

[3] Hidrocibalae d.o.o., Dragutina Žanića Karle 16, Vinkovci, Hrvatska, ivan.zokvic@hidrocibalae.hr

Sažetak

Zakonodavstvo EU-a kojim se promiču obnovljivi izvori energije u moru znatno se razvilo proteklih godina, sukladno i povećanim investicijama u polju obnovljivih izvora energije u moru. Proces izgradnje infrastrukture u moru zahtijeva i kompleksna istraživanja u svim svojim fazama. Paralelno s razvojem metoda izgradnje u moru razvijaju se i metode hidrografskih istraživanja, gdje zahtjevi investitora postaju sve kompleksniji u vidu tražene pouzdanosti i reprezentativnosti podataka. Za uspješnu provedbu ovog dugoročnog procesa, neophodan je multidisciplinaran pristup metoda hidrografske izmjere i obrade njezinih izlaznih podataka.

Ključne riječi: *hidrografija, obnovljivi izvori energije u moru, seizmička istraživanja, vjetroelektrane u moru*

1. Uvod

Obnovljivi izvori energije mogu osigurati značajan dio energetskih potreba Europe u 21. stoljeću. Postoji široka zabrinutost zbog ekoloških učinaka konvencionalne potrošnje energije, a posebno globalnog zatopljenja. Budući da su obnovljivi izvori energije dobro raspoređeni po cijeloj zemlji, za razliku od mnogih drugih, oni nude mogućnost globalnog odgovora na globalne promjene. Za Europu su najvažniji obnovljivi izvori biomasa, vjetar, fotonaponska energija, male hidroelektrane, energija plime i oseke i solarne zgrade (Schneider i dr., 2005). Energija vjetra ima sve značajniji potencijal, a aktualan je i javni konsenzus za snažniji razvoj obnovljivih izvora energije u Europi. Od 1990-ih, Europska unija se posvetila preuzimanju globalnog vodstva u čistim energijama kao što su solarna fotonaponska energija i energija vjetra. Zajednički kapacitet vjetra i sunca porastao je s 12,5 GW (ili 2% ukupnog instaliranog kapaciteta električne energije) u 2000. na 261,2 GW u 2018. (ili 28,1% ukupnog instaliranog kapaciteta električne energije) (Amenta i Stagnaro, 2022).

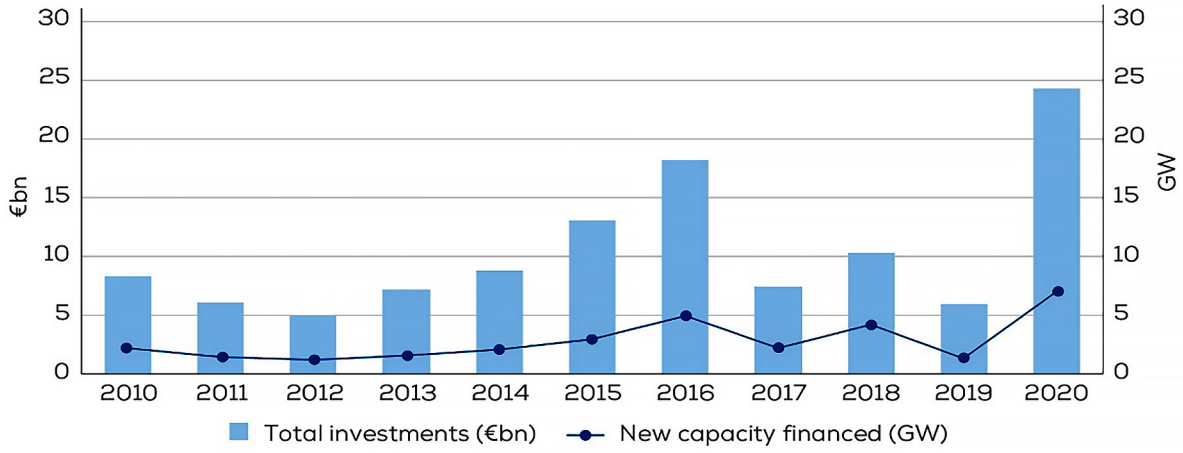
Rješavanje problema klimatskih promjena zahtijeva globalno koordiniran, dugoročan odgovor u svim gospodarskim sektorima. Vođena dugoročnom vizijom europskog gospodarstva s niskim udjelom ugljika i resursima učinkovitog do 2050., Europska unija je usvojila ambiciozne i obvezujuće klimatske i energetske ciljeve. Države članice postavile su strateški cilj izgradnje energetske unije, čiji je cilj osigurati pristupačnu, sigurnu i održivu energiju. Energetski sektor, kao srce ove transformacije, svjedočio je učinkovitom prihvaćanju čistih energetskih rješenja u posljednjem desetljeću, posebno obnovljivih. Obnovljiva energija ima važnu ulogu u energetskoj tranziciji, jer da nudi priliku za doprinos nekoliko ciljeva održivog razvoja: (1) društveni i ekonomski razvoj; (2) pristup energiji; (3) energetsku sigurnost i (4) ublažavanje klimatskih promjena i smanjenje utjecaja na okoliš i zdravlje.

2. Vjetroelektrane u moru

Korištenje energije vjetra na moru već je prisutno u mnogim zemljama diljem svijeta, posebno u zemljama s izlazom na plitko Sjeverno more (do 100 metara), velikom brzinom i stalnom učestalošću vjetra kroz dugo razdoblje, kao što su Danska, Ujedinjeno Kraljevstvo, Švedska, Njemačka, Nizozemska i Belgija.

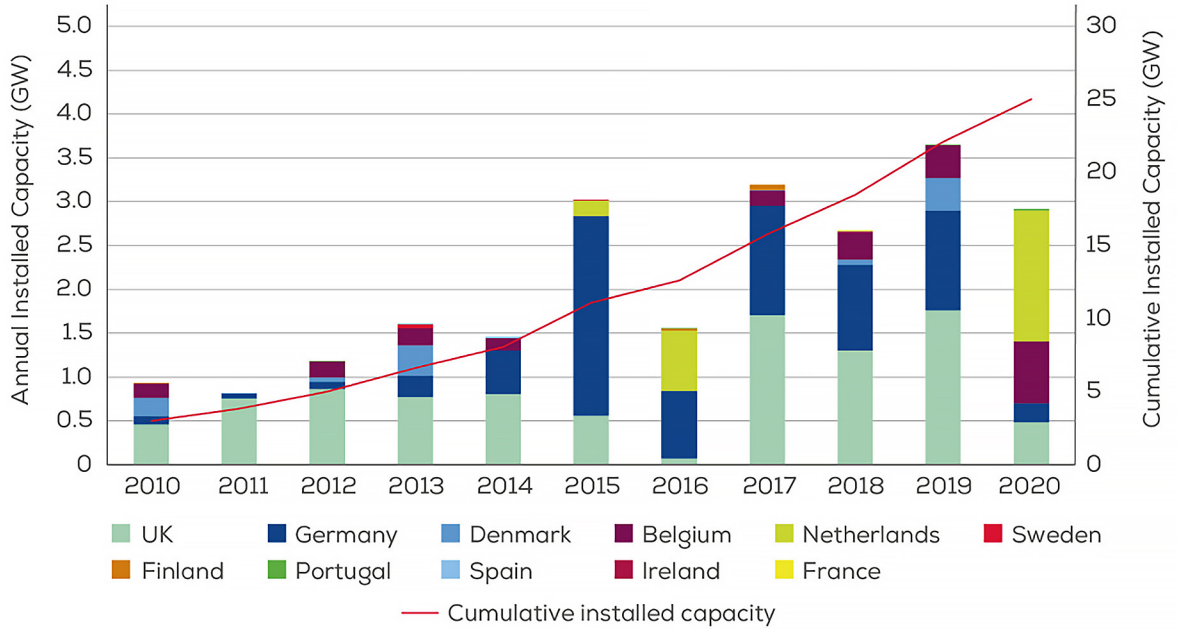
Trenutno Europa ima ukupni instalirani kapacitet vjetroelektrana na moru od 25 GW (Slika 2). To odgovara broju od 5402 vjetroturbine spojene na mrežu u 12 zemalja. Osam novih projekata vjetroelektrana na moru doseglo je Final Decision Investment (FID) u četiri različite zemlje tijekom 2020., a izgradnja bi trebala započeti u narednim godinama. Ulaganja u nova sredstva iznosila su 24,2 milijarde eura kako bi se financiralo 7,1 GW dodatnih kapaciteta (Slika 1). Najveća vjetroelektrana u moru po priključenom kapacitetu u Europi 2020. je Borssele koja se nalazi na obali Kraljevine Nizozemske i trenutno je najveći projekt vjetroelektrana u zemlji. Razvoj je podijeljen u pet faza. Povećanje kapaciteta za vjetroelektranu iznosilo je gotovo 1500 MW u 2020. godini, što odgovara energiji potrebnoj za oko 1 900 000 kućanstava.

Izgradnja vjetroelektrana u moru očekuje se i u Hrvatskoj, na Jadranu, no inicijalne studije su tek u početnoj fazi. Najveći izazov za realizaciju ovog projekta predstavljaju velike dubine u Jadranskom moru (>100 m) na lokacijama povoljnim za njihovu izgradnju. Uloga hidrografskih i seizmičkih istraživanja prisutna je u svim fazama izgradnje obnovljivih izvora



	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Total investments (€bn)	8.4	6.1	5	7.2	8.8	13.1	18.2	7.5	10.3	6	24.2
New capacity financed (GW)	2.2	1.5	1.3	1.6	2.1	3	5	2.3	4.2	1.4	7.1

Slika 1: Nova ulaganja u vjetroelektrane na moru i financirani kapaciteti: 2010. – 2020. (u milijardama eura) (URL 2).



Slika 2: Godišnja izgradnja vjetroelektrana po državi (lijeva os) i kumulativnom kapacitetu (desna os) (URL 2).

energije u moru, od idejnih rješenja do monitoringa izgrađene infrastrukture.

3. Faze izgradnje vjetroelektrana u moru

Hidrografsku izmjeru na projektima izgradnje obnovljivih izvora energije u moru može se podijeliti u sljedeće faze:

1. inicijalna izmjera (morfologija, studija utjecaja na okoliš, analiza morskih staništa) – određivanje lokacije i koridora komunikacijskih vodova,
2. detaljna geofizikalna/geotehnička/seizmička izmjera,
3. faza izgradnje – topografska i hidrografska izmjera,
4. izmjera izvedenog stanja,
5. monitoring izgrađene infrastrukture.

Tablica 1: Upotreba metoda hidrografske izmjere u fazama izgradnje vjetroelektrana u moru.

Faze	MBES[1]	SSS[2]	MAG[3]	SBP[4]	HRS/UHRS[5]
1.					
2.					
3.					
4.					
5.					

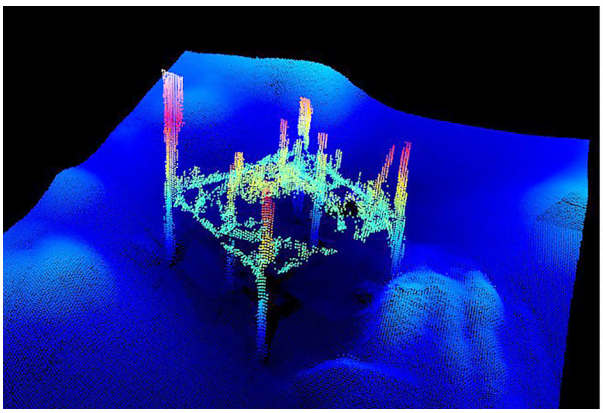
[1] MBES (engl. Multibeam echosounder) – višesnopni dubinomjer

[2] SSS (engl. Sidescan sonar) – panoramski dubinomjer

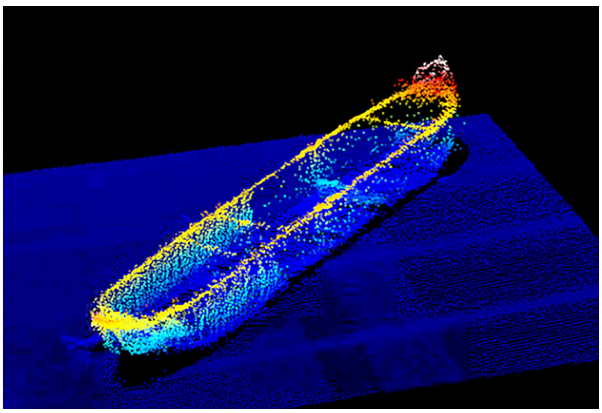
[3] MAG (engl. Magnetometer) – magnetometar

[4] SBP (engl. Sub-bottom profiler) – geološko-strukturni dubinomjer

[5] HRS/UHRS (engl. High/Ultra high resolution seismic) – seizmika visoke/ultra visoke razlučivosti



Slika 3: Centralna platforma sustava vjetroelektrana u moru – višesnopni dubinomjer.



Slika 4: Olupina broda na dnu mora – višesnopni dubinomjer.

4. Metode hidrografske izmjere

Hidrografska istraživanja prisutna su u svim fazama izgradnje sustava vjetroelektrana u moru. Kako je i prikazano u Tablici 1, ovisno o fazi izgradnje, kombiniraju se i različite metode istraživanja. U nastavku su navedene metode koje se najčešće koriste.

4.1. Višesnopni dubinomjer (MBES)

Višesnopni dubinomjer je osnovna tehnologija za kartiranje dubina i morfologije morskog dna, a razlučivost podataka dobivenih ovom metodom je centimetarska. Ova tehnologija se također koristi kako bi se izbjegla područja koja bi potencijalno mogla ugroziti plovila i njihovu opremu te za precizno mapiranje morskog dna (Slika 3, Slika 4). Kada govorimo o fazama izmjere, MBES nalazi primjenu u svakoj od njih: određivanje lokacije i rute komunikacijskih vodova, detaljna geofizikalna i geotehnička izmjera, izmjera izvedenog stanja, monitoring izgrađene infrastrukture itd.

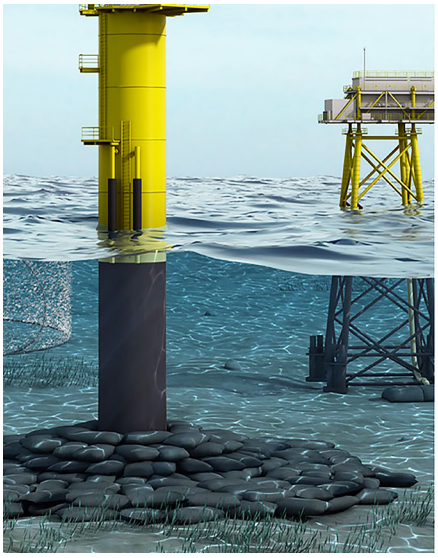
4.2. Panoramski dubinomjer (SSS)

Panoramski dubinomjer je sonar koji emitira stožaste ili lepezaste impulse prema morskom dnu okomito na putanju senzora kroz vodu, koji se može vući s površinskog plovila, podmornice ili montirati na trup broda. Intenzitet akustične refleksije od morskog dna ove lepezaste zrake bilježi se u nizu poprečnih presjeka, a kroz rezultate primljenih signala, dobivamo informacije o sedimentu, objektima i staništima morskog dna.

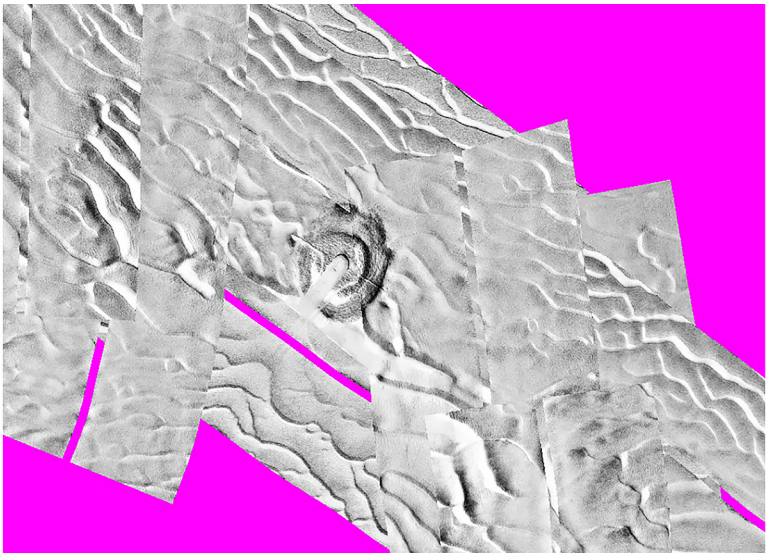
Visoko je funkcionalan alat za otkrivanje objekata i drugih prepreka na morskom dnu koje mogu biti opasne za plovidbu, instalacije u naftnoj industriji te u ovom slučaju, industriju gradnje obnovljivih izvora energije u moru. Ova je metoda neizostavna u svim fazama izgradnje vjetroelektrana u moru.

Monitoringom izgrađene infrastrukture osigurava se ažurnost informacija za procjenu stanja zaštite infrastrukture od erozije (engl. scour protection), razine morskog dna u blizini temeljnih stupova, dubine ukopanih podmorskih kabela cijelom njihovom dužinom u svrhu zaštite od rizika izbijanja kabela na morsku površinu, što može predstavljati rizik trošenja i pucanja, te prekida isporuke električne energije (Slika 5, Slika 6). Radi se i monitoring križanja više elektroenergetskih kablova koji se zaštićuju posebnom betonskom armaturom nalik krevetnim madracima, kao i nasipavanjem velike količine kamenja (engl. rock dump protection).

Osim podvodne inspekcije izgrađene infrastrukture, neizostavan dio je i identifikacija objekata na dnu

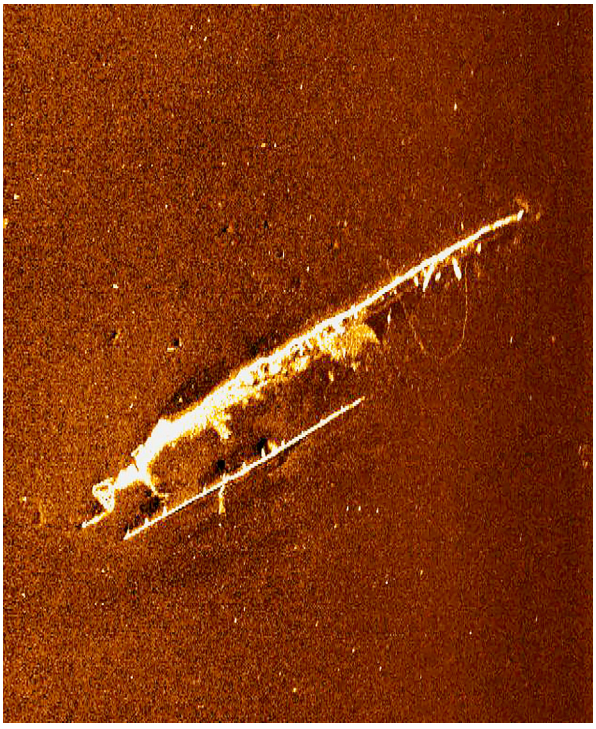


Slika 5: Zaštita od erozije na konstrukcijama vjetroelektrana u moru (URL 3).



Slika 6: Podvodni stup s vidljivim kablovima koji ulaze u konstrukciju te pripadajuća kružna zaštita od erozije – panoramski dubinomjer.

mora, koji predstavljaju potencijalnu opasnost za sigurnost gradnje, navigaciju i okoliš (Slika 7).



Slika 7: Japanski lovac na podmornice (CHA-116) u zaljevu Manila potopljen 13. studenoga 1944., podatci panoramskog dubinomjera.

4.3. Geološko-strukturni dubinomjer (SBP)

Geološko-strukturni dubinomjeri, tj. sustavi za profiliranje ispod morskog dna identificiraju i mjere različite slojeve morskog sedimenta te izgrađene infrastrukture ispod razine morskog dna (Slika 8). Ovi akustični sustavi koriste tehniku sličnu jednofrekvencijskim sonarima. Izvor zvuka emitira zvučni signal okomito prema dolje u vodu, a prijemnik prati povratni signal koji se odbija od morskog dna. Dio akustičnog signala će prodrijeti kroz morsko dno i reflektirati se kada naiđe na granicu između dva sloja koji imaju različitu akustičnu impedanciju. Spomenutu reflektiranu energiju sustav koristi za pružanje informacija o slojevima sedimenta ispod granice sediment/voda.

4.4. Magnetometar (MAG)

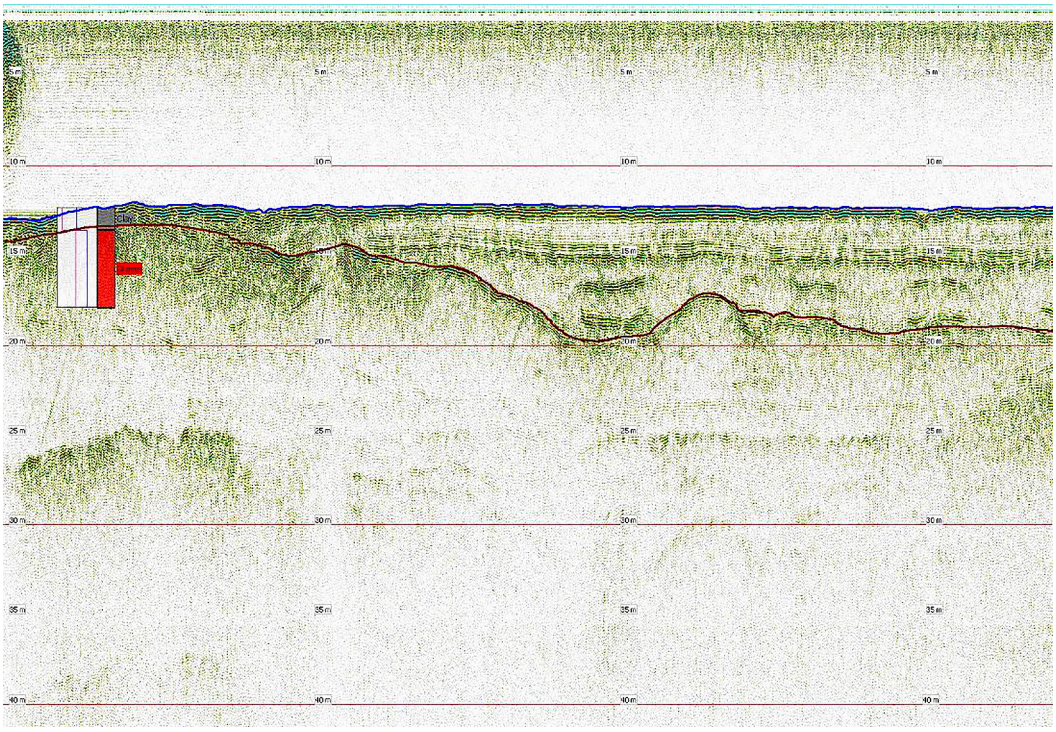
Magnetometar mjeri varijaciju Zemljinog magnetskog polja i može se koristiti za otkrivanje antropogenih obilježja na morskom dnu, zakopanih na kopnu ili kao pomoć u kartiranju geoloških obilježja. Osnovna je metoda za identifikaciju preostalih eksplozivnih naprava na dnu mora, kojih je npr. u Sjevernom moru zbog II. Svjetskog rata na desetke tisuća i predstavljaju ozbiljan rizik u procesu izgradnje vjetroelektrana u moru.

Magnetometarska istraživanja koriste se u različitim poljima zbog svoje penetracije do cca 15 m, a posebno su prikladna za otkrivanje i mapiranje svih veličina željeznih objekata, uključujući: cjevovode, kabele, lance, sidra i druge raspršene ostatke bilo brodoloma, streljiva, zrakoplova, motora te drugih magnetskih objekata (Slika 9). Također, primjenu nalazi kod monitoringa prethodno izgrađene infrastrukture (npr. podmorski elektroenergetski kablovi).

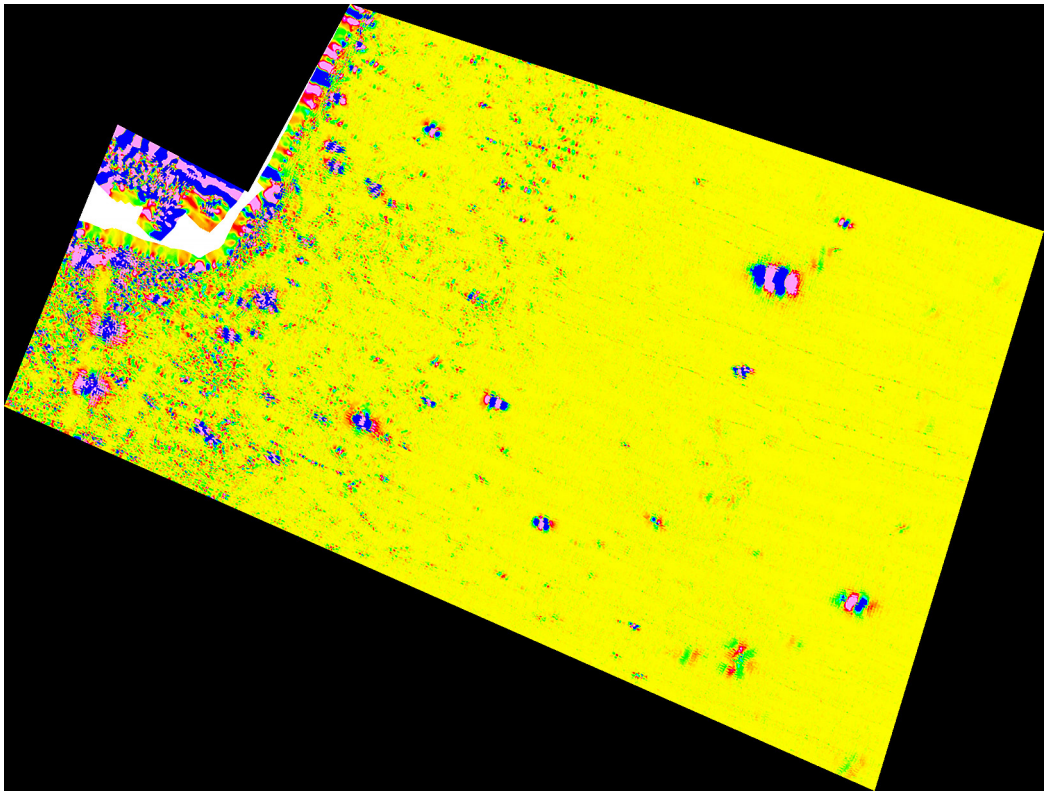
Analiza izlaznih rezultata izmjere magnetometrom pouzdano pretvara velike količine magnetskih podataka u modelirane mreže i daje izračune ciljnih lokacija, dubina te veličine i prividne težine objekta.

4.5. Seizmika visoke i ultra visoke razlučivosti (HRS/UHRS)

Pomorska seizmička istraživanja visoke i ultra visoke razlučivosti obično se koriste za identifikaciju mogućih geoloških opasnosti kod bušotina u moru (prodiranje plitkog plina), razvoja obnovljivih izvora energije kao što su vjetroelektrane, trasa cjevovoda i drugih instalacija u moru. Među mogućim geološkim



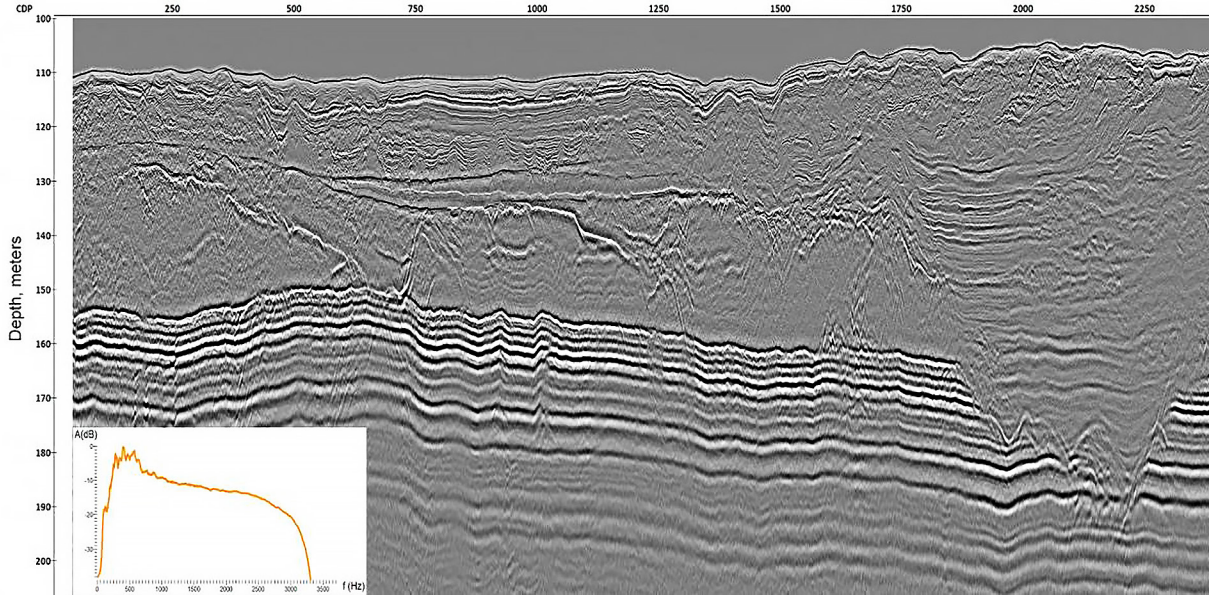
Slika 8: Razina morskog dna i slojevi ispod dna – geološko-strukturni dubinomjer.



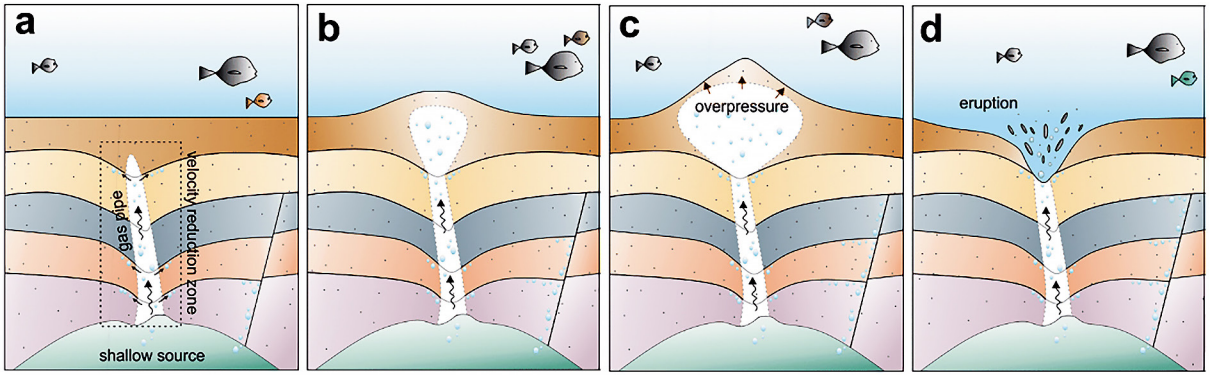
Slika 9: Prikaz izlaznih rezultata istraživanja magnetometrom.

opasnostima su plitki plinski nabijeni intervali, rasjedi, glacijalne značajke, zone povišenog tlaka, tokovi blata, zone toka plitke vode i slično (Slika 11).

Povećana kvaliteta morskih podataka visoke razlučivosti rezultirala je uspješnom primjenom inverzije akustične impedancije UHR podataka za izvođenje fizičkih svojstava podzemnih sedimenata (URL 1). Tradicionalne tehnike obrade, temeljene na tokovima industrije nafte i plina, nisu u potpunosti primjenjive u HR/UHR pomorskoj seizmici, jer ne uzimaju u obzir specifičnosti potonje, kao što je frekvencijski pojas (Slika 10).



Slika 10: Prikaz slojeva dna kroz seizmička istraživanja (URL 1).



Slika 11: Prikaz prodiranja i erupcije plina na morskom dnu (URL 4).

5. Zaključak

U nadolazećem periodu bit će sve više investicija u obnovljive izvore energije u moru, kao alternative konvencionalnim izvorima te će stoga i istraživanja u moru biti sve učestalija. U projektu izgradnje vjetroelektrana u moru potreban je multidisciplinaran pristup i integracija različitih metoda koje su navedene u ovom radu, dok je monitoring izgrađene infrastrukture u moru stalan i izvršava se na mjesečnoj razini.

S ubrzanim napretkom tehnologije za izmjeru i istraživanje mora, povećavaju se i zahtjevi za razinu obrade podataka. Primjerice, 5 godina unazad standard detekcije objekata na morskom dnu je bila identifikacija objekata minimalnih dimenzija 1 m, dok je u današnjim istraživanjima potrebno identificirati objekte minimalnih dimenzija 0,2 m u bilo kojem smjeru.

Sve većom komercijalizacijom bespilotnih površinskih plovila (USV) i autonomnih bespilotnih plovila (AUV) te primjenom metoda umjetne inteligencije u obradi podataka, mijenjaju se standardi i pristup hidrografskim istraživanjima. Popratna regulativa još uvijek nije u potpunosti izrađena i definirana, no na njezinoj se uspostavi proteklih godina ubrzano radi.

Literatura

Amenta, C., Stagnaro, C. (2022): The Failures of the Entrepreneurial State: Subsidies to Renewable Energies in Europe.

Schneider, D. R., Duić, N., Bogdan, Ž. (2005): Mapping the potential for decentralized energy generation based on renewable energy sources in the Republic of Croatia.

URL 1: Geodevice Ltd., https://geodevice.co/, (8.7.2022.).

URL 2: Europska udruga WindEurope, https://windeurope.org/, (8.7.2022.).

URL 3: JÄGER GROUP, https://www.jaegergroup.com/en/, (12.7.2022.).

URL 4: ResearchGate, https://www.researchgate.net/figure/Development-of-a-pockmark-formation-a-gas-pipe-rises-towards-the-seafloor-b-fluid-gas_fig2_327653853, (12.7.2022.).

Hydrographic Survey Methods Analysis in the Offshore Renewables Construction

Abstract

EU legislation which promotes offshore renewables has developed significantly in recent years in line with increased investments in the field of offshore renewables. The process of offshore infrastructure construction also requires complex research in all its phases. In parallel with the offshore construction methods, hydrographic survey methods are also being developed, where the demands of investors are becoming more and more complex in terms of required reliability and representativeness of the data. For the successful implementation of this long-term process, a multidisciplinary approach of the hydrographic survey and data processing methods is required.

Keywords: *hydrography, offshore renewables, offshore windfarms, seismic investigation*

SESIJA 3

Instrumentarij i tehnologije današnjice

40 godina kalibracijske baze Geodetskog fakulteta Sveučilišta u Zagrebu

Mladen Zrinjski[1], Krunoslav Špoljar[2], Đuro Barković[3], Antonio Tupek[4], Sergej Baričević[5]

[1] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, 10000 Zagreb, Hrvatska, mladen.zrinjski@geof.unizg.hr

[2] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, 10000 Zagreb, Hrvatska, krunoslav.spoljar@geof.unizg.hr

[3] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, 10000 Zagreb, Hrvatska, djuro.barkovic@geof.unizg.hr

[4] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, 10000 Zagreb, Hrvatska, antonio.tupek@geof.unizg.hr

[5] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, 10000 Zagreb, Hrvatska, sergej.baricevic@geof.unizg.hr

Sažetak

Kalibracijska baza sastoji se od dva ili više trajno stabiliziranih geodetskih stupova s ugrađenim vijkom za prisilno centriranje, a služi za definiranje mjerila velikih duljina. Kalibracijska baza Geodetskog fakulteta Sveučilišta u Zagrebu izgrađena je 1982. godine na nasipu oteretnog kanala Sava–Odra u Donjoj Lomnici, u blizini Velike Gorice. U radu je dan pregled najvažnijih umjeravanja kalibracijske baze Geodetskog fakulteta u proteklih 40 godina. Baza je uspostavljena za potrebe ispitivanja i umjeravanja elektrooptičkih daljinomjera i postizanja jednoga zajedničkog mjerila pri mjerenju duljina do 3100 m na području Hrvatske. Od izgradnje do danas, obavljen je veliki broj preciznih umjeravanja kalibracijske baze različitim mjernim instrumentima i metodama. Praktičnu primjenu kalibracijska baza dobila je razvojem elektrooptičkih daljinomjera, a razvitkom GNSS-a kalibracijska baza postaje testno područje za ispitivanje GNSS-uređaja. Precizno umjeravanje kalibracijske baze poželjno je obaviti neovisnim mjernim metodama što omogućuje kontrolu i procjenu kvalitete mjernih rezultata.

Ključne riječi: *GNSS, kalibracijska baza, precizni elektrooptički daljinomjer, relativna točnost, umjeravanje*

1. Uvod

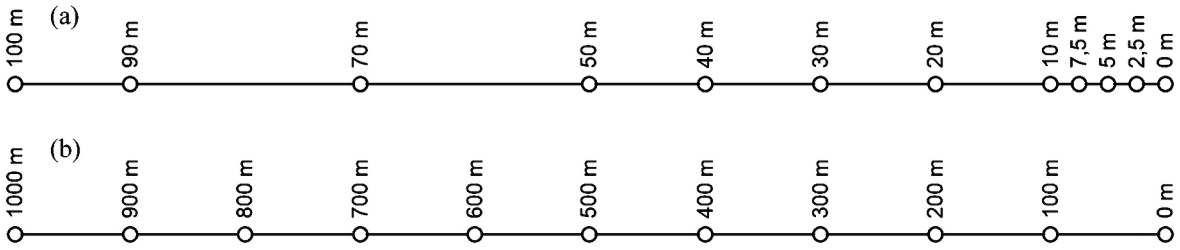
Prva kalibracijska baza Nummela izgrađena je u Finskoj 1933. godine, a služila je za umjeravanje invarnih žica duljine 24 m. Razvitkom preciznih elektrooptičkih daljinomjera, 1947. godine kalibracijska baza Nummela prva je umjerena svjetlosnim interferometrom Väisälä i najdulja je kalibracijska baza u svijetu umjerena svjetlosnim interferometrom (Jokela, 2014). Kalibracijska baza Geodetskog fakulteta Sveučilišta u Zagrebu izgrađena je 1982. godine na inicijativu prof. emer. dr. sc. Nikole Solarića. Uspostavljena je za potrebe ispitivanja i umjeravanja elektrooptičkih daljinomjera i postizanja jednoga zajedničkog mjerila pri mjerenju duljina do 3100 m na području Hrvatske. Prvo umjeravanje obavljeno je invarnim žicama 1983. godine. Prijenosom mjerila s kalibracijske baze Ebersberger Forst u Münchenu 1996. godine primjenom preciznog elektrooptičkog daljinomjera Kern Mekometer ME5000, kalibracijska baza Geodetskog fakulteta postala je dio svjetskih mjernih sustava i primarni etalon za mjerenje velikih duljina u Hrvatskoj. Adicijsku korekciju i mjerilo za velike duljine, zbog pogreške fazne nehomogenosti i periodijske pogreške, nije moguće odrediti u laboratoriju nego na kalibracijskoj bazi. Razvojem globalnih navigacijskih satelitskih sustava (GNSS – Global Navigation Satellite Systems) na kalibracijskim bazama obavljaju se ispitivanja i umjeravanja GNSS-instrumenata najčešće primjenom relativne statičke metode. U nastavku rada dan je opći pregled i metode umjeravanja kalibracijske baze Geodetskog fakulteta.

2. Kalibracijska baza Geodetskog fakulteta

Kalibracijska baza Geodetskog fakulteta Sveučilišta u Zagrebu dizajnirana je slično kao švicarska kalibracijska baza Aarau, a izgrađena je 1982. godine. Njezina glavna namjena je ispitivanje i umjeravanje elektrooptičkih daljinomjera te ispitivanje GNSS-prijamnika i antena. Prema dostupnoj literaturi najdulja je kalibracijska baza u svijetu i baza s najvećim brojem stupova (Zrinjski, 2010). Stupovi kalibracijske baze u blagom su konkavnom luku, visine od 0,94 m u sredini baze do 1,48 m na krajevima baze te su na stupovima ugrađeni vijci za prisilno centriranje podnožnih ploča koji imaju maksimalno poprečno odstupanje do 5 cm u odnosu na pravac od početnog stupa baze do stupa na udaljenosti 1100 m (Slika 1).



Slika 1: Kalibracijska baza Geodetskog fakulteta Sveučilišta u Zagrebu (Zrinjski, 2010).

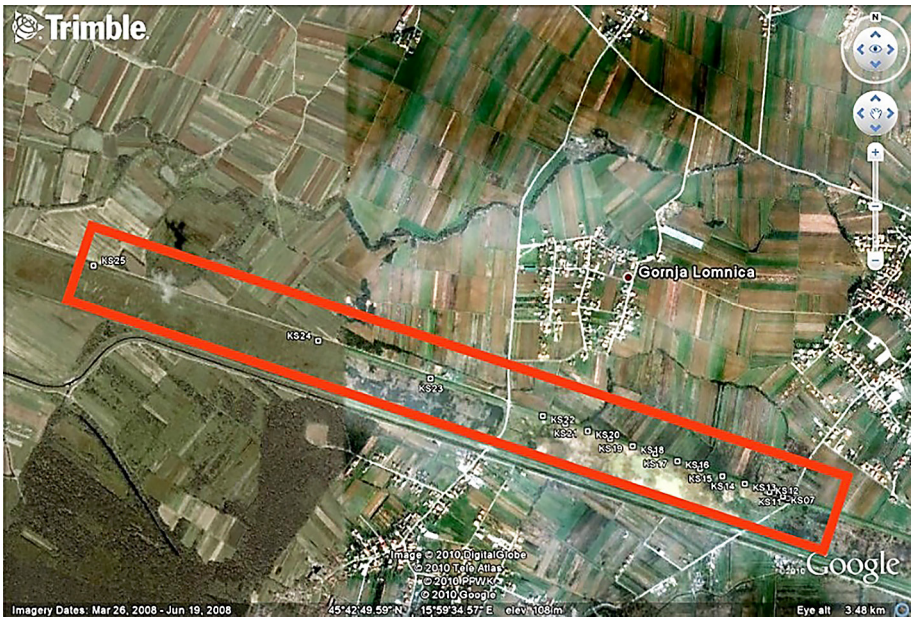


Slika 2: Raspored stupova kalibracijske baze Geodetskog fakulteta, (a) udaljenosti od početnog stupa 11A (Tablica 1, drugi stupac), (b) udaljenosti od početnog stupa 0 (Tablica 1, četvrti stupac) (Zrinjski i dr., 2022).

Projekt s rasporedom stupova (Slika 2, Tablica 1) izrađen je 1980. godine, pri čemu razmaci stupova omogućuju ispitivanje utjecaja pogreške fazne nehomogenosti i periodijske pogreške daljinomjera. Utjecaj pogreške fazne nehomogenosti ispituje se na malim duljinama do 100 m (Zrinjski i dr., 2019), dok stupovi do 3100 m služe za potrebe ispitivanja i umjeravanja daljinomjera na velikim duljinama (Solarić i dr., 1992).

Tablica 1: Raspored stupova kalibracijske baze Geodetskog fakulteta (Zrinjski, 2010).

Oznaka stupa	Udaljenost od početnog stupa 11A [m]	Oznaka stupa	Udaljenost od početnog stupa 0 [m]
11A	0	0	0
10A	2,5	1	100
9A	5	2	200
8A	7,5	3	300
7A	10	4	400
6A	20	5	500
5A	30	6	600
4A	40	7	700
3A	50	8	800
2A	70	9	900
1A	90	10	1000
0	100	11	1500
		12	2000
		13	3000



Slika 3: Položaji stupova kalibracijske baze Geodetskog fakulteta (Zrinjski i dr., 2011).

Slika 3 prikazuje položaj stupova kalibracijske baze Geodetskog fakulteta u aplikaciji Google Earth, koordinate kojih su određene umjeravanjem 2009. godine (Zrinjski i dr., 2011).

3. Pregled metoda umjeravanja kalibracije baze Geodetskog fakulteta

Prvo mjerenje kalibracijske baze Geodetskog fakulteta obavljeno je 1983. godine invarnim žicama duljine 24 m i invarnom vrpcom duljine 12 m. Preciznim elektrooptičkim daljinomjerom Kern Mekometer ME3000 obavljeno je umjeravanje 1984. godine, dok je 1988. i 1996. godine kalibracijska baza umjerena preciznim elektrooptičkim daljinomjerom Kern Mekometer ME5000. Umjeravanje 2009. godine obavljeno je preciznim elektrooptičkim daljinomjerom Leica TCA2003 te je primjenom GPS-a provedena neovisna kontrola mjerenja.

3.1. Umjeravanja kalibracije baze invarnim žicama i Mekometrom ME3000

Prvo umjeravanje kalibracijske baze dvjema invarnim žicama duljine 24 m i jednom invarnom vrpcom duljine 12 m, obavljeno je 1983. godine. Invarne žice i invarna vrpca prije upotrebe umjerene su u Organisation Européenne pour la recherche nucléaire (CERN) u Genevi i Sevresu te su dobile certifikate. Međusobna umjeravanja invarnih žica i vrpce obavljena su na kontrolnim stupovima u Laboratoriju za mjerenja i mjernu tehniku Geodetskog fakulteta. Nakon obavljenog mjerenja na kalibracijskoj bazi, žice i vrpca ponovno su umjerene zbog moguće promjene njihove duljine tijekom rada. Primijenjen je postupak mjerenja Jäderinovim bazisnim priborom. Umjereno je prvih 500 m kalibracijske baze te je dobivena definitivna duljina baze nereducirana na nivo plohu mora (Novaković i dr., 1985):

$$L = 499{,}99196\ \text{m} \pm 0{,}471\ \text{mm} \tag{1}$$

Relativna pogreška mjerenja duljine L iznosila je (Novaković i dr., 1985):

$$R = \frac{1}{1\,100\,000} \tag{2}$$

Umjeravanje kalibracijske baze preciznim elektrooptičkim daljinomjerom Kern Mekometer ME3000 obavljeno je 1984. godine do 3000 m duljine. Umjeravanjem je postignuta relativna nesigurnost $1 \cdot 10^{-6}$ (Maurer i dr., 2001).

3.2. Umjeravanja kalibracije baze Mekometrom ME5000

U jesen 1988. godine u trajanju sedam dana kalibracijska baza Geodetskog fakulteta umjerena je preciznim elektrooptičkim daljinomjerom Kern Mekometer ME5000 u vlasništvu Fakulteta za arhitekturu, građevinu i geodeziju Univerziteta u Ljubljani. Postignuta je visoka relativna preciznost mjerenja duljine $0{,}8 \cdot 10^{-7}$, primjenjujući novi, originalni postupak izjednačenja i ocjene preciznosti mjerenja (Solarić i dr., 2002). Za duljine do 100 m, mjerenja su obavljena dva puta te je dobiveno srednje standardno odstupanje mjerenja duljine u jednom smjeru:

$$\bar{s} = 0{,}058\ \text{mm} \tag{3}$$

Za duljine od 100 m do 3000 m obavljena su dvostruka mjerenja te je dobiveno standardno odstupanje mjerenja duljine:

$$s = 0{,}12\ \text{mm} + 0{,}21\ \text{mm} \cdot D_{\text{km}} \tag{4}$$

Naredno umjeravanje kalibracijske baze obavljeno je 1996. godine primjenom preciznog elektrooptičkog daljinomjera Kern Mekometer ME5000 u suradnji s

Geodetskim institutom Tehničkog sveučilišta u Münchenu. Posebnost tog instrumenta je da se on redovito umjerava na kalibracijskoj bazi Ebersberger Forst u Münchenu koja je umjerena svjetlosnim interferometrom Väisälä (Maurer i dr., 2001). Za duljine od 100 m do 3000 m dobiveno je standardno odstupanje mjerenja duljine u dva smjera te na osnovi izjednačenja svih mjerenja na bazi (Solarić i dr., 2002):

$$s' = 0{,}071\ \text{mm} - 0{,}131\ \text{mm} \cdot D_{\text{km}} + 0{,}375\ \text{mm} \cdot D_{\text{km}}^2 \quad (5)$$

Kalibracijska baza Ebersberger Forst u Münchenu povezana je s kalibracijskim bazama za ispitivanje elektrooptičkih daljinomjera u Njemačkoj, Austriji, Švicarskoj, Mađarskoj, Brazilu i Kanadi. Navedenim umjeravanjem 1996. godine i Hrvatska se uključila u svjetski mjerni sustav za mjerenje velikih duljina (do 3100 m), a kalibracijska baza Geodetskog fakulteta Sveučilišta u Zagrebu postala je primarni etalon za mjerenje velikih duljina u Hrvatskoj (Zrinjski, 2010).

3.3. Umjeravanje kalibracijske baze GPS-om

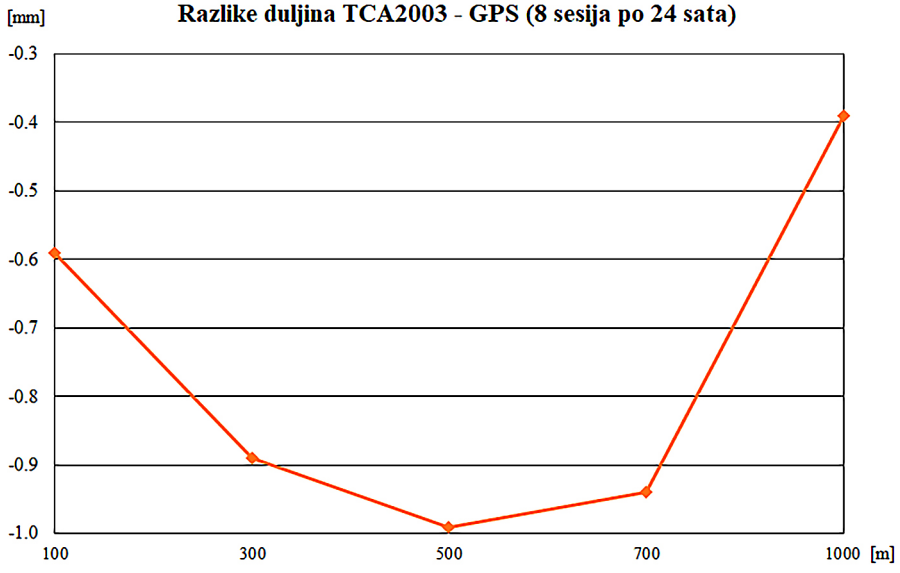
Prvo ispitivanje točnosti statičke i kinematičke metode GPS-mjerenja dvama jednofrekvencijskim prijamnicima Ashtech 1990. godine na kalibracijskoj bazi Geodetskog fakulteta prikazano je u radu Bilajbegović i Solarić (1991). Rezultati tih mjerenja uspoređeni su s rezultatima mjerenja dobivenima Mekometrom ME5000 te u visinskom smislu s rezultatima preciznog nivelmana. U kinematičkom modu rada dobivena je srednja pogreška prostorne duljine ±3,92 mm (mjereno je 10 vektora s registracijom 12 epoha po točki) i srednja pogreška visinskih razlika ±1,05 cm (mjereno je 10 visinskih razlika između stupova). Primjenom relativne statičke metode dobivena je razlika između duljine mjerene Mekometrom ME5000 i GPS-prijamnicima u iznosu +0,6 mm na duljini 1000 m (mjeren je samo jedan vektor). Razlika visinskih razlika između krajnjih točaka baze određena preciznim nivelmanom i GPS-mjerenjima iznosi –11 mm, pri čemu je mjerena samo jedna visinska razlika (Bilajbegović i Solarić, 1991).

3.4. Umjeravanje kalibracijske baze Leicom TCA2003 i GPS-om

Kalibracijska baza obnovljena je 2007. godine i posljednje umjeravanje Geodetski fakultet Sveučilišta u Zagrebu obavio je 2009. godine preciznim elektrooptičkim daljinomjerom, a primjenom GPS-a provedena je neovisna kontrola mjerenja (Zrinjski, 2010). Kalibracijska baza umjerena je preciznim elektrooptičkim daljinomjerom Leica TCA2003, a neovisna kontrola

Tablica 2: Rezultati mjerenja na kalibracijskoj bazi Geodetskog fakulteta 2009. godine (prema Zrinjski, 2010; Zrinjski i dr., 2022).

Stupovi	Približna duljina [m]	Standardno odstupanje TCA2003 (k=1) [mm]	Standardno odstupanje GPS (k=1,96) [mm]	Razlika duljina TCA2003–GPS [mm]	Relativna točnost
0–1	100	0,067	0,26	–0,59	1:169 492
0–3	300	0,070	0,35	–0,89	1:337 079
0–5	500	0,073	0,45	–0,99	1:505 051
0–7	700	0,076	0,49	–0,94	1:744 681
0–10	1000	0,081	0,70	–0,39	1:2 564 103



Slika 4: Razlike konačnih duljina TCA2003 – GPS (Zrinjski, 2010).

Tablica 3: Pregled metoda umjeravanja na kalibracijskoj bazi Geodetskog fakulteta.

Godina	Približna duljina [m]	Metoda umjeravanja	Relativna točnost
1983	500	Invarne žice 24 m + traka 12 m	1:1 061 554
1984	3000	Mekometer ME3000	1:1 000 000
1988	3000	Mekometer ME5000	1:12 500 000
1990	1000	Mekometer ME5000 – GPS	1:1 666 667
1996	3000	Mekometer ME5000	1:9 090 909
2009	1000	Leica TCA2003 – GPS	1:2 564 103

obavljena je GPS-prijamnicima Trimble 5700 i Trimble R7 te antenama Zephyr Geodetic. U Tablici 2 prikazana su standardna odstupanja dobivena mjerenjima duljina raspona stupova baze primjenom TCA2003 i GPS-om te ukupne razlike TCA2003 – GPS pri čemu su sve dobivene razlike manje od 1 mm (Zrinjski, 2010).

Rezultati umjeravanja pokazuju da je mjerilo na kalibracijskoj bazi Geodetskog fakulteta određeno s točnošću 0,39 mm na duljini 1000 m (Tablica 2, Slika 4), uz primjenu preciznog elektrooptičkog daljinomjera Leica TCA2003, senzora za mjerenje atmosferskih parametara Väisälä WXT510, umjeravanjem frekvencije daljinomjera u Laboratoriju za mjerenja i mjernu tehniku i određivanjem periodijske pogreške te neovisnom kontrolom GPS-mjerenjima. Predznak svih razlika duljina je minus, što znači da su sve duljine dobivene GPS-om veće od istih dobivenih primjenom preciznog elektrooptičkog daljinomjera Leica TCA2003 (Zrinjski, 2010).

4. Analiza metoda umjeravanja kalibracijske baze

U Tablici 3 dan je pregled najvažnijih metoda umjeravanja kalibracijske baze Geodetskog fakulteta Sveučilišta u Zagrebu uz postignutu relativnu točnost.

5. Zaključak

Kalibracijske baze sa stabiliziranim stupovima pružaju najbolju mogućnost za određivanje mjerila velikih duljina. Kako bi se postigla relativna točnost 1:1 000 000 (1 ppm, 10^{-6}) ili bolja pri mjerenju elektrooptičkim daljinomjerom, potrebno je precizno mjeriti atmosferske parametre, umjeriti mjernu frekvenciju elektrooptičkog daljinomjera te odrediti adicijsku korekciju i periodijsku pogrešku. Preporuča se mjerenje atmosferskih parametara duž kalibracijske baze, uz svaki stup. Potrebno je odabrati senzor koji ima zadovoljavajuću točnost i automatizirati postupak mjerenja atmosferskih parametara (temperature zraka, atmosferskog tlaka i relativne vlažnosti zraka).

Mnoge kalibracijske baze u svijetu izgrađene su prije razvoja GNSS-a te nemaju mogućnost obavljanja umjeravanja GNSS-om zbog neprikladnog položaja stupova u odnosu na prijam signala satelita. Prednost kalibracijske baze Geodetskog fakulteta je njezin položaj koji je izrazito pogodan za GNSS-mjerenja.

Posljednje umjeravanje kalibracijske baze Geodetskog fakulteta obavljeno je dvjema neovisnim metodama (preciznim elektrooptičkim daljinomjerom Leica TCA2003 i GPS-om), pri čemu je postignuta relativna točnost 1:2 564 103 na duljini 1000 m. Razlika duljina TCA2003 – GPS na duljini 1000 m iznosi –0,39 mm, što definira mjerilo kalibracijske baze Geodetskog fakulteta s točnošću 0,39 mm na duljini 1000 m te se može kategorizirati u visokoprecizna mjerenja.

Danas kalibracijska baza Geodetskog fakulteta služi za ispitivanje i umjeravanje elektrooptičkih daljinomjera i GNSS-instrumenata te drugih mjernih instrumenata i uređaja, što obavezno treba obavljati periodično i prije preciznih geodetskih mjerenja.

Za buduća umjeravanja kalibracijske baze preporuča se svakako primijeniti barem dvije neovisne precizne metode (precizni elektrooptički daljinomjer i GNSS), radi usporedbe dobivenih rezultata i preciznosti mjerenja te procjene ostvarene točnosti umjeravanja.

Literatura

Bilajbegović, A., Solarić, M. (1991): Mogućnosti i stanje GPS-tehnologije te rezultati ispitivanja prijemnika Ashtech na kalibracijskoj bazi Geodetskog fakulteta u Zagrebu, Geodetski list, 45 (1–3), 25–34.

Jokela, J. (2014): Length in Geodesy – On Metrological Traceability of a Geospatial Measurand, Doctoral dissertation, School of Engineering, Aalto University, Espoo, Finland.

Maurer, W., Schnädelbach, K., Solarić, N., Novaković, G. (2001): Povezivanje münchenske i zagrebačke baze za ispitivanje i umjeravanje elektrooptičkih daljinomjera, Geodetski list, 55 (3), 177–194.

Novaković, G., Džapo, M., Lasić, Z. (1985): Prvo mjerenje duljine kalibracijske baze Geodetskog fakulteta u Zagrebu invarskim žicama, Geodetski list, 39 (10–12), 291–295.

Solarić, N., Solarić, M., Benčić, D. (1992): Projekt i izgradnja kalibracijske baze Geodetskog fakulteta Sveučilišta u Zagrebu, Geodetski list, 46 (1), 7–25.

Solarić, N., Lapaine, M., Novaković, G. (2002): Testing the Precision of the Electro-Optical Distance Meter

Mekometer ME 5000 on the Calibration Baseline Zagreb, Survey Review, 36 (286), 4, 612–626.

Zrinjski, M. (2010): Definiranje mjerila kalibracijske baze Geodetskog fakulteta primjenom preciznog elektrooptičkog daljinomjera i GPS-a, doktorska disertacija, Geodetski fakultet Sveučilišta u Zagrebu, Zagreb.

Zrinjski, M., Barković, Đ., Kapustić, M. (2011): Determination of Pillar Coordinates at the Calibration Baseline of the Faculty of Geodesy in Zagreb by Applying GPS, Conference Proceedings, Volume II – 11th International Multidisciplinary Scientific GeoConference SGEM 2011, International Multidisciplinary Scientific GeoConference SGEM (Ed.), Sofia, 239–246.

Zrinjski, M., Barković, Đ., Baričević, S. (2019): Precise Determination of Calibration Baseline Distances, Journal of Surveying Engineering, 145 (4), 05019005, 1–9.

Zrinjski, M., Barković, Đ., Špoljar, K. (2022): Pregled metoda preciznog umjeravanja kalibracijskih baza, Geodetski list, 76 (1), 25–52.

40 Years of the Calibration Baseline of the Faculty of Geodesy, University of Zagreb

Abstract

The Calibration Baseline consists of two or more permanently stabilized pillars with an installed forced centring screw, and it is used for defining long range scales. The Calibration Baseline of the Faculty of Geodesy, University of Zagreb was built in 1982 at the embankment of the Sava–Odra relief canal in Donja Lomnica, in the vicinity of Velika Gorica. The paper presents an overview of the most important calibrations at the Calibration Baseline of the Faculty of Geodesy in the last 40 years. The Calibration Baseline was established for the purpose of testing and calibration of electro-optical distance meters and of achieving a common scale in measuring the distances up to 3100 m at the territory of Croatia. Ever since the establishment until today, there have been numerous precise calibrations performed at the Calibration Baseline with various measuring instruments and methods. The development of electro-optical distance meters has brought along the practical application of the Calibration Baseline, and the development of GNSS provided the use of Calibration Baseline as a test area for testing the GNSS devices. Precise calibration of the Calibration Baseline should be done by means of independent measuring methods, which provides the quality checking and evaluation of measuring results.

Keywords: *calibration, Calibration Baseline, GNSS, precise electro-optical distance meter, relative accuracy*

Određivanje vlažnosti šumskog pokrova i utjecaj na šumske požare

Robert Župan[1], Stanislav Frangeš[2], Adam Vinković[3]

[1] Geodetski fakultet, Sveučilište u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, rzupan@geof.hr

[2] Geodetski fakultet, Sveučilište u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, sfranges@geof.hr

[3] Geodetski fakultet, Sveučilište u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, avinkovic@geof.hr

Sažetak

Istražene su mogućnosti praćenja vlage i vodenih površina na primjeru nizinske šume uz desnu obalu rijeke Česme koje su dio gospodarske jedinice Česma. Korišteni su podaci s nove satelitske misije Sentinel-2 i Landsat 8 koji omogućavaju do sada najbolju prostornu rezoluciju besplatnih multispektralnih snimaka. Korišteni su vegetacijski indeksi te kombinacija vodnog indeksa normalizirane razlike i termalnih podataka kako bi se dobile razlike u vlažnosti. Za računanje vlažnosti korištene su metode vodni indeks normalizirane razlike (NDWI1 i NDWI2), Tasseled Cap Transformation Wetness (TCTW) te kombinacija modificiranog Soil moisture indeksa koji umjesto vegetacijskog indeksa normalizirane razlike koristi vodni indeks normalizirane razlike u kombinaciji s termalnim kanalom Landsata 8. U razdoblju bez zeljaste vegetacije za detekciju vodnih površina i mokrih površina najbolje se pokazao NDWI2 dok je za vegetacijsko razdoblje najbolje rezultate pokazao modificirani indeks vlažnosti tla kojim se jasno razlikuju vlažniji i suši dijelovi šume. Premda se najveća vrijednost za vlažnost nije pokazala odgovarajućom te bi se za prikazanu metodu prije našla primjena pri definiranju biomase u šumama.

Ključne riječi: *daljinska istraživanja, požari, sentinel-2, vlažnost šumskog zemljišta, vodene površine*

1. Uvod

Šume su važan dio Zemljina ekosustava, a bitne su za regulaciju funkcija ekosustava te za ekonomske djelatnosti i produkciju sirovina u građevinarstvu, drvnoj industriji i energetskom iskorištavanju drvne mase (Krajter Ostoić i Vuletić, 2016). Uslijed mnogih antropogenih pritisaka, kao što je promjena hidroloških uvjeta u šumama zbog hidrotehničkih radova, tj. kanaliziranja vodotoka, presijecanja meandara ili izgradnje nasipa što dovodi do smanjenja prirodnog plavljenja poplavnih šuma i smanjenja retencijskih sposobnosti šuma, također tijekom kanaliziranja vodotoka često dolazi do ukapanja korita vodotoka čime se snižava razina podzemnih voda u zaobalju što drastično utječe na razvoj poplavnih šumskih ekosustava (Prpić, 2003). Navedenim radovima također se smanjuje korištenje šuma kao retencijskih područja za odterećivanje poplavnih viškova te općekorisne funkcije šuma (Bačić, 2016; Pilaš i Planinšek, 2011). Pošto su šume pod velikim pritiskom koji je potrebno pratiti u cjelini zbog toga su daljinska istraživanja odlična za praćenje velikih šumskih površina (Benko i Balenović, 2011).

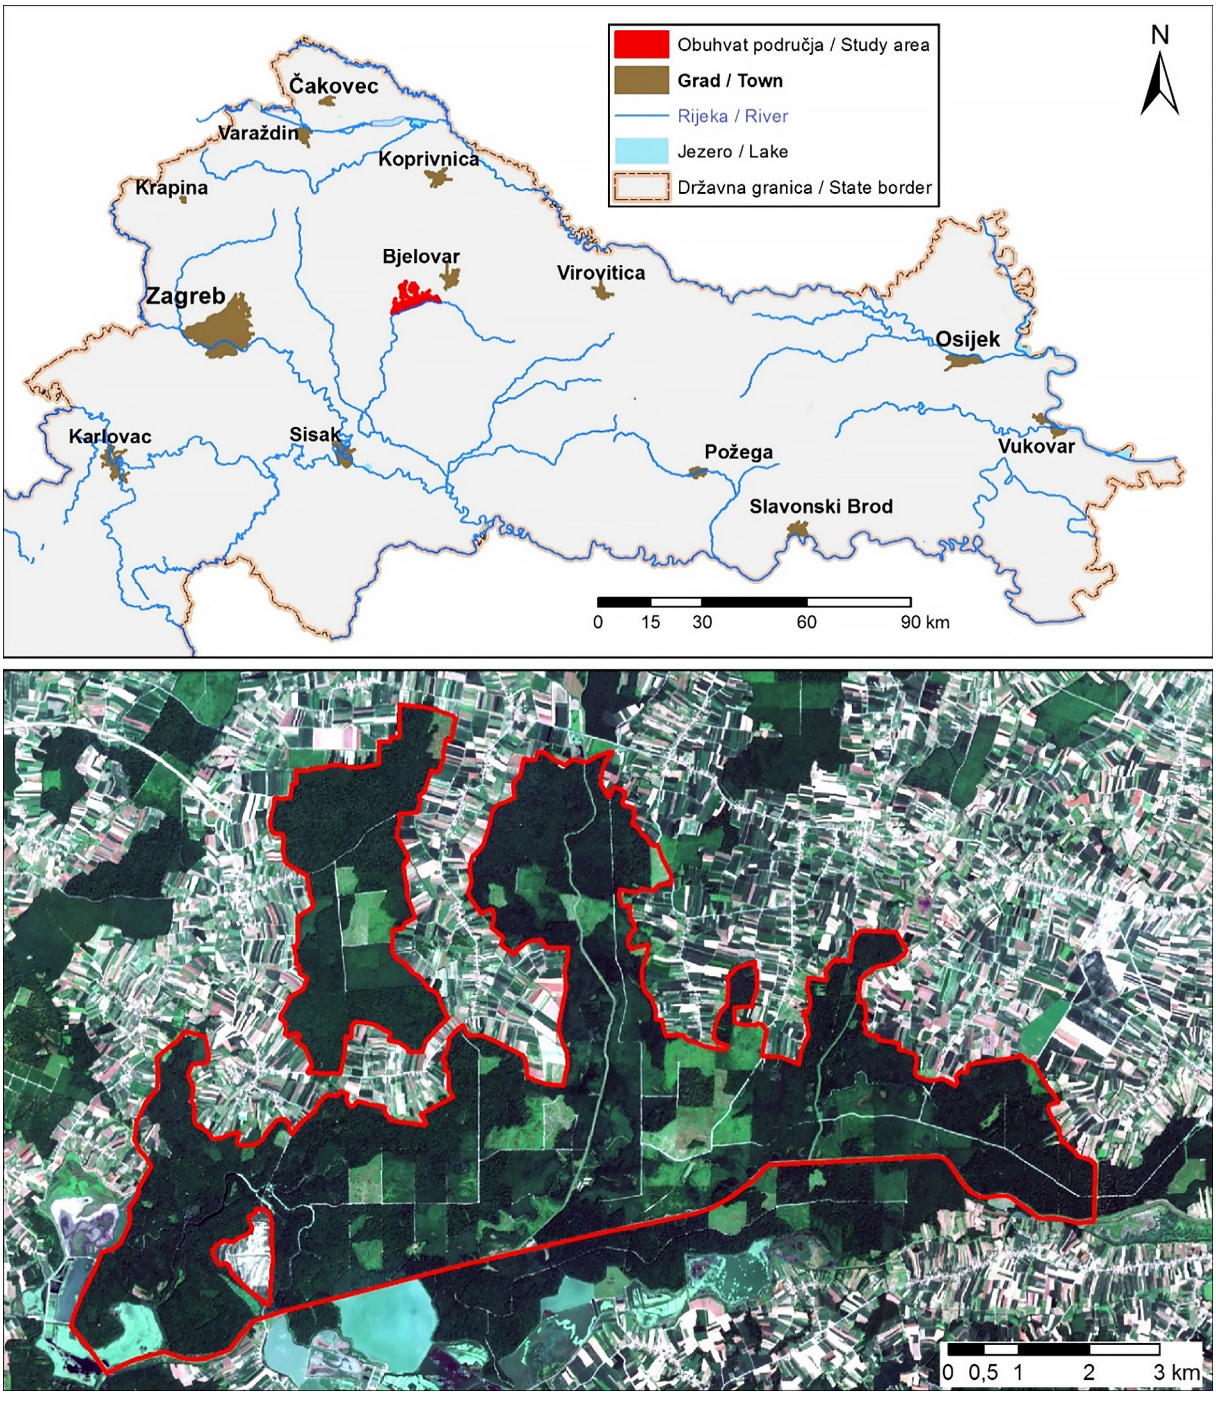
Praćenje vlažnosti šumskog zemljišta pomoću daljinskih istraživanja izuzetno je rijetko, jer gustoća šumske vegetacije onemogućava direktni vizualni kontakt s tlom što otežava određivanje vlažnosti tla (Srivastava i dr., 2016). Zbog toga se vlaga tla češće procjenjuje posredno, preko vegetacijskih indeksa. Jedno od prvih korištenja daljinskih istraživanja vlage na šumskim područjima prikazano je u radovima *Multispectral Sensing of Moisture Stress* (Olson i Rohde, 1970) i *Remote Sensing To Detect Stress in Forest* (Weber i Polcyn, 1972) u kojima se pomoću multispektralnih snimaka pokušava odrediti razina stresa kod biljaka. U istraživanjima se često koristi kombinacija vegetacijskih indeksa u kombinaciji s termalnim indeksima gdje se definira suhi i vlažni rub između vrijednosti vegetacijskih indeksa i temperature pomoću kojega se određuje vlaga određenog područja (Carlson, 2007; Chen i dr., 2015; Zubair Younis i Iqbal, 2015; Zhang i dr., 2014).

2. Područje istraživanja

Područje istraživanja na kojem se provela analiza je šuma Česma. Područje istraživanja je omeđeno sa zapada potokom Dunjara te Ribnjacima Dubrava, s juga novim koritom rijeke Česme, s istoka dalekovodom između naselja Narta – Veliko Korenovo, a sa sjevera linijom naselja Zvonik – Veliko Korenovo (Slika 1).

2.1. Korišteni podaci

Za analizu vlažnosti korišteni su podaci s platforme Europske svemirske agencije Sentinel-2 i NASA-in Landsat 8 prvi termalni kanal. Sentinel-2 platforma je nova misija unutar Copernicus programa za koji je nadležna Europska svemirska agencija (ESA) koji je generalno namijenjen za praćenje stanja kopna,



Slika 1: Položaj istraživanog područja na Sentinel-2 snimku.

prvenstveno tla, vegetacije i kopnenih voda i dr. Sentinel-2 misija sastoji se od dva satelita Sentinel-2A i Sentinel-2B koji su identični i nose identične multispektralne senzore (MSI) s 13 spektralnih kanala koji obuhvaćaju vidljivi, bliskoinfracrveni i kratkovalni infracrveni spektar (Tablica 1). Lansiranjem drugog satelita Sentinel-2 (7.3.2021.) vrijeme prekrivanja jednog područja je 5 dana, dok je prije lansiranja drugog satelita bilo 10 dana. Budući da u vrijeme istraživanja Sentinel-2B još nije bio lansiran, za potrebe ovog rada korišteni su samo podaci sa satelita Sentinel-2A.

Za potrebe ovog istraživanje korišteni su snimci procesne razine Level-1c, što znači da su na snimkama prethodno izvršene radiometrijske i geometrijske korekcije. Od Landsat 8 (URL 2) misije korišteni su podaci s prvog termalnog (dugovalni infracrveni) kanala, valne duljine 10,60 – 11,19 µm i prostorne rezolucije od 100 metara.

3. Metode

Metode praćenja vlage pokrova u šumskim ekosustavima pomoću multispektralnih snimaka podijeljena su u dvije vremenske kategorije tijekom godine: u vegetacijskom razdoblju i u razdoblju mirovanje ta dva razdoblja istraživana su jedno neovisno o drugom. Pomoću multispektralnih snimaka moguće je jedino

Tablica 1: Specifikacija Sentinel-2 kanala (URL 1).

Sentinel-2 kanali	Srednja valna duljina (nm)	Prostorna rezolucija (m)
Kanal 1 – Coastal aerosol	0,443	60
Kanal 2 – Plava	0,490	10
Kanal 3 – Zelena	0,560	10
Kanal 4 – Crvena	0,665	10
Kanal 5 – Vegetation Red Edge	0,705	20
Kanal 6 – Vegetation Red Edge	0,740	20
Kanal 7 – Vegetation Red Edge	0,783	20
Kanal 8 – NIR	0,842	10
Kanal 8A – Vegetation Red Edge	0,865	20
Kanal 9 – Water vapour	0,945	60
Kanal 10 – SVVIR – Cirus	1,375	60
Kanal 11 – SVVIR	1,610	20
Kanal 12 – SVVIR	2,190	20

praćenje vlage tla u površinskom sloju tla ili u vegetaciji (Carlson, 2007). Za računanje vlažnosti u ovom radu je korišteno nekoliko metoda: Vodni indeks normalizirane razlike (NDWI1 i NDWI2), Tasseled Cap Transformation Wetness (TCTW) te kombinacija normiranog vodnog indeksa s termalnim kanalom. Dobiveni podaci su uspoređeni s Hrvatskom osnovnom kartom mjerila 1:5000.

3.1. Vodni indeks normalizirane razlike

Kako bi se detektirale vodne i izrazito vlažne površine koje se nalaze u šumi koristi se metoda Vodnog indeksa normalizirane razlike (engl. Normalized Difference Water Index – NDWI), za računanje ovog indeksa koriste se barem dvije formule NDWI1 i NDWI2, (McFeeters, 1996; Gao, 1996). NDWI je najčešći način mjerenja količina vlage preko količine vlage/vode u vegetaciji, za računanje ovog indeksa postoje barem dvije formule. Prvi predstavlja kombinaciju blisko infracrvenog i kratkovalnog infracrvenog područja te je predstavljen formulom NDWI1 = (NIR–SWIR)/(NIR+SWIR) (Gao, 1996), korišteni kanali za Sentinel-2 su $NDWI = \frac{\text{kanal 12} - \text{kanal 8}}{\text{kanal 12} + \text{kanal 8}}$.

Drugi način računanja je NDWI2 koji je kombinacija zelenog spektra i kratkovalnog infracrvenog spektra, a računa se na slijedeći način NDWI2 = (ZELENI–NIR) / (ZELENI+NIR) (McFeeters, 1996) $NDWI2 = \frac{\text{kanal 3} - \text{kanal 8}}{\text{kanal 3} + \text{kanal 8}}$.

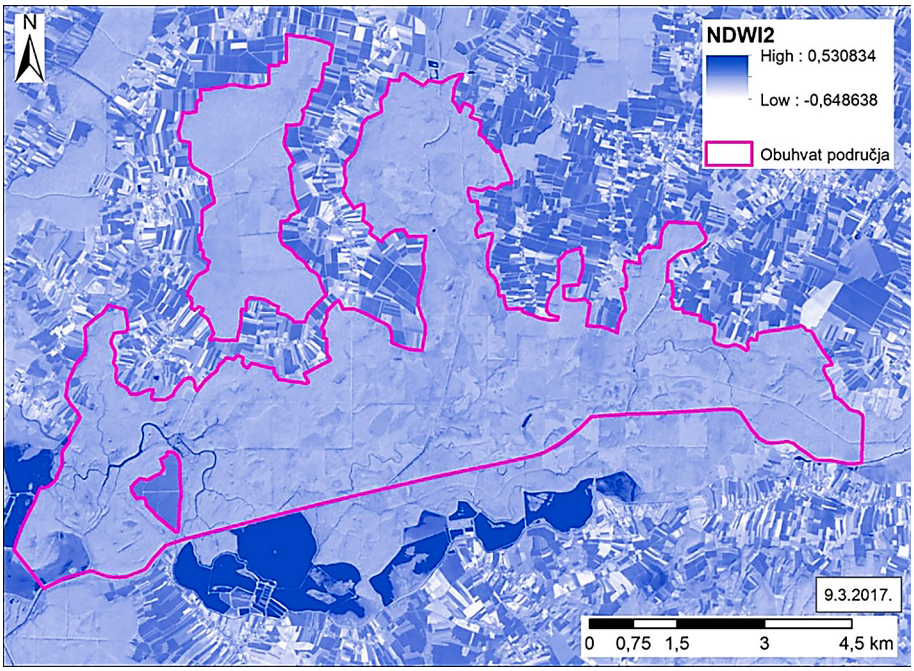
NDMI je razvijen za izračun vlage tla te je često povezan s mjerenjima vlage vegetacije predstavlja kombinaciju blisko infracrvenog i kratkovalnog infracrvenog područja te je predstavljen formulom NDMI= (NIR–SWIR)/(NIR+SWIR) (Wilson i Sader, 2002). Korišteni kanali sa Sentinel-2 su $NDMI = \frac{\text{kanal 8} - \text{kanal 11}}{\text{kanal 8} + \text{kanal 11}}$.

Razlika između NDWI i NDMI je u uporabi kanala 11 umjesto kanala 12 kod Sentinel-2 što ne donosi do velike razlike u dobivenom rezultatu, pošto NDMI bolje reagira na vlagu tla a u šumskim ekosustavima rijetko dolazi do prodiranja kontakta s samim tlom ovaj indeks nije dalje korišten.

3.2. Kombinacija vodnih indeksa normalizirane razlike i termalnih kanala pri procjeni vlage pokrova

Izračun vlažnosti pomoću ove metode većinom je korištena na područjima s pretežno poljoprivrednom vegetacijom (Carlson, 2007; Chen i dr., 2015; Zubair Younis i Iqbal, 2015), gdje se kombinacijom temperature površine tla/pokrova koja je dobivena iz Landsat prvog termalnog kanala i NDVI-a. Bitno je napomenuti da su navedena istraživanja se odnosila na nisku vegetaciju, pa za potrebe ovog rada korišten je umjesto NDVI-a, je korišten NDWI kojim se lakše razlučuje masu vegetacije koja utječe na samu vlagu i temperaturu pokrova. U literaturi se navode dva načina izračuna temperaturnog indeksa koji su predstavljeni formulom $SMI = \frac{\text{Tmax} - \text{Ts}}{\text{Tmax} - \text{Tmin}}$ (Zeng i dr., 2004; Wang i Qu, 2009) gdje T_{max} i T_{min} predstavljaju maksimalnu i minimalnu temperaturu površine za svaku individualnu vrijednost NDWI-a, a T_s je temperatura površine za svaki individualni piksel. Drugi način izračuna ovog indeksa je prema formuli $SMI = \frac{\text{Ts} - \text{Tmin}}{\text{Tmax} - \text{Tmin}}$ (Carlson, 2007; Zubair Younis i Iqbal, 2015) koji nije korišten u ovom radu.

Tasseled Cap Transformation Wetness metoda je osmišljena kako bi se kombinacijom više spektara uspjelo izolirati dio spektra koji bi ukazivao u ovom slučaju na vlažnost vegetacije (Franklin, 2001). Računanje TCTW za vlažnost iz Sentinel-2 snimaka je



Slika 2: NDWI2 na istraživanom području.

prema izrazu: 0,1509*kanal 2 + 0,1973*kanal 3 + 0.3279*kanal 4 + 0,3406*kanal 8 – 0,7112*kanal 11 – 0,4572*kanal 12 (URL 3).

Jedna o primjena TCTW je detektiranje sušenja stabala (Franklin, 2001), težište ovog izraza je dano na bliskom infracrvenom spektru pomoću kojeg se određuje količina vode u lišću. Prednost ove metode je u tome što ne stvara potencijalnu razliku između starije i mlađe šume, što dalje donosi boljoj interpretaciji vlažnosti vegetacije (Wilson i Sader, 2002).

4. Rezultati

Dobiveni rezultati NDWI1 i NDWI2 (Slika 2) podijeljeni su u dva razdoblja: razdoblje mirovanja vegetacije te u vegetacijskom razdoblju.

4.1. Razdoblje mirovanja vegetacije

Za rezultate u ovom razdoblju cilj je bio razlučiti površine u šumi koje su pod vodnim površinama te izvesti zaključke o dosegu tih vodnih površina. Za prikaz površina koje su tijekom mirovanja vegetacije bile pod vodom najbolji se pokazao rezultat NDWI2 (Slika 2). Rezultati su uspoređeni s Hrvatskom osnovnom kartom mjerila 1:5000. Pomoću ove snimke može se raspoznati mreža tekućica prije nego što su izvršene regulacije vodotoka te topografskih depresija na tom području. Istraživano područje je uvećano na lokacijama brana te pokazuje vodene površine unutar šume tijekom zimskog razdoblja.

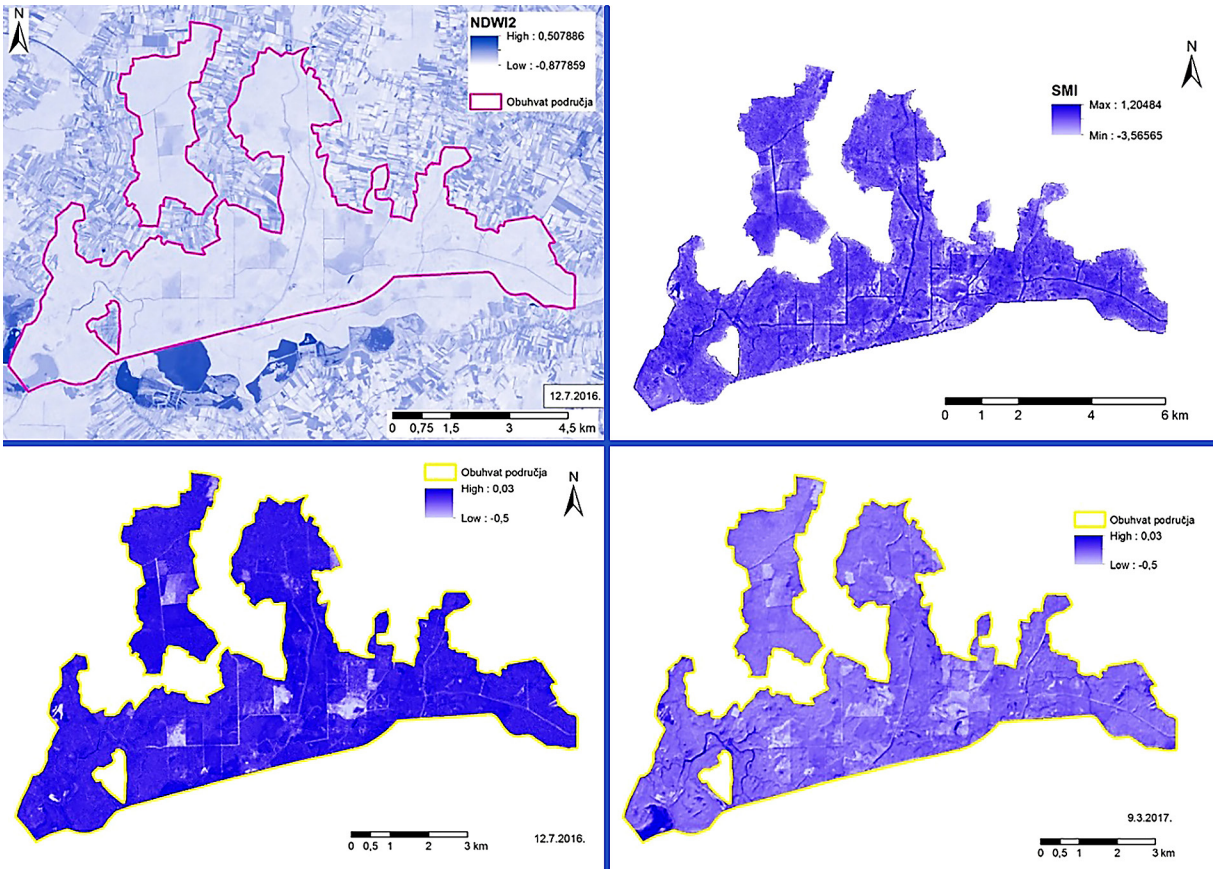
4.2. Vegetacijsko razdoblje

Tijekom vegetacijskog razdoblja ne dolazi do direktnog kontakta s površinom zemlje što otežava detekciju vodnih površina. Usporedbom izračuna NDWI1 i NDWI2 za istraživano područje, rezultati ovih indeksa nisu se pokazali prikladnim za određivanje vlažnosti šumske vegetacije. Vrijednosti NDWI1 su najmanje na lokacijama poznatih vodnih površina i mreži šumskih puteva te na površinama gdje je nedavno izvršena sječa stabala, a najintenzivnije vrijednosti su na starijim sastojinama što znači da najbolje reagira na veću količinu zeljaste vegetacije u krošnjama drveća. NDWI2 (Slika 3a) je detektirao dio vodnih površina, ali je i odsjeke s mladom vegetacijom neopravdano odredio kao vlažne. Može se zaključiti da NDWI1 i NDWI2 daju oprečne rezultate.

Provedenom modifikacijom Triangulacijske metode i Soil moisture indexa (SMI) prema Zeng i dr. (2004), gdje je umjesto NDVI-a korišten NDWI1 (Slika 3b). Iako se radi o ljetnom razdoblju kada je šumska vegetacija gusta rezultat ove metode modificirane metode pokazuje najveću vlažnost na područjima vodnih površina koja se nalaze unutar šume. Također je lako uočiti i ostatke mrtvica te depresije koje se nalaze unutar šume. Usporedbom s Hrvatskom osnovnom kartom mjerila 1:5000 koje su izrađene početkom 1980-ih godina vidljivo je poklapanje SMI-a s bivšim tokom rijeke Česme, pritocima te mrvicama i depresijama. Za testiranje metode Tasseled Cap Transformation Wetness (TCTW) korištene su tri snimke Sentinel-2 za dane 12.7.2021. i 30.9.2021. u vegetacijskom razdoblju te 9.3.2021 za razdoblje mirovanja vegetacije (Slika 3c, 3d). Analizom snimaka je utvrđeno da je rezultat povećan na području uz napravljene akumulacije u starom koritu Česme uz koje ujedno i ima najviše drvne mase.

5. Rasprava i zaključci

Mogućnosti detekcije vlažnosti na šumskom zemljištu pomoću multispektralnih snimaka tijekom izrade



Slika 3: (a) NDWI2 tijekom ljetnog dana na istraživanom području, (b) Modificirani Soil moisture indeks (SMI) za 12.7.2021, (c) Tasseled cap transformation wetness za 12.7.2021, (d) Tasseled cap transformation wetness za 9.3.2021.

ovog rada pokazala je da je potrebno ovom problemu potrebno pristupiti na dva načina i to ovisno o vegetacijskom razdoblju, tj. razdoblju mirovanja i razdoblju kada je vegetacija u punom rastu. Zasigurno najbolje rezultate pri detekciji vodnih, zamočvarenih i izrazito vlažnih površina tijekom mirovanja vegetacije pokazao je algoritam NDWI2 kojem prilikom detekcije ne smeta drvenasta vegetacija. Za isto razdoblje Tasseled cap transformation wetness pokazao se osjetljivim na drvenu masu gdje područja s gustim i starijim sklopom drveća neopravdano definira kao vlažnija, dok odsjeke gdje je izvršena potpuna sječa detektira kao izrazito suha područja. Dodatni nedostatak je to što ne prepoznaje dobro niti manje vodene površine, zbog čega je bolje dati prednosti NDWI2 algoritmu. U vegetacijskom razdoblju NDWI2 pokazuje da su najvlažnije veće vodene površine i odsjeci s mladom šumom, dok su susjedni odsjeci sa starijom šumom, iako topografski nema značajnih razlika – izrazito suhi, što dokazuje nedostatke ovog algoritma za određivanje vlažnosti. Ujedno je teško prepoznati depresije pod gustom šumskom vegetacijom. Tasseled cap transformation wetness u vegetacijskom razdoblju ne prepoznaje vlagu zemljišta nego detektira količinu šumske zeljaste vegetacije i veće vodene površine što više može poslužiti za detekciju mase drveća tili stres drveća uslijed nedostatka vode tijekom sušnijih godina. Zasigurno najbolji rezultat za vegetacijsko razdoblje je dobiven modifikacijom Soil moisture indeks algoritma, nedostatak ovog algoritma pokazao se u prikazu šumskih cesta koje su detektirane kao poprilično vlažne površine, zbog toga je potrebno prethodno biti upoznat sa šumskim prometnicama na promatranom području.

Treba napomenuti da su ove metode isprobane isključivo na nizinskoj šumi te je moguće da ove metode vjerojatno neće odgovarati šumama na višim nadmorskim visinama ili padinama. Dosadašnji radovi o detekcija vlažnosti tla korištenjem daljinskih istraživanja odnosila su se na veće površine ne uzimajući u obzir šumsku vegetaciju, što čini ovaj rad drugačijim od ostalih. Korištenjem nove satelitske platforme Sentinel-2 koji donosi bolju prostornu razlučivost mogu se identificirati prostorno detaljniji rezultati o vlazi zemljišta, ali se mogu i koristiti za izradu drugih vegetacijskih indeksa bez naknade za plaćanjem podataka s komercijalnih satelitskih platforma kako bi se kontinuirano mogao vršiti monitoring šuma. Metodama koje se navode u literaturi isto kao i ovdje dobiveni rezultati ne daju točnu vlagu tla nego daju relativnu sliku o vlažnosti šumskog tla pomoću kojih je moguće zaključiti koji su dijelovi prostora pod vodenim površinama, velikom vlagom, osrednje vlažni ili pak poprilično suhi zbog čega ovakav pristup treba koristiti s određenim oprezom, ali u kombinaciji s terenskim istraživanjem ili monitoringom mogu pokazati vodnost šumskog okoliša.

Literatura

Bačić, S. (2016): Odnos hidroloških čimbenika i odumiranja stabala poljskog jasena, diplomski rad, Šumarski fakultet Sveučilišta u Zagrebu, Zagreb.

Benko, M., Balenović, I. (2011): Prošlost, sadašnjost i budućnost primjene metoda daljinskih istraživanja pri inventuri šuma u Hrvatskoj, Šumarski list, 135(13), 272–281.

Carlson, T. (2007): An Overview of the "Triangle Method" for Estimating Surface Evapotranspiration and Soil Moisture from Satellite Imagery.

Chen, S., Wen, Z., Jiang, H., Zhao, Q., Zhang, X., Chen, Y. (2015): Temperature vegetation dryness index estimation of soil moisture under different tree species, Sustainability, 7.

Franklin, S. E. (2001): Remote Sensing for Sustainable Forest Management, CRC Press, Boca Raton.

Gao, B. C. (1996): NDWI – A normalized difference water index for remote sensing of vegetation liquid water from space, Remote sensing of environment, 58(3), 257–266.

Krajter Ostoić, S., Vuletić, D. (2016): Uloga informiranosti u poznavanju problematike općekorisnih funkcija šuma, Šumarski list, 140(5–6), 215–227.

McFeeters, S. K. (1996): The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features, International journal of remote sensing, 17(7), 1425–1432.

Olson, C. E. Jr., Rohde, W. G. (1970): Multispectral Sensing of Moisture Stress, NASA Sensor Studies.

Pilaš, I., Planinšek, Š. (2011): Obnova vodnog režima nizinskih šuma kao potpora potrajnom gospodarenju, Šumarski list, 135(13), 138–147.

Prpić, B. (2003): Utjecaj tehničkih zahvata u prostoru na nizinske šume, Šumarski list, 5–6.

Srivastava, P., Petropoulos, V., Kerr, Y. H. (2016): Satellite Soil Moisture Retrieval, Elsevier, Amsterdam.

Wang, L., Qu, J. J. (2009): Satellite remote sensing applications for surface soil moisture monitoring: A review, Frontiers of Earth Science in China, 3(2), 237–247.

Weber, F. P, Polcyn, F. C. (1972): Remote sensing to detect stress in forests, Photogrammetric Engineering, 38(2), 163–175.

Wilson, E. H., Sader, S. A. (2002): Detection of forest harvest type using multiple dates of Landsat TM imagery, Remote Sensing of Environment, 80, 385–396.

Zeng, Y., Feng, Z., Xiang, N. (2004): Assessment of soil moisture using Landsat ETM+ temperature/vegetation index in semiarid environment, In IGARSS 2004, IEEE International Geoscience and Remote Sensing Symposium 2004, Vol. 6, 4306–4309.

Zhang, D., Tang, R., Zhao, W., Tang, B., Wu, H., Shao, K., Li, Z.-L. (2014): Surface Soil Water Content Estimation from Thermal Remote Sensing based on the Temporal Variation of Land Surface Temperature, Remote Sensing, 6, 3170–3187.

Zubair Younis, S. M., Iqbal, J. (2015): Estimation of soil moisture using multispectral and FTIR techniques, The Egyptian Journal of Remote Sensing and Space Science, 18(2).

URL 1: GMES Sentinel-2 mission requirements document, http://esamultimedia.esa.int/docs/GMES/Sentinel-2_MRD.pdf, (23.6.2022.).

URL 2: Landsat 8, https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview/, (23.6.2022.).

URL 3: A database for remote sensing indices,

http://www.indexdatabase.de/db/i-single.php?id=93, (8.7.2022.).

Determination of Forest Cover Humidity and Impact on Forest Fires

Abstract

Possibilities of monitoring moisture and water surfaces on the example of lowland forest along the right bank of the river Česma, which are part of the economic unit Česma, were investigated. Data from the new Sentinel-2 and Landsat 8 satellite missions were used, which provide the best spatial resolution of free multispectral images so far. Vegetation indices and a combination of water index of normalized difference and thermal data were used to obtain differences in humidity. Normalized difference water index (NDWI1 and NDWI2), Tasseled Cap Transformation Wetness (TCTW) and a combination of modified Soil moisture index, which uses the normalized difference water index instead of the normalized difference vegetation index in combination with the Landsat 8 thermal channel, were used to calculate humidity. In the period without herbaceous vegetation, NDWI2 proved to be the best for the detection of water surfaces and wetlands, while for the vegetation period the modified soil moisture index showed the best results, clearly distinguishing between wetter and drier parts of the forest. Although the highest value for humidity did not prove to be appropriate, the presented method would have been used earlier in defining forest biomass.

Keywords: *fires, forest soil moisture, remote sensing, sentinel-2, water bodies*

Testiranje programskih rješenja za obradu podataka snimljenih dronom pri inspekcijskom snimanju

Marija Perić[1], Željko Bačić[2], Zvonimir Nevistić[3]

[1] GDi d.o.o., Baštijanova 52a, Zagreb, Hrvatska, marija.peric@gdi.net

[2] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, zbacic@geof.hr

[3] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, znevistic@geof.hr

Sažetak

Bespilotna letjelica (Unmanned aerial vehicle – UAV) ili dron vrsta je letjelice koja samostalno izvodi operaciju leta, a moguć je autonomni ili daljinski upravljani let. Opremljeni različitim senzorima dronovi raspolažu sposobnošću brzog prikupljanja velike količine prostornih podataka u kratkom vremenu. Stoga dronovi danas imaju široku komercijalnu primjenu te su nadišli svoju prvotnu vojnu namjenu. U geodeziji dronovi se standardno koriste za izradu ortofoto prikaza, digitalnih modela terena (Digital Elevation Model - DEM), 3D modela, oblaka točaka i drugih prikaza na kojima je moguće izvoditi različite prostorne analize. Iako je široko primjenjiva u geodeziji, tehnologija dronova se susreće s tehničkim i pravnim ograničenjima. Pravna ograničenja povezana su s propisima kojih se potrebno pridržavati pri letenju, a tehnička se odnose na samo korištenje i obradu prikupljenih podataka, odnosno tehnološke pretpostavke za uspješnu provedbu obrade. U ovome radu ispitani su tehnološki aspekti obrade, odnosno tri različita softvera za obradu snimki drona i izradu 2D i 3D prikaza šume i pruge. Analiza softvera provedena je na temelju dobivenih prikaza i usporedbom dobivenih rezultata. Provedena je diskusija o dobivenim rezultatima te je donesen zaključak o optimalnom softveru.

Ključne riječi: *Agisoft Metashape Pro, analiza softvera, Drone2Map, Site Scan*

1. Uvod

Paralelno s napretkom i stvaranjem novih tehnologija, razvile su se nove metode mjerenja koje omogućuju brzo i jednostavno prikupljanje prostornih podataka u odnosu na klasične geodetske metode. Jedna od tih tehnologija su dronovi, koji se danas koriste u različitim djelatnostima. Razlog njihove primjene je mogućnost dobivanja georeferenciranih podataka o stanju Zemljine površine, objekata i pojava na njoj u kratkom vremenskom roku te široki spektar proizvoda koje je moguće dobiti obradom snimki (Perić, 2022).

Efikasnost upotrebe dronova u geodeziji, ali i ostalim djelatnostima određena je sposobnošću savladavanja same tehnologije dronova i pravnog okvira koji uređuje korištenje istih (Bačić i Nevistić, 2021). Tehnologija dronova podrazumijeva poznavanje načina rada drona, upravljanje dronom, planiranje operacija (leta) te rad u softverima za obradu prikupljenih podataka. Iako je digitalna revolucija omogućila pojednostavljenje i automatizaciju obrade, kao i samo dobivanje kraj-njih proizvoda, u geodeziji problem i dalje predstavlja obrada podataka. Kod obrade podataka prikupljenih dronom postoje dva ograničenja, a to su hardverski i softverski uvjeti. Hardverski uvjeti ponajprije ovi-se o broju snimku koje softver može obraditi odnosno veličini projekta, vrijednosti prostorne veličine slikovnog elemenata na terenu (GSD) i kvaliteti krajnjih prikaza. Memorija računala s nasumičnim pristupom (RAM) je ograničavajući čimbenik hardvera koji procjenjuje mogućnost obrade u odnosnu na procesorsku snagu korištenog računala. Softverski uvjeti odnose se na specijaliziran softver i znanje rada u istom. Primarna svrha fotogrametrijskih softvera je izdvajanje geometrijskih informacija iz 2D snimki za renderiranje u 3D prikaz, a danas su na tržištu dostupni različiti komercijalni softveri, ali i oni otvorenog koda (Perić, 2022). Proizvođači fotogrametrijskih softvera ne objavljuju javno pojedinosti, algoritme i principe rada svojih softvera. Odabir softvera kompleksan je zadatak koji ponajprije ovisi o dostupnim hardverskim uvjetima, poznavanju rada, vrsti projekta i budžetu. Potaknuti time u ovome radu provedena je analiza 3 različita fotogrametrijska softvera na temelju obrade istih podataka (snimki) i ocjena kvalitete obrade.

2. Instrumentarij i provedena testiranja

Kako bi se ispitale različite mogućnosti dostupnih softvera za obradu, provedeno je testiranje na području grada Zagreba, točnije na području silosa Resnik na kojem se nalaze željeznička pruga i šuma s visinskom razlikom. Površina obuhvata šume iznosi 7

Tablica 1: Parametri leta

Naziv leta	Tip snimanja	Datum snimanja	Visina leta (m)	Preklop (%)	Nagib kardanskog prstena (gimbal), (°)
Pruga 1	Corridor	31.4.2021.	55	80, 70	0
Pruga 2	Corridor	31.4.2021.	55	80, 70	30
Šuma area	Area	31.4.2021.	70	80, 70	0
Šuma CH	Crosshatch	31.4.2021.	60	70, 60	0
Šuma dio 1	Crosshatch	31.4.2021.	60	80, 70	0
Šuma dio 2	Crosshatch	31.4.2021.	60	85, 75	0
Šuma 2.6	Crosshatch	2.6.2021.	60	85, 80	35

ha, a duljina pruge je 751 m. Snimanjem je obuhvaćena katastarska čestica 3350/3 i njoj susjed-ne u katastarskoj općini Resnik. Snimanje testnog područja provedeno je u 2 termina: 31. travnja 2021. godine i 2. lipnja 2021. godine.

Za aerofotogrametrijo snimanje korišten je multi rotorski dron DJI Phantom 4 Pro V2.0 (kvadkopter) s multispektralnom kamerom (URL 1). Za planiranje leta korištena je Site Scan Flight Planing aplikacija izrađena od tvrtke ESRI koja je dostupna samo na iOS tablet uređajima. U prvome snimanju provedeno je 8 letova (snimanje šume i pruge), a u drugom terminu 1 let (snimanje šume). Za snimanje pruge odabran je corridor način rada unutar kojeg je linijski objekt snimljen dvostrukim preletom, a za snimanje šume area i crosshatch način rada koji se razlikuju u broju preleta i prikupljenih snimaka nad istim područjem. Snimanje u area načinu rada omogućuje izradu 2D modela dok crosshatch način rada omogućuje dobivanje 3D modela dvostrukim preletom preko zadanog područja. Podešeni parametri pojedinih načina snimanja s definiranim preklopom, visinom leta i nagibom senzora (kamere) dani su u Tablici 1.

Prije početka leta bilo je potrebno obaviti rekognosciranje terena i postaviti zemaljske kontrolne točke (Ground Control Points - GCP) koje se koriste za georeferenciranje snimaka kako bi se omogućilo povezivanje dobivenih prostornih informacija s referentnim koordinatnim sustavom i računanje stvarnih visinskih razlika i volumena. Obvezna je prijava aktivnosti leta na AMC portalu, nadležnoj jedinci za upravljanje zračnim prostorom. Postavljeno je 6 GCP točaka na području šume i pruge kako bi se obuhvatilo cjelokupno područje snimanja. Za signalizaciju GCP točaka korištene su signalizacijske ploče uzorka šahovnice kako bi se spriječilo stvaranje odsjaja na snimkama. Također, navedeni način prikaza GCP točaka većina softvera automatski prepoznaje čime se sprečava manualno traženje točaka na prikupljenim snimkama.

Za određivanje koordinata GCP točaka primijenjena je GNSS RTK (engl. Global Navigation Satellite System Real-Time Kinematic) metoda, a korišteni uređaj je Trimble R8 pomoću kojeg je uspostavljena veza na hrvatski pozicijski sustav (CROPOS). Od 3 vrste usluga koje CROPOS nudi, za ovaj rad korišten je visoko precizni servis pozicioniranja u realnom vremenu (VPPS). Svaka je GCP točka izmjerena u 20 epoha s ratom registracije (pohrane podataka u GNSS uređaju) od 1 s, čime je osigurana visoka centimetarska točnost dobivenih 3D koordinata. Koordinate GCP točaka određene su u službenom projekcijskom koordinatnom referentnom sustavu Republike Hrvatske (HTRS96/TM) čime će i dobiveni modeli iz prikupljenih snimaka također biti povezani s istim sustavom (Perić, 2022).

3. Korišteni softveri i obrada mjerenja

Obrada podataka odnosno snimki prikupljenih mjerenjem provedena je u 3 različita programska paketa: Site Scan Manager (verzija 4.142.0), Drone2Map (verzija 2.3.2.) i Agisoft Metashape Pro (verzija 1.7). Provedene su 3 različite obrade koje su se sastojale od snimki različitih misija. Prva obrada sastojala se od 291 snimki pruge (2 corridor leta), a druga obrada od 1088 snimki šume iz 4 različita leta (1 area i 3 crosshatch leta). Trećom obradom cilj je bio dobiti prikaz šume iz snimki 1 leta (crosshatch, 1921 snimaka). Obradom snimki u svim softverima dobiveni su ortofoto prikazi, digitalni visinski modeli, oblaci točaka i 3D mode-li (Perić, 2022).

3.1. Site Scan Manager

Site Scan Manager je web cloud softver tvrtke ESRI za obradu snimki dobivenih dronom. Osim obrade snimki u softveru se može izvršiti planiranje leta, spajati letove i pratiti zdravlje (stanje) baterija unutar projekta (Fleet Management opcija). Site Scan Manager ne zahtijeva hardverske uvjete, a za rad je potrebna samo internetska veza. Obrada snimki je jednostavna, a prvi korak je učitavanje snimki i GCP točaka. Zatim slijedi označavanje GCP točaka na 5 do 8 snimki za svaku točku kako bi se postigli optimalni rezultati. Drugi korak je postavljanje osnovnih parametara obrade, a treći ujedno i posljednji je procesuiranje koje se odvija u oblaku. Za potrebe izrade ovog rada postavljeni su parametri visoke kvalitete, a u Tablici 2 dani su osnovni podaci o vremenu potrebnom za obradu te dobivenoj točnosti modela (Ground Sample Point - GSD), (Perić, 2022).

Tablica 2: Osnovni parametri proveden obrade u Site Scan Manageru

Naziv obrade	GSD (cm/px)	Vrijeme trajanja obrade (min)
Pruga	1.53	80
Prva obrada šume	1.61	321
Druga obrada šume	2.27	430

Tablica 3: Osnovni parametri proveden obrade u Drone2Map-u

Naziv obrade	GSD (cm/px)	Vrijeme trajanja obrade (min)
Pruga	1.54	156
Prva obrada šume	1.61	483
Druga obrada šume	2.30	927

Tablica 4: Osnovni parametri proveden obrade u Agisoft Metashape Pro-u

Naziv obrade	GSD (cm/px)	Vrijeme trajanja obrade (min)
Pruga	1.58	1186
Prva obrada šume	1.65	850
Druga obrada šume	1.99	2182

3.2. Drone2Map

Drone2Map je računalna aplikacija koja je trenutno dostupna samo na operacijskim sustavima Windows. Patentiran od strane tvrtke ESRI, Drone2Map namijenjen je za korisnike ArcGIS platforme zbog sličnosti sučelja i samog načina rada. Ovisno o veličini projekta Drone2Map zahtijeva sljedeće hardverske uvjete: RAM i slobodnu memoriju, a osim toga preporučuje se i korištenje integrirane grafičke kartice. Aplikacija funkcionira ne temelju predložaka koje korisnik odabire ovisno o željenim prikazima, odgovarajućoj rezoluciji i vrsti projekta. Nakon odabranog predloška, potrebno je učitati snimke i koordinate GCP točaka te označiti iste na snimkama. Unutar svakog predloška postavljeni su parametri obrade koje je moguće izmijeniti i tako kreirati nove predloške. Obrada se sastoji od 3 dijela: *initial* (izdvajanje veznih točaka i poudaranja snimki te postavljanje parametara kamere), *dense* (kreiranje 3D Mesha i oblaka točaka) i kreiranja ortofoto prikaza i DEM-a. Ukoliko se odabere predložak za izradu 2D prikaza, softver će svejedno procesuirati *dense* dio obrade (Perić, 2022). Za izradu ovog rada korišten je predložak 3D Mapping, a podaci o obradi dani su u Tablici 3.

3.3. Agisoft Metashape Pro

Agisoft Metashape Pro jedan je od najpoznatijih komercijalnih fotogrametrijskih softvera koji omogućuje procesuiranje digitalnih snima-ka (zračne, terestričke i fotogrametrijske) iz RGB, multispektralnih i termalnih kamera u 2D i 3D prikaze. Softver se bazirana na Python programskom jeziku, a moguće je i korištenje programske konzole. Obrada ovisi o hardverskim uvjetima, ali i o broju i rezoluciji snimki kao i o odabranim parametrima tijekom obrade. Ograničavajući hardverski čimbenici su RAM, slobodna memorija, a preporučuje se korištenje izdvojene grafičke kartice. Unutar Agisoft-a moguće su dvije obrade: automatizirana (potrebno je na početku postaviti sve parametre) i obrada u koracima (10 koraka gdje je potrebno postaviti parametre pri svakom). Zbog različitih mogućnosti intervencije tijekom obra-de u Agiosft-u je moguće dobiti zadovoljavajuće rezultate iz lošijih početnih podataka (Perić, 2022). Parametri o provedenoj obradi dani su u Tablici 4.

4. Analiza rezultata

Na temelju rezultata dobivenih obradom snimki u tri neovisna softverska rješenja, provedena je analiza kvalitete 2D i 3D prikaza kao i analiza kvalitete postignute točnosti zemaljskih kontrolnih točaka na georeferenciranim snimkama zasebno za snimanje pruge i šume (Zrinjski i dr., 2021).

4.1. Obrada pruge

Promatrajući srednju pogrešku georeferenciranja kontrolnih točaka u svim smjerovima (RMS), najmanja vrijednost dobivena je u Site Scan-u za obradu pruge i ona iznosi 0 m. U Drone2Map-u ukupan RMS iz-nosi 1.21 m što je puno veće od dobivene vrijednosti GSD-a (1.54 cm/px). U Agisoft-u ukupan RMS iznosi 2.616 cm što ukazuje da je Agisoft dao nešto lošije

Tablica 5: Pogreške položaja kontrolnih točaka i pogreške projekcije za obradu pruge

	SITE SCAN			
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	0.000070	0.000011	-0.000213	0.565
SIGMA	0.001311	0.000642	0.000389	1.694
RMS	0.001313	0.000642	0.000443	0.323
	DRONE2MAP			
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	0.652	0.522	-0.628	0.534
SIGMA	1.166	0.913	1.554	2.135
RMS	1.336	1.051	1.676	0.288
	AGISOFT METASHAPE PRO			
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	0.064	0.608	0.044	1.243
SIGMA	0.006	0.010	-0.023	3.929
RMS	0.025	0.006	0.002	1.520

rezultate georeferenciranja u odnosu na Site Scan, dok je Drone2Map dao najlošije. Pogreška projekcije odnosno odstupanje mjerene vrijednosti slikovnih koordinata GCP od projicirane vrijednosti temeljem parametara unutarnje i vanjske orijentacije kamere dobivenih kalibracijom u Site Scan-u iznosi 0.222 px, u Dro-ne2Map-u 0.174 px i u Agisoft-u 1.29 px. Pogreške položaja kontrolnih točaka odnosno razlika izračunatih koordinata prilikom izrade 2D i 3D prikaza i koordinata izmjerenih na terenu dana je u Tablici 5. Pre-ma RMS vrijednosti najmanja ostvarena pogreška položaja kontrolnih točaka ostvarena je u Site Scan-u, a najveća u Drone2Map-u i to u svim smjerovima. Također je dana i pogreška projekcije u pikselima odnosno udaljenost između mjesta na kojima su GCP točke označene na snimkama i mjesta na kojima su one ponovno projicirane. Dobiveni ortofoto prikazi u sva tri softvera nalaze se na Slici 1.

4.2. Prva obrada šume

Kod prve obrade šume koje se sastojala od snimki različitih misija s različitim postavkama leta ukupan RMS u Site Scan-u u svim smjerovima iznosi 1.199



Slika 1: Dobiveni ortofoto prikazi snimanja pruge u SitScan-u (lijevo), Drone2Map-u (sredina) i Agisoftu (desno)

Tablica 6: Pogreške položaja kontrolnih točaka i pogreške projekcije za prvu obradu šume

	SITE SCAN			
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	0.472	0.372	0.765	0.493
SIGMA	1.056	0.832	1.711	2.955
RMS	1.157	0.911	1.874	0.266
DRONE2MAP				
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	0.459	0.365	0.781	0.388
SIGMA	1.026	0.815	1.727	2.328
RMS	1.124	0.892	1.896	0.157
AGISOFT METASHAPE PRO				
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N(m)	H (m)	(piksel)
MEAN	0.003	0.003	0.033	0.184
SIGMA	0.331	0.317	0.196	1.102
RMS	0.084	0.075	0.044	0.121

m, u Drone2Map-u 1.189 m, a u Agisoft-u 0.121 m. Uspoređujući RMS s GSD-om, u sva tri softvera ukupna pogreška GCP točaka je puno veća od dobivenog GSD-a što je uzrok korištenja snimki različitih letova. Ukupna pogreška projekcije u Site Scan-u je 0.178 px, u Drone2Map-u 0.185 px, a u Agisoft-u 1.55 px. Prema RMS vrijednostima iz Tablice 6, najmanji RMS dobivena je u Agisoft-u, dok je u Drone2Map-u i Site Scan-u sličnih vrijednosti. RMS pogreške projekcije najmanji je u Agisoft-u, a najveći u Site Scan-u. Dobiveni ortofoto prikazi prve obrade šume u SitScan-u i Drone2Map-u nalaze se na Slici 2.

4.3. Druga obrada šume

Kod druge obrade šume koja se sastojala od jednog leta, ukupni RMS iznosi 0.16 m u Site Scanu, u Drone-2Map-u 0.142 m, a u Agisoft-u 0.034 m. Uspoređujući te vrijednosti s GSD-om jedino dobiveni RMS u Agisoft-u nije 2 do 3 puta veći od dobivenog GSD-a (Tablica 7). Promatrajući RMS vrijednosti najmanji ostvaren je u Agisoft-u i to za sve smjerove, dok je najveća vrijednost postignuta u Site Scan-u. Po-greška projekcije u Site Scanu iznosi 0.179 px, u Drone2Map- 0.183 px, a u Agisoft-u 0.925 px. Najmanji RMS pogreške projekcije dobi-ven je u Drone2Map-u. Dobiveni ortofoto prikazi nalaze sa na Slici 3.



Slika 2: Dobiveni ortofoto prikazi prve obrade šume u SitScan-u (lijevo) i Drone2Map-u (desno)

Tablica 7: Pogreške položaja kontrolnih točaka i pogreške projekcije za drugu obradu šume

	SITE SCAN			
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	0.004	0.0003	0.0003	0.423
SIGMA	0.121	0.239	0.122	2.535
RMS	0.121	0.239	0.122	0.236
	DRONE2MAP			
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	-0.001	-0.003	-0.005	0.087
SIGMA	0.113	0.219	0.097	0.519
RMS	0.114	0.219	0.097	0.009
	AGISOFT METASHAPE PRO			
	POGREŠKA POLOŽAJA KONTROLNIH TOČAKA			POGREŠKA PROJEKCIJE
	E (m)	N (m)	H (m)	(piksel)
MEAN	0.001	0.023	0.007	0.048
SIGMA	0.001	0.135	0.045	0.290
RMS	0.014	0.030	0.008	0.303

5. Zaključak

U ovome radu dan je kratki pregled tri različita fotogrametrijska softvera: Agisoft Metashpe Pro, Drone2Map i Site Scan koji se međusobno razlikuju po načinu rada, tijeku obrade te dodatnim alatima i funkcijama. Provedeno je ukupno 9 obrada u sva tri softvera i na temelju dobivenih prikaza i izvješća o obradi provedena je analiza kvalitete obrade.

Obrada se sastojala od dobivanja prikaza pruge (iz 2 snimanja s različitim postavkama), prvog prikaza šume (iz više snimanja s različitim postavkama) i drugog prikaza šume (jedno snimanje). Svi softveri su uspješno obradili podatke, ali zbog ograničenja hardverskih uvjeta obrada u Drone2Map-u i Agisoft-u zahtijevala je postavljanje minimalnih parametara. Korištene su GCP točke u svrhu georeferenicranja kako bi se ostvarila apsolutna točnost. U Agiosoft-u je postignuta centimetarska točnost za sve obrade, dok je u Site Scan-u ostvarena samo za drugu obradu šume i pruge. U Drone2Map-u ostvarena je točnost unutar 1 m za prvu obradu šume i pruge, dok je za drugu obradu šume ostvarena centimetarska točnost. Dobivenim rezultatima prikazano je kako korištenje snimki različitih misija otežava obradu te će se



Slika 3: Dobiveni ortofoto prikazi druge obrade šume u SitScan-u (lijevo) i Agisoftu-u (desno)

dobiti manja točnost u odnosu na korištenje snimki jedne misije. Pretpostavka je i da bi se uz bolje performanse računala i korištenja većeg broja GCP točaka dobili bolji rezultati.

Do danas su provedena mnoga istraživanja o usporedbama fotogrametrijskih softvera koja pokušavaju ocijeniti najbolji softver, međutim taj postupak je subjektivan za svakog korisnika. Svaki softver ima svoje prednosti i nedostatke, a izbor ponajprije ovisi o znanju i iskustvu, željenim proizvodima, budžetu i računalnim uvjetima. Ovaj rad može poslužiti kao smjernica za odabir najboljeg softvera za obradu između softvera kompanije ESRI i Agisoft-a u kojima su provedene analize.

Literatura

Bačić Ž., Nevisitć Z. (2021.): Primjena bespilotnih letjelica u geo-detsko-geoinformatičkoj struci u Hrvatskoj, 14. simpozij ovlašte-nih inženjera geodezije, 103-109.

Perić, M. (2022.).: Ispitivanje ESRI Site Scan i Drone Collection softvera za linijska i površinska snimanja flotom dronova, diplomski rad, Zagreb.

Zrinjski M., Matika, K., Barković, Đ., Kaštelan, I. (2021.): Geodetska izmjera objekata kulturne baš-tine bespilotnom letjelicom, Ekscentar, 84-95.

URL 1: Specifikacije DJI Phantom 4 Pro V2.0, https://www.dji.com/hr/phantom-4-pro-v2/specs, (27.02.2022.)

Testing Software Solutions for Processing Drone Data During Inspection Recording

Abstract

An unmanned aerial vehicle (UAV) or drone is a type of aircraft that independently performs a flight operation, and autonomous or remotely controlled flight is possible. Equipped with various sensors, drones can quickly collect a large amount of spatial data in a short time. Therefore, drones today have a wide commercial application and have surpassed their original military purpose. In geodesy, drones are standardly used to create orthophoto images, digital elevation models (DEM), 3D models, point clouds and other outputs on which it is possible to perform various spatial analyses. Although widely applicable in geodesy, drone technology faces technical and legal limitations. Legal restrictions are related to the regulations that must be followed when flying, and technical restrictions relate to the use and processing of the collected data, that is, the technological prerequisites for the successful implementation of the processing. In this paper, the technological aspects of processing drone images and creating 2D and 3D maps of the forest and the railroad, with three different software, were examined. The analysis of the software was carried out based on the obtained maps and by comparing the obtained results from which conclusion was reached on the optimal software.

Keywords: *Agisoft Metashape Pro, software analysis, Drone2Map, Site Scan*

Integracija BIM-a i GIS-a

Vlado Cetl[1], Danko Markovinović[2], Sanja Šamanović[3], Milan Rezo[4]

[1]Sveučilište Sjever, Jurja Križanića 31b, Varaždin, vlado.cetl@unin.hr

[2]Sveučilište Sjever, Jurja Križanića 31b, Varaždin, danko.markovinovic@unin.hr

[3]Sveučilište Sjever, Jurja Križanića 31b, Varaždin, sanja.samanovic@unin.hr

[4]Sveučilište Sjever, Jurja Križanića 31b, Varaždin, milan.rezo@unin.hr

Sažetak

Građevinska i geoprostorna industrija u javnom i privatnom sektoru zahtijeva nove pristupe za postupke projektiranja, urbanističkog planiranja, upravljanja imovinom i dr., a sve u svrhu smanjenja troškova te održivog utjecaja na okoliš. Iz tog razloga potrebno je integrirano upravljanje informacijama temeljeno na standardima i jasnim smjernicama. Jedan od osnovnih pristupa k tome je razvoj i integracija BIM (Building Information Modeling - modeliranje informacija o građevini) i GIS tehnologija. Povezivanjem građevinskog i geoprostornog upravljanja informacijama moguće je poboljšanje procesa izgradnje, upravljanja imovinom, uključujući zgrade, ceste i druge važne objekte. Integracija također pomaže u stvaranju održive i fleksibilne prometne infrastrukture kao i potporu infrastrukturnim ulaganjima sa smanjenim negativnim društvenim i ekonomskim utjecajem te utjecajem na okoliš. Međutim, integracija podataka ovih sektora zahtjeva visoku razinu stručnosti obje domene. S ciljem jačanja kapaciteta u integraciji BIM-a i GIS-a pokrenut je Erasmus+ projekt BIRGIT (training on Building InfoRmation models integrated with Geographical InformaTion) Sveučilišta Sjever i ostalih partnera. Projekt ima za cilj povezati područja BIM-a i GIS-a u svrhu osposobljavanja budućih stručnjaka s potrebnim znanjima i vještinama kroz izradu novih nastavnih sadržaja u okviru preddiplomskih i diplomskih studija, te programima cjeloživotnog obrazovanja. BIRGIT projekt će trajati 3 godine u razdoblju od 01. 02. 2022. do 31. 01. 2025.god. U ovom radu su predstavljeni dosadašnji rezultati rada na projektu kao i planovi buduće implementacije.

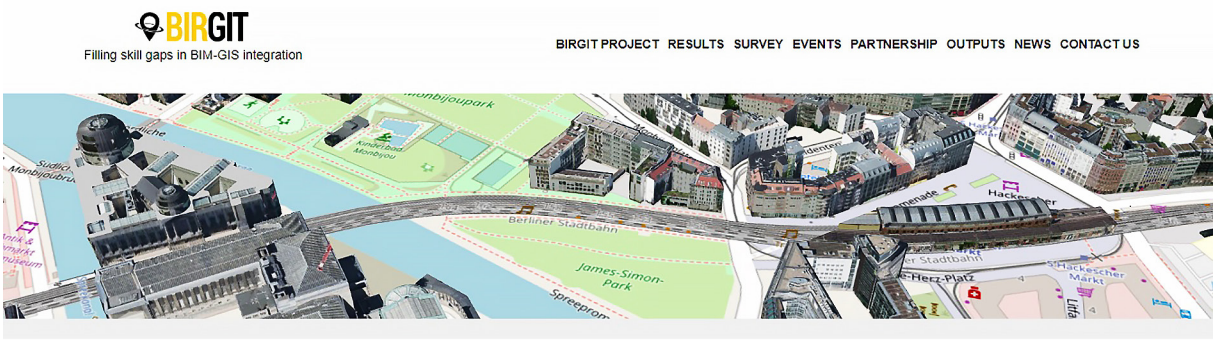
Ključne riječi: *BIM, BIRGIT projekt, GIS, integracija.*

1. Uvod

BIM (Building Information Modeling) i GIS (Geoinformation systems) dvije su discipline specifične namjene i upotrebe. GIS ima značajke kartiranja i prostorne baze podataka, dok se BIM posebno koristi kao informacijski model baziran na objektima. Poveznica između ove dvije tehnologije dobiva na vjerodostojnosti u složenim i velikim projektima. Arhitektonski i građevinski projekti obično koriste BIM tehnologije, dok se geodetsko-geoinformatički projekti izvode pomoću GIS sustava (URL 1). Informacije dobivene iz građevnih informacijskih modela kao i pridruženih geoprostornih podataka i GIS analize mogu povećati uspješnost procesa izgradnje i upravljanje imovinom, uključujući zgrade, ceste i druge objekte (Hijazi i dr., 2018).

Uspješno upravljanje održivim projektima zahtijevaju integraciju GIS-a i BIM-a, pružajući holistički pogled na projekte koji mogu biti učinkovito dijeljeni i upravljani i kojima pristupaju različiti dionici. Integrirana GIS i BIM rješenja mogu neprekidno međusobno povezati podatke gradilišta, radnika i opreme, stvarajući tako slobodan protok informacija kroz čitavi životni ciklus projekta. Ova integracija također može iskoristiti prednosti podataka za dobivanje boljeg uvida u prirodne uvjete koji utječu na mjesto građenja, kao što je na primjer razumijevanje kako osjetljivost područja na poplave može utjecati na odluke o lokaciji, orijentaciji i građevinskom materijalu potrebnom za određeni infrastrukturni projekt (URL 2).

Učinkovita i uspješna integracija BIM-a i GIS-a zahtijeva duboko poznavanje barem jedne od te dvije discipline, kao i znanje o tome kako surađivati s drugom disciplinom. Preliminarna istraživanja dionika u Švedskoj, Italiji, Španjolskoj i Hrvatskoj, ukazala su na nedostatak kvalificiranog osoblja kao i strukovnih tečajeva/radionica koji se bave kompetencijama potrebnim za postizanje integracije BIM-a i GIS-a. Postojeći VET (Vocational education and training) programi diljem Europe za građevinske inženjere, arhitekte, geodete, geografe i druge stručnjake koji rade na gradilištima i upravljanju urbanim područjima, obično uključuju tečajeve BIM-a ili GIS-a, ali ne i njihovu integraciju. Čini se kako stručnjaci u području BIM-a i stručnjaci u području GIS-a još uvijek žive različite svjetove, koriste različite tehnologije, standarde i sintaksu (Van Berlo i De Laat, 2011). Kao posljedica toga, stručnjaci navedenih domena rijetko znaju kako učinkovito riješiti probleme gdje su potrebne tehničke vještine i jedinstven pristup BIM-u i GIS-u. S ciljem jačanja kapaciteta u integraciji BIM-a i GIS-a pokrenut je Erasmus+ projekt BIRGIT (training on Building InfoRmation models integrated with Geographical InformaTion) koji je detaljno opisan u idu-



Slika 1: Web stranica BIRGIT projekta (URL 3)

ćem poglavlju, uz prikaz dosadašnjih rezultata rada na projektu kao i planova za buduću implementaciju.

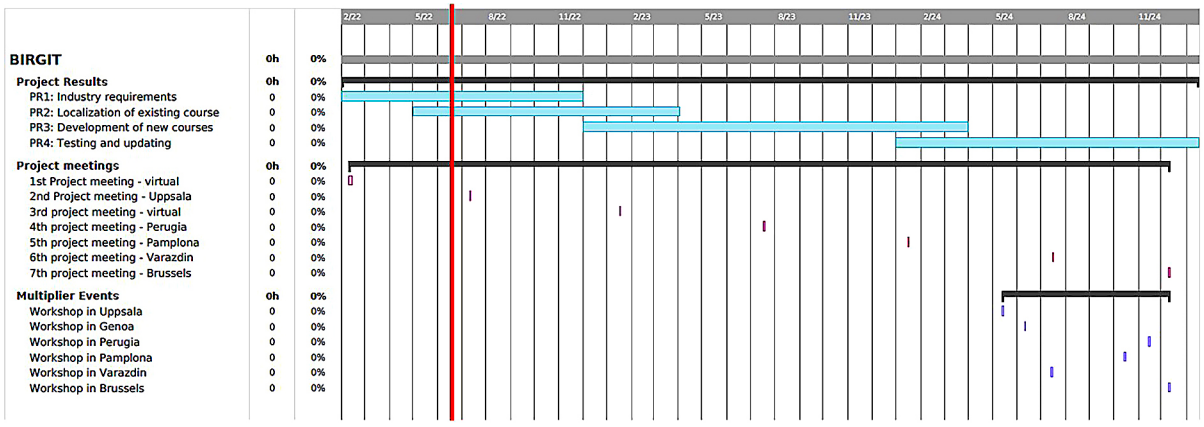
2. BIRGIT projekt

2.1. Općenito o projektu

Erasmus+ BIRGIT projekt (URL 3) ima za cilj povezati područja BIM-a i GIS-a u svrhu osposobljavanja budućih stručnjaka s potrebnim znanjima i vještinama kroz izradu novih nastavnih sadržaja u okviru preddiplomskih i diplomskih studija, te programima cjeloživotnog obrazovanja (Slika 1).

BIRGIT projekt će se izvoditi tri godine u razdoblju od 01. 02. 2022. do 31. 01. 2025.god. Partneri na projektu uz Sveučilište Sjever su sljedeći: Ocellus Information Systems AB i Novogit AB iz Švedske, GISIG – Geographical Information Systems International Group i FORMA.Azione iz Italije, Asociación de la Industria Navarra iz Španjolske te European Forum of Technical and Vocational Education and Training iz Belgije. Više detalja o projektnim partnerima može se pronaći na web stranici BIRGIT projekta (URL 3).

Rad na projektu podijeljen je u četiri glavne aktivnosti i s njima povezane zadaće. Kako bi se stvorile tražene vještine, nastavni materijali trebaju zadovoljiti potrebe različitih ciljnih skupina. Te potrebe će se pažljivo proučiti tijekom prve faze projekta koja ima za cilj istražiti zahtjeve tržišta u svakoj od partnerskih zemalja kako bi se odredili željeni ciljevi učenja. Pritom će se koristiti analiza postojećih materijala, upitnici i intervjui sa stručnjacima kako bi se definirale specifikacije nastavnih sadržaja koji će se razvijati. Još jedna ključna aktivnost koju treba provesti je prilagodba postojećih BIM/GIS materijala za obuku na različite jezike i za nacionalne potrebe. Za to su predviđene prevoditeljske aktivnosti te harmonizacija skupova podataka koji će se koristiti u kontekstu praktičnih vježbi. Temeljna aktivnost projekta bit će razvoj novih tečajeva za specifične vještine i kompetencije koje zahtijeva industrija. Te će tečajeve koristiti pružatelji osposobljavanja za poboljšanje kvalitete svojih strukovnih programa. Razvijat će se materijali koji ispunjavaju tražene ciljeve učenja utvrđene u prvoj projektnoj aktivnosti. Proces izrade materijala temeljit će se na SCRUM metodologiji (URL 4), koja je dobro poznata metodologija u kolaborativnom softverskom inženjerstvu. Posljednja aktivnost projekta temeljit će se na procjeni i testiranju razvijenih tečajeva i povezanih ishoda učenja u kontekstu stvarnih aktivnosti obuke koje provode različiti dionici. Ova aktivnost će osigurati daljnji razvoj, ažuriranje i poboljšanje nastavnih materijala na temelju stvarnih povratnih informacija koje dolaze od polaznika osposobljavanja. Slika 2 prikazuje detaljni gantogram projekta.



Slika 2: Gantogram BIRGIT projekta (URL 3)

Osim četiri glavne projektne aktivnosti (PR1, PR2, PR3 i PR4), projekt obuhvaća i više projektnih sastanaka kao i radionice s različitim dionicima zainteresiranim za integraciju BIM-a i GIS-a. U trenutku pisanja ovog rada (lipanj 2022.), projekt se nalazi u provedbi prve projektne aktivnosti (PR1) i početku rada na drugoj projektnoj aktivnosti (PR2). Na slici 2 to je označeno crvenom linijom.

2.2. Dosadašnji ostvareni rezultati

Kako je navedeno i sukladno projektnom planu, projekt je zasad fokusiran na provedbu prve projektne aktivnosti PR1: Zahtjevi industrije. Cilj ove aktivnosti je specificirati zahtjeve za obuku integracije BIM-a i GIS-a. Zahtjevi će biti opisani kao skupovi ciljeva učenja, prema međunarodnim standardima. Aktivnost uključuje nekoliko zadaća, a prva je T1.1: Pregled postojećih tečajeva i materijala za učenje. Cilj zadaće je identificirati postojeće relevantne tečajeve i dati preporuke o svim dijelovima svakog tečaja (uključujući ciljeve učenja) koji mogu biti uključeni u obrazovnu ponudu projekta. Zadaća T1.2: Istraživanje potreba industrije ima za cilj prikupiti zahtjeve industrije i krajnjih korisnika u svakoj od partnerskih zemalja obzirom na BIM/GIS integraciju. Zahtjevi će biti opisani kao potrebna znanja, vještine i kompetencije. Zadaća T1.3: Specifikacija strukovnih tečajeva će odredit skup strukovnih tečajeva na temelju rezultata ostvarenih u T1.1 i T1.2.

Tijekom rada na zadaći T1.1 identificirano je preko 50 postojećih izvora što uključuje predavanja, tečajeve, radionice, predmete na studijima i dr. Uglavnom se postojeći izvori odnose na BIM ili GIS i vrlo ih je malo koji sadrže integraciju BIM-a i GIS-a. Većina izvora je na engleskom jeziku dok je dio na službenim jezicima zemalja partnera.

Zadaća T1.2 ima za cilj identificirati vodeće pružatelje BIM/GIS rješenja i provesti upitnik te ciljane intervjue kako bi se prikupili zahtjevi industrije i krajnjih korisnika. Upitnik s ukupno 27 pitanja je otvoren početkom lipnja na službenim jezicima zemalja partnera i na engleskom jeziku (URL 5). Trenutno je u planu provedba ciljanih intervjua. U nastavku je dan pregled dijela prikupljenih odgovora na upitnik zaključno s 26. 06. 2022. Upitnik će biti otvoren do početka rujna 2022.

1.1 Za koju vrstu organizacije radite?

		Odgovori	Omjer
Obrazovanje i istraživanje (obrazovanje na svim razinama, istraživanje na akademskoj razini...)		5	16.13 %
Industrija/poduzeće (veliko poduzeće)		4	12.90 %
Mala i srednja poduzeća (MSP)		20	64.52 %
Uprava/javno tijelo (na svim razinama)		1	3.23 %
Pružatelji strukovnog obrazovanja i osposobljavanja		1	3.23 %
Ostalo		3	9.68 %
Nema odgovora		0	0.00 %

1.2 U kojoj se zemlji nalazi vaša organizacija?

		Odgovori	Omjer
Međunarodna organizacija		0	0.00 %
Europska organizacija		1	3.23 %
Hrvatska		13	41.94 %
Italija		6	19.35 %
Španjolska		3	9.68 %
Švedska		0	0.00 %
Ostalo		8	25.81 %
Nema odgovora		0	0.00 %

1.4 Navedite sektor ili sektore u kojima uglavnom posluje vaše poduzeće/organizacija/ustanova.

		Odgovori	Omjer
Osposobljavanje i obrazovanje		8	25.81 %
Arhitektura, inženjerstvo, građevinarstvo		19	61.29 %
Razvoj i distribucija softvera		9	29.03 %
Urbanističko planiranje		0	0.00 %
Osiguranje		0	0.00 %
Komunalne usluge		1	3.23 %
Upravljanje objektima		2	6.45 %
Energija		6	19.35 %
Usluge zaštite okoliša		4	12.90 %
Prijevoz		1	3.23 %
Drugo (navedite u nastavku)		3	9.68 %
Nema odgovora		0	0.00 %

2.1 Kako biste ocijenili status/stupanj usvojenosti integracije BIM-a i GIS-a u vašoj zemlji?

		Odgovori	Omjer
Nije usvojena/irelevantna		4	12.90 %
U razvoju/rana faza usvajanja		18	58.06 %
U porastu		8	25.81 %
Visoki stupanj/dobro razvijena		1	3.23 %

2.2 U kojim se područjima tehnologija integracije BIM-a i GIS-a uglavnom upotrebljava ili bi se u budućnosti mogla upotrebljavati u vašoj zemlji?

		Odgovori	Omjer
Korištenje zemljišta i urbanističko planiranje		17	54.84 %
Pametni gradovi		12	38.71 %
Arhitektura		21	67.74 %
Željeznice		10	32.26 %
Ceste i autoceste		16	51.61 %
Mostovi		10	32.26 %
Zračne luke		6	19.35 %
Električne mreže		7	22.58 %
Komunalne podzemne mreže		11	35.48 %
Upravljanje objektima		11	35.48 %
Upravljanje životnim ciklusom infrastrukture		9	29.03 %
Fotonaponska postrojenja		6	19.35 %
Postrojenja vjetroelektrana		6	19.35 %

2.3 Pretpostavimo da želite zaposliti osobu za rad na integraciji BIM-a i GIS-a. Koje se razine obrazovanja traže od tog kandidata?

		Odgovori	Omjer
Završeno srednjoškolsko obrazovanje		5	16.13 %
Potvrda o stručnoj/strukovnoj izobrazbi		9	29.03 %
Preddiplomski studij		19	61.29 %
Diplomski studij		20	64.52 %
Doktorat/doktorski studij		4	12.90 %

2.6 Kako biste ocijenili razinu usklađenosti između postojećih postojećih visokoškolskih ustanova i/ili programa strukovnog obrazovanja i osposobljavanja i potreba industrije u smislu BIM i GIS integracije?

		Odgovori	Omjer
Dobro usklađeno		1	3.23 %
Djelomično usklađeno		9	29.03 %
Nije usklađeno		18	58.06 %
Ne znam		3	9.68 %

2.8 Prema vašem mišljenju, u kojoj mjeri TRENUTNI ZAPOSLENICI u geoprostornoj industriji i području arhitekture, inženjerstva i građevine posjeduju kompetencije i vještine potrebne za integraciju BIM-a i GIS-a?

		Odgovori	Omjer
Njihove vještine dobro odgovaraju potrebama integracije		1	3.23 %
Imaju vještine potrebne za ispunjavanje zahtjevnijih zadaća		1	3.23 %
Potrebno im je dodatno osposobljavanje		19	61.29 %
Ne posjeduju potrebne vještine		3	9.68 %
Ne znam		7	22.58 %

3.1 Koje vrste aspekata povezanih s obrazovanjem smatrate najvažnijima za jačanje integracije GIS-a i BIM-a? (Nije obvezno) : Stažiranje u okviru obrazovnih programa

		Odgovori	Omjer
Uopće nije važno		1	3.23 %
Donekle važno		3	9.68 %
Važno		12	38.71 %
Prilično važno		6	19.35 %
Vrlo važno		3	9.68 %
Nemam mišljenje		2	6.45 %
Nema odgovora		4	12.90 %

2.3. Diskusija

Prema dosad ostvarenim rezultatima upitnika, najveći broj ispitanika je iz privatnog sektora (male, srednje i velike tvrtke) i iz akademskog sektora. Najveći odaziv je iz Hrvatske. Obzirom na sektor najveći dio ispitanika je u sektoru arhitekture, inženjerstva i graditeljstva, a slijedi ih IT sektor i obrazovanje. Stupanj usvojenosti integracija BIM-a i GIS-a je općenito nizak (u ranoj fazi usvajanja). S druge pak strane jasno se prepoznaje potencijal takve integracije koji se može primijeniti u različitim područjima od arhitekture i urbanizma, prometa, energetike do upravljanja objektima. Razina usklađenosti između postojećih visokoškolskih ustanova i/ili programa strukovnog obrazovanja i osposobljavanja i potreba industrije u smislu BIM i GIS integracije je niska. Odgovarajuća razina obrazovanja bi bila preddiplomski ili diplomski studij. U svrhu bolje integracije BIM-a i GIS-a postojećim zaposlenicima je potrebno dodatno osposobljavanje. Bolja integracija mogla bi se postići stažiranjem tijekom izobrazbe, izradom završnog rada takve tematike te učenjem na primjerima iz prakse.

Iako su ovo tek preliminarni i necjeloviti rezultati upitnika, već sad se iz njih mogu identificirati odgovarajući trendovi i izvesti neki zaključci. Konačni rezultati zajedno s rezultatima ciljanih intervjua biti će dobra osnova za daljnji rad na projektnim aktivnostima.

3. Zaključak

Sve je veći interes za integracijom BIM-a i GIS-a. Tradicionalno BIM i GIS uključuju različite stručnjake, najčešće arhitekte i građevinare u području BIM-a te geodete i geoinformatičare u području GIS-a. U praksi su ta dva svijeta još uvijek prilično razdvojena. Korisnici GIS-a vide BIM kao osnovni izvor podataka za građevine. S druge strane GIS se vidi kao ključni izvor podataka za dizajn i integraciju novih BIM modela u prostorni kontekst. Inicijalni rezultati upitnika koji se provodi u BIRGIT projektu potvrđuju takav zaključak.

Integracija BIM-a i GIS-a podrazumijeva stvaranje stručnjaka koji će posjedovati relevantna znanja iz oba područja. U tome bi od velike pomoći trebao biti BIRGIT projekt. Projekt će rezultirati novim predmetima, tečajevima i nastavnim materijalima za potrebe integracije BIM-a i GIS-a. Postojeći materijali će se poboljšati identificiranim zahtjevima dionika. Materijali koji će se razviti ili prilagoditi bit će pomno odbrani i organizirani od strane stručnjaka u domeni i uključivat će najnovija dostignuća u obje tehnologije. Materijali će sadržavati predavanja, video zapise kao i skupove podataka, zadatke, prijedloge literature i testne upitnike. Praćenjem navedenoga kroz predavanja, tečajeve i radionice, očekujemo da će GIS stručnjaci prepoznati važnost i razumijevanje mogućnosti i informacijske strukture BIM-a, kako to uskladiti i koristiti te integrirati u svoje baze podataka. S druge strane, učenjem kako koristiti GIS, BIM stručnjaci će postići veće razumijevanje i pristup relevantnim informacijama kojima treba pristupiti, upravljati i koristiti ih za donošenje odluka.

Literatura

Hijazi, I., Donaubauer, A., Kolbe, T.H. (2018): BIM-GIS Integration as Dedicated and Independent Course for Geoinformatics Students: Merits, Challenges, and Ways Forward. ISPRS Int. J. Geo-Inf. 2018, 7, 319. https://doi.org/10.3390/ijgi7080319

Van Berlo, Léon, De Laat, Ruben (2011): Integration of BIM and GIS: The development of the CityGML GeoBIM extension. In Kolbe, T. H., König, G., Nagel, C. (Eds.) 2011: Advances in 3D Geo-Information Sciences, ISBN 978-3-642-12669-7.

URL 1: Integration of BIM & GIS, https://www.united-bim.com/integration-of-bim-gis/, (24. 6. 2022.)

URL 2: GIS AND BIM INTEGRATION. A High Level Global Report, https://www.geospatialworld.net/consulting/reports/gis-and-bim-integration/, (24. 6. 2022.)

URL 3: BIRGIT, https://birgitproject.eu/, (24. 6. 2022.)

URL 4: What Is Scrum Methodology? & Scrum Project Management https://www.digite.com/agile/scrum-methodology/, (25. 6. 2022.)

URL 5: BIRGIT survey on BIM-GIS integration, https://birgitproject.eu/survey/, (25. 6. 2022.)

BIM and GIS Integration

Abstract

The construction and geospatial industry in the public and private sector requires new approaches for design procedures, urban planning, asset management, etc., all with the aim of reducing costs and sustainable impact on the environment. For this reason, integrated information management based on standards and clear guidelines is needed. One of the basic approaches to this is the development and integration of BIM (Building Information Modeling) and GIS (Geoinformation Systems) technologies. By linking construction and geospatial information management, it is possible to improve the construction process, property management, including buildings, roads and other important facilities. Integration also helps to create sustainable and flexible transport infrastructure as well as support infrastructure investments with reduced negative social, economic and environmental impacts. However, the integration of data from these sectors requires a high level of expertise in both domains. With the aim of strengthening the capacity in the integration of BIM and GIS, the Erasmus + project BIRGIT (training on Building InfoRmation models integrated with Geographical InformaTion) of the University of the North and other partners was launched. The project aims to connect the areas of BIM and GIS in order to train future professionals with the necessary knowledge and skills through the development of new teaching content in undergraduate and graduate studies, and lifelong learning programs. The BIRGIT project will last for 3 years in the period from February 1, 2022 to January 31, 2025. This paper presents the results of the project achieved so far as well as plans for future implementation.

Keywords: *BIM, BIRGIT project, GIS, integration.*

Mogućnosti primjene jeftinog GNSS senzora za geodetsku izmjeru

Loris Redovniković[1], Antun Jakopec[2], Iva Odak[3]

[1] Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, lredovnikovic@geof.hr

[2] Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, ajakopec@geof.hr

[3] Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, iodak@geof.hr

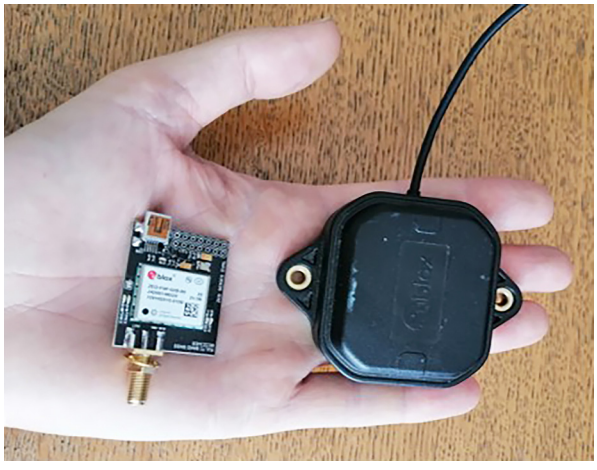
Sažetak

GNSS prijemnici se već desetljećima koriste u geodeziji i mnoge geodetske tvrtke svoje poslovanje dobrim dijelom temelje na korištenju GNSS tehnologije. U početcima su GNSS prijamnici bili vrlo skupi, velikih dimenzija i mase što ih je činilo manje pogodnima za izvođenje svakodnevnih geodetskih poslova. Tada su se koristili prvenstveno u vojne svrhe, a kasnije su se počeli koristiti i za civilne potrebe. Prvi potpuno operativan sustav bio je američki GPS sustav, a kasnije i ruski GLONASS. Zbog manjeg broja satelita na nebu u to vrijeme inicijalizacija je trajala dugo. U današnje vrijeme imamo i europski svemirski sustav Galileo te kineski BeiDou. U trendu su GNSS prijemnici vrlo malih dimenzija koji primaju signale sa svih gore navedenih satelitskih sustava. Njihova cijena je prilično niska u usporedbi sa cijenama prijemnika starije generacije. U ovome radu ispitati će se točnost i praktičnost korištenja jednog od tih novih senzora uz korištenje besplatnih aplikacija.

Ključne riječi: *GNSS, RTKLIB, SW Maps, U-blox, ZED-F9P*

1. Uvod

Krajem prošloga stoljeća GNSS tehnologija počela se sve više koristiti za navigaciju i apsolutno pozicioniranje na Zemlji. U početcima se uglavnom koristila u vojne svrhe, ali se postupno sve više počela koristiti i za razne civilne potrebe. Geodezija je jedna od struka koja je najzaslužnija za razvoj GNSS tehnologije, ali je istovremeno imala i značajne koristi od nje. Svakodnevni geodetski posao u današnje vrijeme dobrim dijelom se oslanja na GNSS tehnologiju. Kinematika u realnom vremenu ili RTK metoda izmjere pritom je najkorištenija GNSS metoda izmjere u našoj struci. U tim početcima cijena je bila glavni ograničavajući čimbenik za šire korištenje u geodetske svrhe. Zbog visoke cijene dvofrekventnih prijemnika njihovo korištenje uglavnom nije bilo isplativo za korisnike drugih struka, a i geodeti sebi nisu mogli lako priuštiti blagodati koje im je GNSS tehnologija pružala. Uvođenjem CROPOS-a više nije bilo potrebno koristiti dva prijemnika, što je za posljedicu imalo daljnje smanjenje cijene sustava te je postala još masovnije korištena metoda izmjere od strane geodetskih stručnjaka. Cijena GNSS prijemnika neprestano se smanjuje dok se njihove performanse poboljšavaju. Sve je više satelitskih sustava i satelita na nebu, a prijemnici osim manje cijene postaju sve manjih dimenzija i imaju manju masu. Od travnja 2022. godine CROPOS usluga je postala besplatna što će za posljedicu imati još masovniju primjenu u praksi i to ne samo u geodetske svrhe nego i za mnoga druga područja.



Slika 1a: U-blox F9P prijemnik
(autor: L. Redovniković)

2. Jeftini GNSS senzori i prateća oprema

Kao što je rečeno u uvodu, u početcima je glavni nedostatak GNSS tehnologije bio njena visoka cijena. S vremenom se to polako mijenjalo i na tržištu se osim renomiranih proizvođača geodetske opreme kao što su Leica, Topcon, Trimble i sl., počeo pojavljivati sve veći broj proizvođača. Među njima se ističe U-blox, švicarska firma koja se bavi proizvodnjom bežičnih i modula za potrošačka, automobilska i industrijska tržišta (URL 1). U-blox je postao poznat po sedmoj i osmoj generaciji jeftinih jednofrekventnih GNSS čipova, a u novije vrijeme izbacili su na tržište generacije devet i deset od kojih je najpoznatiji dvofrekventni prijemnik F9P (Slika 1a i 1b).

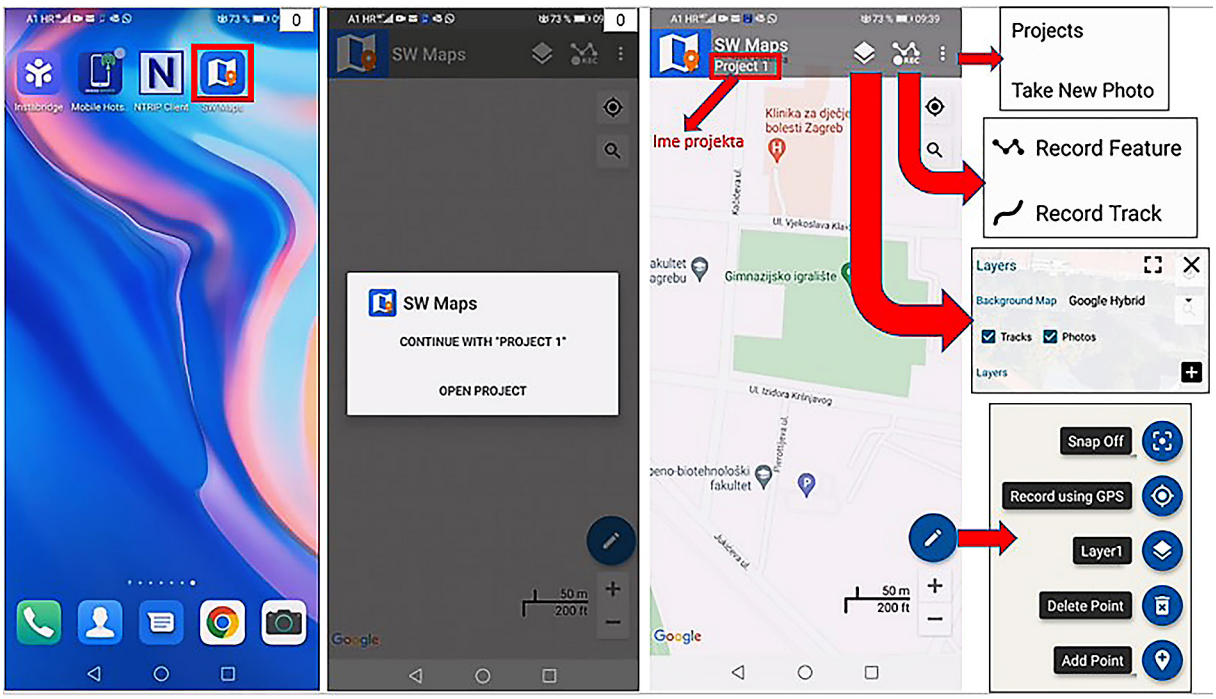


Slika 1b: ANN-MB antena
(autor: L. Redovniković)

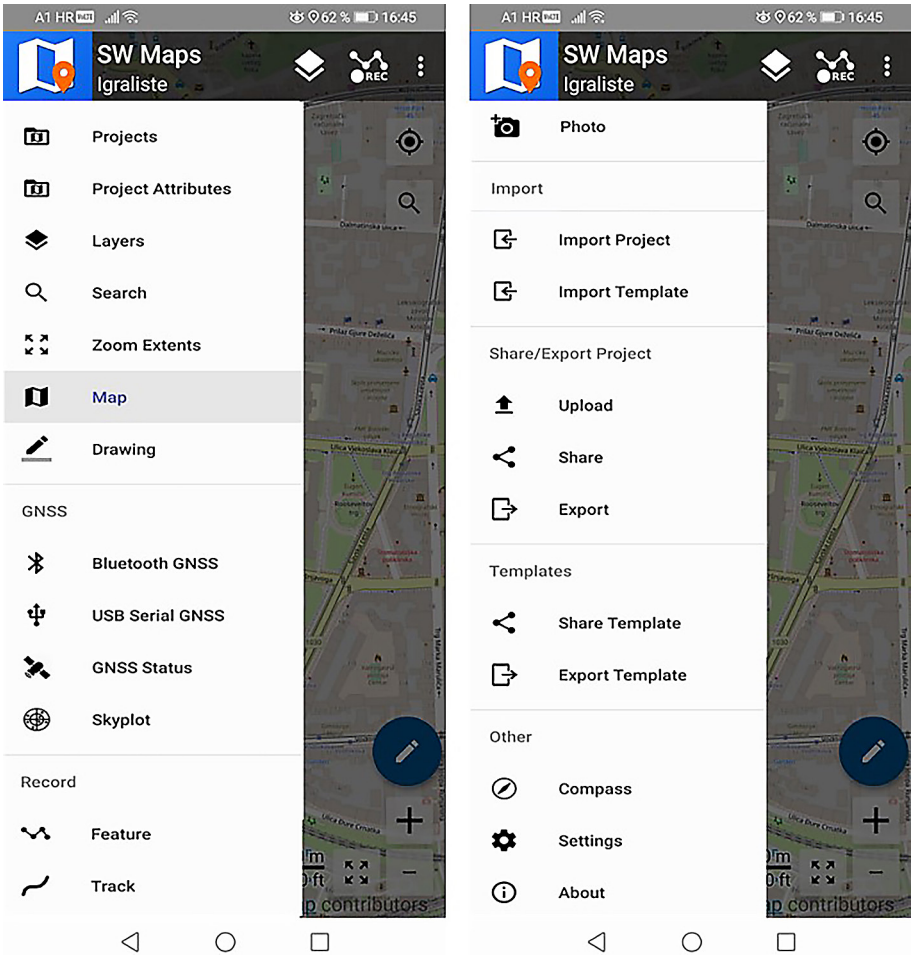
Prijemnici se mogu povezati s U-bloxovim aktivnim antenama poput ANN-MB antene ili manje i lakše Helix antene. Moguće ih je povezati i s kvalitetnijim antenama koje se koriste za geodetsku izmjeru, ali i s ovim jeftinim antenama mogu se postići prilično dobri rezultati (Nguyen i dr. 2021).

3. Softver za obradu podataka

Prilikom istraživanja softvera koji bi bio pogodan za obradu podataka prikupljenih pomoću U-blox F9P senzora, najprije je razmatran U-bloxov u-center softver koji nudi jako puno mogućnosti prvenstveno namijenjenih konfiguriranju prijemnika, ali nudi i mogućnost spajanja na NTRIP mrežu i dobivanja RTK rješenja. Nedostatak softvera u-center je taj što je namijenjen za stolna ili prijenosna računala, koja nisu pogodna za rad na terenu. Nakon u-centera odabir je bio RTKLIB programski paket otvorenog koda za GNSS pozicioniranje (URL 2). Njegov tvorac Tomoji Takasu postavio je kod na Github-u (URL 3), ali već nekoliko godina se ne radi na njegovom daljnjem razvoju. RTKLIB je poslužio kao osnova za razvoj mnogih drugih aplikacija, budući da ima jako dobro dokumentirane korisničke upute, koje sadrže preko 180 stranica teksta. Izvorni kod je nastavio razvijati Tim Everett koji ima odličan blog rtklibexplorer (URL 4), u kojem je obradio niz tema o korištenju jeftinih GNSS senzora. Izdano je više verzija poboljšanja izvornog koda i sve je moguće preuzeti putem interneta (URL 5). RTKLIB nudi jako puno mogućnosti, ali zbog ograničenog prostora u ovom radu neće biti značajnije razmatran. Vrijedi spomenuti da se kod može koristiti na raznim operativnim sustavima i na različitim hardverima, od stolnog računala preko laptopa do mini računala poput Raspberry Pi-a i sl. Također je vrijedno istaknuti Emlid zajednicu koja za bazu koristi jeftine senzore, ali daje nadogradnju kako po pitanju hardvera tako i po pitanju softvera. Od sof-



Slika 2: Pokretanje aplikacije SW Maps (autor: L. Redovniković)



Slika 3: Glavni meni aplikacije SW Maps (autor: L. Redovniković)

tvera je zgodno istaknuti PPK softver Emlid Studio (URL 6) i mobilnu aplikaciju ReadhView 3 (URL 7) koji također imaju mnoštvo edukacijskih materijala u kojima na jednostavan način uspijevaju približiti mogućnosti nove tehnologije korisnicima (URL 8). Jedna besplatna android aplikacija pod nazivom SW Maps pokazala se kao vrlo korisna i praktična za obavljanje geodetskih zadataka te će biti detaljnije opisana u nastavku.

3.1. Android aplikacija SW Maps - GIS & Data Collector

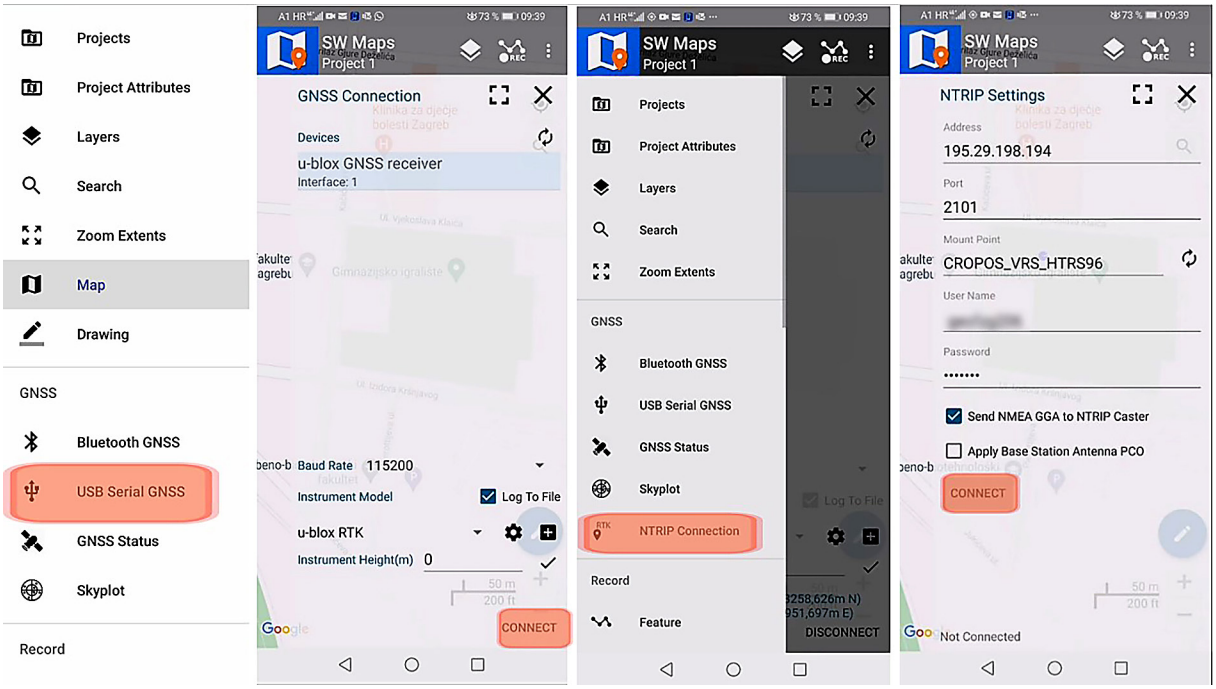
Ova besplatna i intuitivna android aplikacija vrlo je zgodna za prosječnog korisnika. Velika prednost je što podržava preuzimanje korekcija preko mreže referentnih baznih stanica. Također je prednost i to što podržava korištenje vanjskog GNSS prijemnika, bilo putem USB-C kabela i USB On-The-Go (OTG) adaptera ili putem Bluetooth-a.

Nakon pokretanja aplikacije moguće je nastaviti s posljednje kreiranim poslom ili otvoriti neki drugi, postojeći ili novi posao. Nakon toga otvara se početni zaslon u kojem je moguće zumirati kartu na trenutnu poziciju (Slika 2).

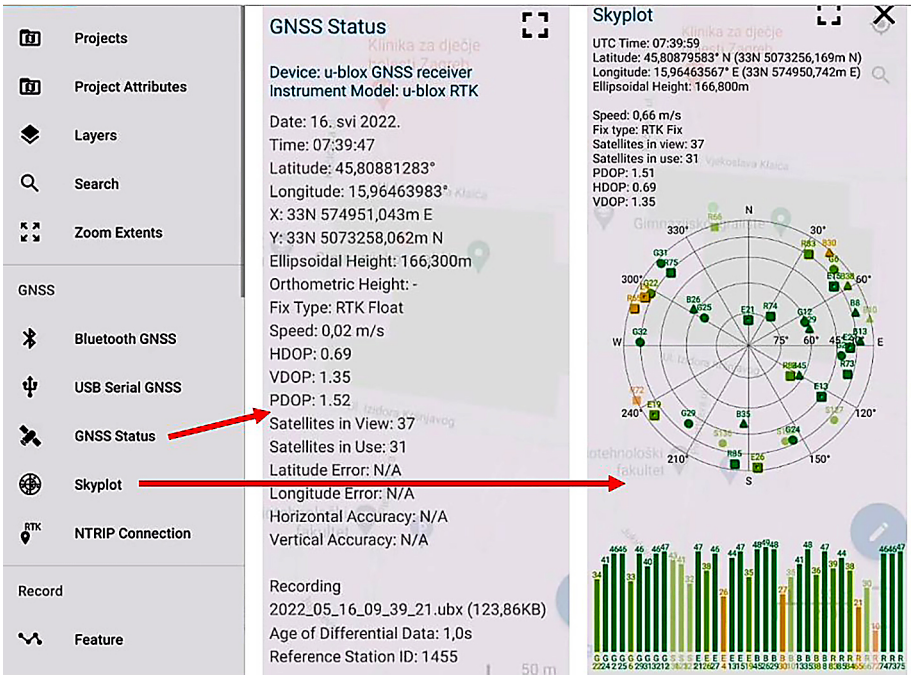
Pritiskom na ikonu u gornjem lijevom kutu otvara se padajući meni prikazan na Slici 3.

Ono što čini aplikaciju posebnom je vrlo jednostavno i učinkovito povezivanje s vanjskim GNSS uređajem kao i spajanje na mrežu referentnih baznih stanica. U nastavku je ukratko objašnjen postupak koji je prikazan na Slici 4. U glavnom izborniku odabere se povezivanje s GNSS uređajem pomoću USB-a ili bluetooth-a. U otvorenom dijaloškom okviru odabere se model korištenog prijemnika i po potrebi, upiše visina antene i odabere mogućnost pohranjivanja mjerenih podataka na android uređaj. Nakon povezivanja s vanjskim GNSS prijemnikom u glavnom izborniku se pojavljuje mogućnost povezivanja na mrežu referentnih baznih stanica (NTRIP Connection) te se pojavljuje dijaloški okvir u kojega je potrebno upisati korisničko ime i lozinku te odabrati adresu i port poslužitelja na kojega se pokušavamo spojiti. Ukoliko se žele koristiti virtualne referentne stanice potrebno je označiti slanje NMEA pozicije NTRIP poslužitelju.

Nakon uspješnog povezivanja s GNSS prijemnikom i spajanja na NTRIP server sustav je spreman za rad. U glavnom izborniku može se odabrati ikone GNSS status ili Skyplot da bi se vidjeli podaci o trenutnom vremenu i položaju antene. Ono što je za geodeziju uglavnom bitno je da su rješenja fiksna. Također je moguće vidjeti podatke o horizontalnoj, visinskoj i položajnoj raspršenosti podataka te broj i raspored satelita (Slika 5).



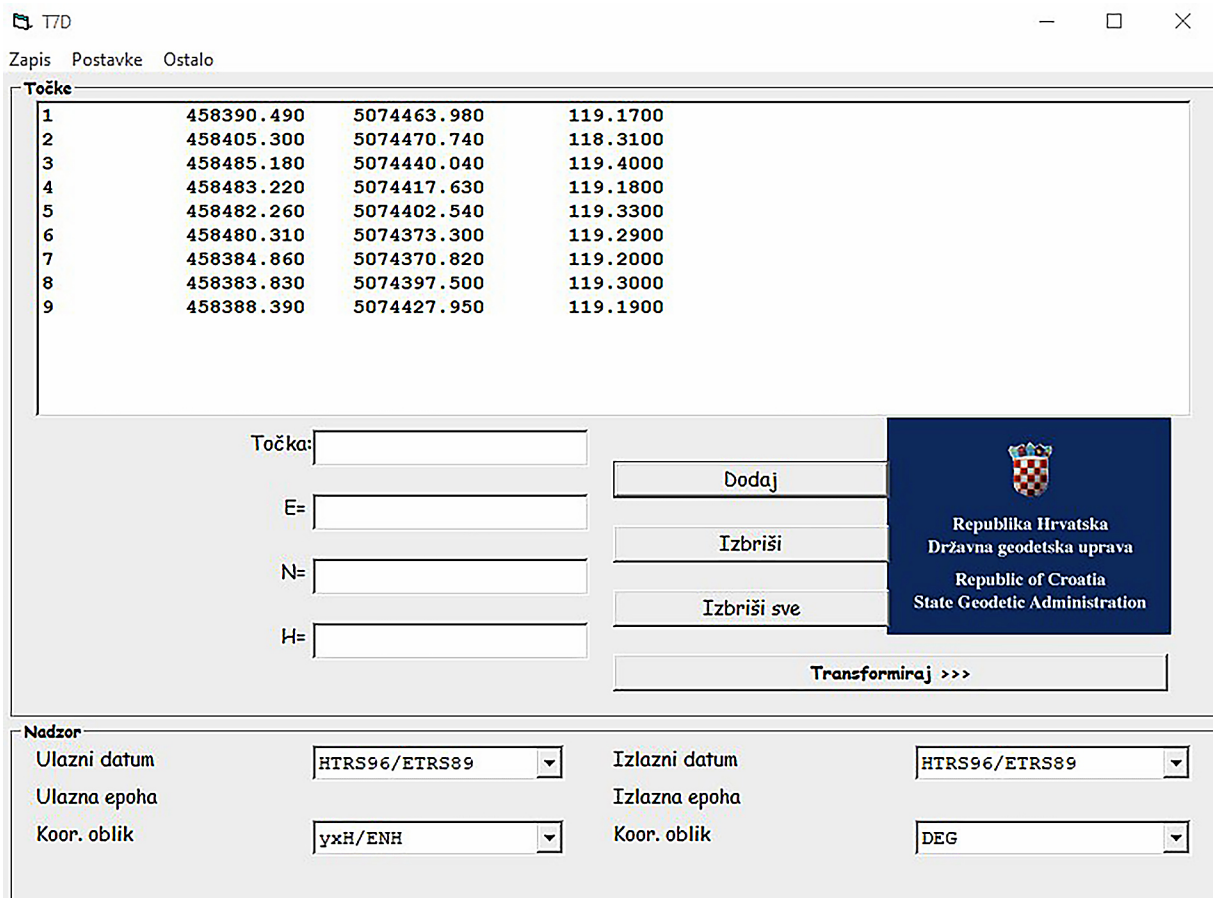
Slika 4: Povezivanje na vanjski GNSS i NTRIP server (autor: L. Redovniković)



Slika 5: GNSS status i skyplot (autor: L. Redovniković)

Unutar aplikacije je moguće snimanje pojedinačnih značajki, GNSS tragova i fotografija. Od pojedinačnih značajki moguće je snimati točke, linije i poligone. Kod točkastih znakova je moguće zadati boju i oblik (krug, trokut ili pravokutnik) dok je kod linijskih i poligonskih objekata moguće zadavati boju i debljinu linije.

Snimanje točaka moguće je pokrenuti iz izbornika za snimanje  koji se nalazi u gornjem redu pored izbornika slojeva ili iz izbornika za editiranje  koji se nalazi po sredini desno nakon čega je potrebno odabrati *Record using GPS*. Po želji se može uključiti računanje prosjeka iz većeg broja epoha, što je preporučljivo za primjenu u geodeziji jer prema važećim propisima detaljne točke treba opažati barem 6 epoha, a točke geodetske osnova 3 puta po 30 epoha i nakon određenog vremenskog perioda ponovno 3 puta po 30 epoha. Ukoliko želimo ponovno pokrenuti računanje prosjeka to je moguće pritiskom na ikonu  reset, a kada se postigne željeni broj epoha točku možemo pohraniti pomoću ikone za snimanje.



Slika 6: Postavke za transformaciju u T7D (autor: L. Redovniković)

Snimanje fotografije moguće je pokrenuti iz glavnog izbornika gore lijevo ili iz izbornika gore desno. Nakon što je snimljena fotografija na karti se prikazuje ikona . Klikom na tu ikonu otvara se snimljena fotografija sa koordinatama i vremenom snimanja. Kod snimanja fotografija one se pohranjuju u lokalnu memoriju pod SW_Maps/Pictures. U exif zapisu slike bilježi se podatak o lokaciji snimljene fotografije.

Pomoću aplikacije SW Maps moguće je iskolčavati točke, ali je potrebna prethodna priprema. Ukoliko su zadane koordinate u HTRS96/TM koordinatnom sustavu treba ih prvo konvertirati u WGS84. To je moguće napraviti pomoću T7D, besplatne aplikacija koju izdaje DGU. Kao ulazni datum treba odabrati HTRS96/ETRS89, a za koordinatni oblik odaberemo xyH/ENH. Za izlazni datum također odaberemo HTRS96/ETRS89, a za koordinatni oblik može se odabrati DEG (Slika 6). Za visinski datum odaberemo *Postavke/Odabir visinskog datma/HVRS71*.

Nakon provedene transformacije pohranimo dobivene koordinate. U tekstualnom editoru otvorimo dobivenu .lst datoteku i dodamo prvi redak sa tekstom tipa br,B,L,H i zamjenimo sva prazna mjesta sa zarezima te snimimo datokeku sa nastavkom .csv.

Na računalu je moguće instalirati besplatnu aplikaciju Google Earth Pro u kojoj pomoću CTRL+O otvorimo prethodno spremljenu .csv datoteku. Na sljedećem ekranu potrebno je odabrati polja koja odgovaraju geografskoj širini B i geografskoj dužini L. Nakon završenog unosa pojavljuje se pitanje, da li želimo primijeniti promjene stila na uvedene značajke, na što treba odgovoriti potvrdno. Zatim se odabere stvaranje novog predloška i u kartici *visine* odaberemo *postavi visinu iz polja* i odaberemo polje H. Ne moramo snimati ponuđeni predložak. Desnim klikom na prethodno kreirani sloj odabiremo *spremi mjesto kao*. Upišemo naziv i mjesto pohrane dataoteke te odaberemo ekstenziju Kml ili Kmz. Tako dobivenu datoteku učitamo u memoriju android uređaja pod *SW_Maps/Maps/kml*.

U SW Maps aplikaciji odaberemo slojeve ( ) u gornjem desnom izborniku, dodamo novi sloj pomoću ikone . Odaberemo KML i prethodno kreiranu .kml datoteku. Nakon toga bi se na zaslonu trebale pojaviti točke sa željenom podlogom u pozadini.

Moguće je učitati i shape datoteku koju možemo kreirati u također besplatnom programu Qgis na način da odemo na *Layer/Add Layer/Add Delimited Text Layer*. Odaberemo prethodno kreiranu .csv datoteku i definiramo geografsku dužinu kao x os, a geografsku širinu kao y os. U polju Geometry CRS odaberemo EPSG:4326 – WGS 84 koordinatni sustav. Kliknemo na dodaj i zatvori. Točke su dodane i za kontrolu je poželjno u pozadinu učitati OpenStreetMap na način da se na tipkovnici pritisne CTRL+L zatim u gornjem lijevom dijelu odabere *Browser* i sa desne strane *XYZ Tiles* te dvostrukim klikom na *OpenStreetMap* učitamo sloj u Qgis. Da bi točke bile vidljive sloj s točkama treba dignuti iznad karte. Desnim klikom na sloj

s točkama možemo otvoriti atributnu tablicu i kada u njoj selektiramo određeni redak na karti se žutom bojom prikaže selektirana točka. Također desnim klikom na isti sloj možemo odabrati *Export/Save Featues As*, odaberemo *ESRI Shapefile*, ime i mjesto gdje želimo pohraniti datoteku. Tako dobivenu datoteku učitamo u memoriju android uređaja pod *SW_Maps/Maps/shapefiles*.

Prije samog iskolčenja dobro je u aplikaciji odabrati kompas da kartu položimo u smjeru sjevera i krenemo iskolčavati željenu točku. Kada se približimo točki koju želimo iskolčiti možemo ju dotaknuti prstom i tada se otvara novi okvir koji nam daje odstupanja po x i y osi. U praktičnom primjeru odlučili smo iskolčiti i snimiti 5 točaka na srednjoškolskom igralištu ispred zgrade Fakulteta. Preuzete koordinate su dobivene u prethodnim diplomskim radovima u kojima se mreža točaka opažala pomoću GNSS-a, preciznog nivelira i precizne mjerne stanice. Koordinate točaka mreže određene su nakon što je na mjerenja primijenjena stroga metoda izjednačenja i smatrale su se bespogrešnima. Uspješno smo iskolčili svih 5 točaka i nakon što smo ih iskočili iste smo snimili na način da smo uzeli sredinu iz 30 epoha opažanja. Tijekom mjerenja, prilikom vrhunjenja dozne libele, štap je držan ručno. Dobivene koordinate su bile u WGS koordinatnom sustavu sa elipsoidnom visinom, a budući da smo prethodno učitali model geoida u *SW_Maps/Geoids/Geoid2009.gtx* na terenu smo odmah imali i normalne ortometrijske visine. Pokazalo se da je moguće postići horizontalnu točnost pozicioniranja od oko jednog centimetra dok je po visini točnost bila unutar 5 centimetara (Tablica 1).

Tablica 1: Razlike između poznatih i snimljenih točaka izražene u metrima

Br. toc.	D E	D N	T7D D H	SW_MAPS D H
A	-0.01	0.00	0.02	0.02
B	0.01	0.00	0.00	0.00
C	-0.01	0.00	-0.01	-0.01
D	-0.01	0.00	-0.04	-0.03
E	-0.01	-0.01	0.01	0.02

4. Zaključak

Iz svega navedenog može se zaključiti da proizvođači jeftinih GNSS senzora poput U-blox-a rade vrlo kvalitetne uređaje te besplatno daju na raspolaganje moćan softver u-center pomoću kojega je moguće izvršiti razne konfiguracije uređaja i dobivati RTK rješenja. U-center aplikacija, premda je vrlo moćna, nije praktična za svakodnevnu upotrebu, budući da je predviđena za rad na prijenosnim ili stolnim računalima. U praksi se pokazala kao vrlo praktična i korisna besplatna android aplikacija SW Maps koja nudi mogućnost povezivanja s vanjskim GNSS prijemnikom i primanje korekcija preko NTRIP mreže. Kako se od travnja ove godine ne naplaćuje naknada za korištenje CROPOS-ovog visokopreciznog servisa pozicioniranja (VPPS servisa) za registrirane korisnike, ova mogućnost je svakako dobrodošla. Zahvaljujući prijemu svih globalnih navigacijskih satelita vrlo brzo se postižu fiksna rješenja koja se mogu održati i u područjima koja nisu pretjerano pogodna za GNSS izmjeru. Osim snimanja, pomoću aplikacije je moguće i iskolčavanje točaka, mada je procedura nešto malo složenija od one na koju je većina geodetskih stručnjaka navikla. Na temelju svega navedenoga može se zaključiti da je pred nama era jeftinih GNSS uređaja koji u kombinaciji s besplatnim softverima nude prilično kvalitetna rješenja. To geodetskim stručnjacima otvara nove mogućnosti, ali će ista tehnologija postati dostupnija i mnogim drugim zainteresiranim korisnicima koji imaju potrebu za točnim i jeftinim pozicioniranjem.

Literatura

Nguyen, N.V., Cho, W., Hayashi, K. (2021): Performance evaluation of a typical low-cost multi-frequency multi-GNSS device for positioning and navigation in agriculture –Part 1:

Static testing, Smart Agricultural Technology 1 (2021),

https://doi.org/10.1016/j.atech.2021.100004.

URL 1: U-blox, https://en.wikipedia.org/wiki/U-blox, (24. 6. 2022.).

URL 2: RTKLIB, http://rtklib.com/, (24. 6. 2022.).

URL 3: RTKLIB, https://github.com/tomojitakasu/RTKLIB, (24. 6. 2022.).

URL 4: rtklibexplorer, https://rtklibexplorer.wordpress.com/, (24. 6. 2022.).

URL 5: rtklibexplorer dewnloads, http://rtkexplorer.com/downloads/rtklib-code/# (24. 6. 2022.).

URL 6: Emlid Studio, https://docs.emlid.com/emlid-studio/, (24. 6. 2022.).

URL 7: ReachView 3, https://emlid.com/reachview3/, (24. 6. 2022.).

URL 8: Emlid Tutorials, https://emlid.com/category/tutorials/, (24. 6. 2022.).

URL 9: Cropos obavijesti, https://www.cropos.hr/obavijesti. (24. 6. 2022.).

Possibilities of Application of Cheap GNSS Sensor for Geodetic Survey

Abstract

GNSS receivers have been used in geodesy for decades and many surveying companies base their business largely on the use of GNSS technology. In the beginning, GNSS receivers were very expensive, large in size and mass, which made them less suitable for performing everyday geodetic work. At that time, they were used primarily for military purposes, and later began to be used for civilian purposes. First fully operational system was American GPS system, and later the Russian GLONASS. Due to the smaller number of satellites in the sky at that time, the initialization took a long time. Nowadays we also have the European space system Galileo and the Chinese BeiDou. GNSS receivers of very small dimensions that receive signals from all the above satellite systems are in trend. Their price is quite low compared to the prices of the older generation receivers. This paper will examine the accuracy and convenience of using one of these new sensors using free applications.

Keywords: *GNSS, RTKLIB, SW Maps, U-blox, ZED-F9P*

Ispitivanje mogućnosti 20 Hz GNSS PPK mjerenja za određivanje pomaka i vlastitih frekvencija objekata

Josip Peroš[1], Rinaldo Paar[2], Ivan Racetin[3], Boštjan Kovačić[4]

[1] Fakultet građevinarstva, arhitekture i geodezije Sveučilišta u Splitu, Matice Hrvatske 15, Split, Hrvatska, jperos@gradst.hr

[2] Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, rpaar@geof.hr

[3] Fakultet građevinarstva, arhitekture i geodezije Sveučilišta u Splitu, Matice Hrvatske 15, Split, Hrvatska, ivan.racetin@gradst.hr

[4] Samostalni istraživač, Maribor, Slovenija

Sažetak

Monitoring je periodično ili kontinuirano promatranje konstrukcija, građevina ili dijelova Zemljine površine na temelju kojega se može procijeniti njihovo opće stanje povezano uz uporabljivost i stabilnost. Glavni cilj i zadatak monitoringa je odrediti i dokazati značajne geometrijske promjene između dvije ili više epoha mjerenja. Određivanje vlastitih frekvencija konstrukcija i objekata je sastavni dio procesa monitoringa. Detekcija značajnih promjena frekvencija, u odnosu na projektirane, može biti pokazatelj strukturalnih oštećenja konstrukcija i objekata. Korištenje novih generacija geodetskih instrumenata omogućuje, uz određivanje statičkih pomaka točaka, određivanje i dinamičkih pomaka točaka. Na temelju određenih dinamičkih pomaka točaka u vremenskom nizu mogu se određivati i vlastite frekvencije objekata. Kroz ovaj rad ispitane su ostvarive preciznosti određivanja simuliranih dinamičkih pomaka i vlastitih frekvencija korištenjem Trimble-ovog GNSS uređaja najnovije generacije, modela R12i. Podaci mjerenja GNSS uređaja prikupljani su s frekvencijom od 20 Hz. Način prikupljanja sirovih podataka mjerenja GNSS uređaja i kasnijeg izjednačenja mjerenja je Post-Processed Kinematic (PPK) metoda. Testna ispitivanja sastojala su se od određivanja simuliranja dinamičkih pomaka frekvencije od 0,5 Hz do 5,0 Hz i amplitude gibanja od 5 mm do 40 mm. Pomaci su simulirani korištenjem elektrodinamičkog pobuđivača, dok su referentne vrijednosti pomaka određene korištenjem induktivnog osjetila (LVDT). Ostvareni rezultati dijela testova pri određivanju dinamičkih pomaka i vlastitih frekvencija prikazani su u radu.

Ključne riječi: *dinamički pomak, monitoring, PPK, Trimble GNSS R12i, vlastita frekvencija*

1. Uvod

S razvojem i komercijalnom dostupnosti novih generacija geodetskih GNSS uređaja, postavlja se pitanje o njihovoj primjenjivosti u zadacima inženjerske geodezije, čija zahtjevnost s godinama raste zbog izgradnje i eksploatacije sve većih i kompleksnijih građevina. Određivanjem pomaka i deformacija građevina tijekom njihove eksploatacije dobiva se potvrda ponaša li se građevina u skladu s projektnim rješenjima, a dobiveni podaci predstavljaju važan parametar u procjeni stanja i sigurnosti građevine (Marendić i dr., 2013). Korištenjem GNSS uređaja mogu se određivati 3D položaji točke s frekvencijom od 10 do 100 mjerenja u sekundi. GNSS mjerenja više nisu ograničena samo na praćenje statičkih pomaka građevina, već se mogu koristiti i za određivanje dinamičkih pomaka te na temelju njih, određenih u vremenskoj domeni, određuju se i vlastite frekvencije građevina.

U prošlosti geodetsko praćenje dinamičkih pomaka prvenstveno je bilo usmjereno na fleksibilnije građevine, poput elastičnih mostova, nebodera i tornjeva. Takve građevine karakteriziraju pomaci većih iznosa s niskim frekvencijama (Meng i dr., 2007; Ogaja i dr., 2007; Ogaja i dr., 2003; Roberts i dr., 2001).

Razvojem GNSS uređaja, povećanjem njihove preciznosti mjerenja i intervala registriranja mjerenja, omogućeno je praćenje i krutih građevina čije su vlastite frekvencije veće od 1 Hz uz manje amplitude osciliranja. Prema svemu navedenome, ukazuje se potreba za ispitivanjem zadnjih generacija GNSS uređaja i određivanja njihovih ograničenja i mogućnosti za potrebe monitoringa. Na temelju takvih ispitivanja može se odrediti njihova potencijalna primjena u različitim sustavima monitoringa.

U ovom radu testirati će se GNSS uređaj Trimble R12i, s frekvencijom mjerenja od 20 Hz u PPK načinu rada. Uređaj će se testirati za određivanje amplituda i frekvencija simuliranih oscilacija. Na taj način će se pokušati odrediti granične vrijednosti i mogućnosti GNSS uređaja Trimble R12i, koji predstavlja posljednju generaciju geodetskih GNSS uređaja. Za potrebe

testiranja u svrhu simuliranja periodičkih sinusoidnih oscilacija s unaprijed određenim karakteristikama korišten je elektrodinamički pobuđivač.

2. Monitoring objekata

Monitoring je periodično ili kontinuirano promatranje konstrukcija, građevina ili dijelova zemljine površine na temelju kojega se može procijeniti njihovo opće stanje vezano uz uporabljivost i stabilnost. Glavni cilj i zadatak monitoringa je odrediti i dokazati značajne geometrijske promjene između dvije ili više epoha mjerenja. Određivanje vlastitih frekvencija konstrukcija i objekata je sastavni dio procesa monitoringa. Detekcija značajnih promjena frekvencija, u odnosu na projektirane, može biti pokazatelj strukturalnih oštećenja konstrukcija i objekata. Korištenje novih generacija geodetskih instrumenata, s frekvencijom mjerenja do 10 Hz do 100 Hz, omogućuje, uz određivanje statičkih pomaka točaka, određivanje i dinamičkih pomaka točaka. Na temelju određenih dinamičkih pomaka točaka u vremenskom nizu mogu se određivati i vlastite frekvencije objekata.

3. GNSS u monitoring sustavima

GNSS uređaji su dugo vremena zastupljeni u geodetskoj struci. U svakodnevnoj geodetskoj praksi GNSS prijamnik postao je praktično nezamjenjiv instrument. GNSS uređaji omogućavaju jednostavna i brza mjerenja sa zadovoljavajućom točnosti mjerenja za veliki broj standardnih klasičnih geodetskih zadataka.

Geodetski monitoring velikih građevina i određivanje njihovih dinamičkih pomaka u prošlosti uglavnom se baziralo na primjeni GNSS uređaja (Li, 2004; Ogaja i dr., 2007). U prvim projektima monitoringa građevina, predmet istraživanja bilo je ponašanje visokih zgrada i tornjeva uslijed djelovanja vjetra i potresa, te ponašanje velikih mostova uslijed djelovanja prometa i vjetra (Ogaja i dr., 2007). Nakon prvih projekata dinamičkog monitoringa primjenom geodetskih instrumenata, pri čemu se prvenstveno misli na GNSS tehnologiju, u kojima je napravljen veliki korak u pogledu primjenjivosti tehnologije, istraživanja su se usmjerila na integraciju senzora (GNSS uređaja, akcelerometara, pseudolita, itd.) i operativnosti sustava monitoringa (Barnes i dr., 2005; Li, 2004; Meng i dr., 2007). Integracijom GNSS uređaja i drugih senzora iskorištavaju se prednosti i nadilaze ograničenja pojedinačnih sustava. Frekvencija mjerenja većine današnjih GNSS uređaja iznosi 10-20 Hz. Konstantnim razvojem GNSS tehnologije došlo se do GNSS uređaja s mjernom frekvencijom od 50 Hz pa čak i do 100 Hz. U radu (Wyn Roberts i dr., 2004) prezentirani su ostvareni rezultati testiranja GNSS uređaja (frekvencija mjerenja 50 Hz) pri određivanju dinamičkih pomaka mosta Wilford u Nottighamu (Marendić i dr., 2013).

3.1. GNSS Trimble R12i

Kroz provedeno ispitivanje za potrebe rada testirane su mogućnosti GNSS uređaja Trimble R12i, u daljnjem tekstu R12i, za određivanje simuliranih pomaka i vlastitih frekvencija. R12i je uređaj zadnje generacije GNSS uređaja, koji mjeri na tri frekvencije sa 672 kanala (Slika 1). Jedna od značajnih novih mogućnosti je korekcija nagiba štapa korištenjem IMU (engl. Inertial Motion Unit), koji je neovisan o magnetskim utjecajima. R12i može istovremeno pratiti signale sa svih trenutno aktivnih, svjetskih GNSS sustava. R12i je kompaktan i lako prenosiv te se može se koristiti kao baza za statička i za RTK (engl. real - time kinematic) mjerenja. R12i je prilagodljiv i kompatibilan za naknadne obrade podataka s Post-Processing Kinematikom (PPK) ili statikom uz korištenje Virtualnih Referentnih Stanica (VRS). Ostvarive frekvencije mjerenja i pozicioniranja su 1 Hz, 2 Hz, 5 Hz, 10 Hz i 20 Hz (Trimble Geospatial, 2020).



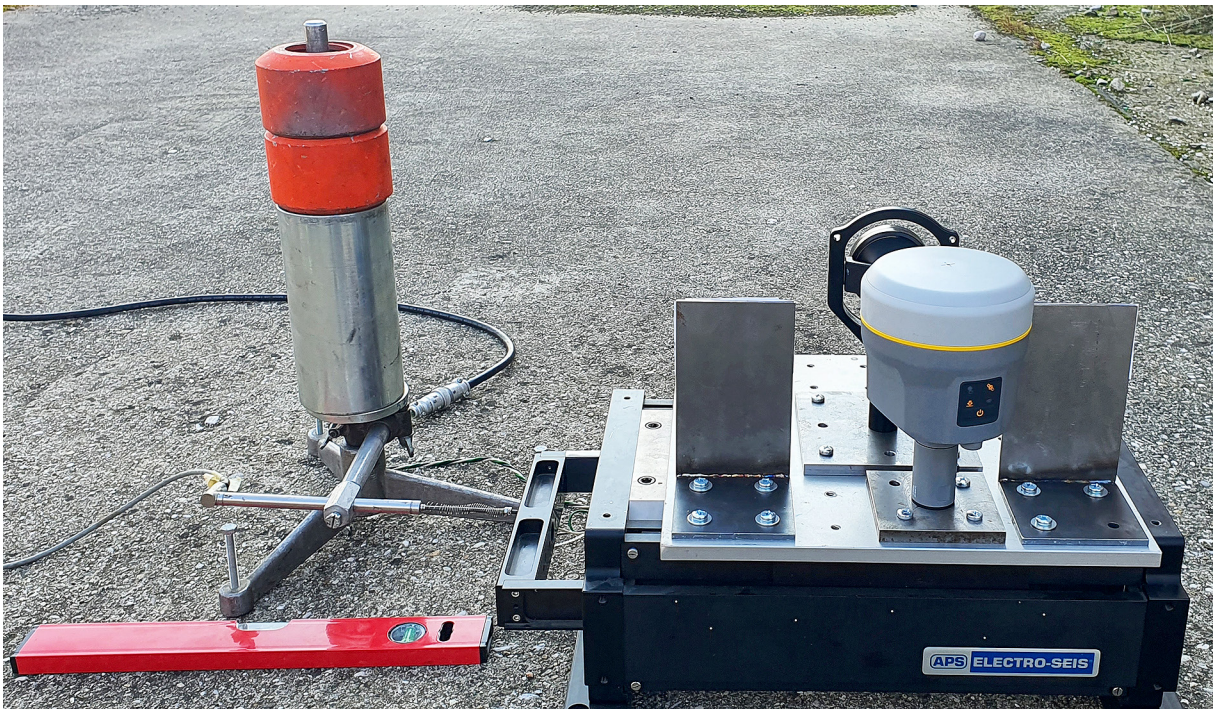
Slika 1: GNSS Trimble R12i (vlastita fotografija)

4. Metodologija ispitivanja

Testni postupak osmišljen je kao simulacija odaziva građevine na djelovanje dinamičkog opterećenja na nju, poput vjetra. Cilj ispitivanja je odrediti simulirane dinamičke pomake i vlastite frekvencije objekta korištenjem R12i, koji se pojavljuju uslijed djelovanja dinamičkih opterećenja.

4.1. Testni postupak

R12i testiran je za određivanje položaja točke u pokretu, u horizontalnoj ravnini. Testno ispitivanje je napravljeno na način da se korištenjem R12i određivao položaj točke koja izvodi harmonično gibanje s unaprijed zadanim vrijednostima.



Slika 2: Elektrodinamički pobuđivač s GNSS uređajem i induktivnim osjetilom (vlastita fotografija)

Odabrano testno područje nalazilo se na području Kampusa Borongaj Sveučilišta u Zagrebu. Na mjestu s otvorenim nebom postavljen je elektrodinamički pobuđivač i na njega je montirana sva potrebna oprema za ispitivanje (Slika 2). Elektrodinamički pobuđivač, zajedno s pojačalom i generatorom frekvencija, korištio se za ostvarivanje kontrolnih i unaprijed zadanih simuliranih dinamičkih pomaka. Na elektrodinamički pobuđivač postavljen je R12i. Prizma i ostali dodaci montirani na pobuđivač korišteni su za potrebe drugih istraživanja, koja ne ulaze u opseg ovoga rada. Vrijednosti zadanih amplituda kontrolirane su pomoću induktivnog osjetila (LVDT). Induktivnim osjetilima mogu se mjeriti pomaci i deformacije s točnošću od 10^{-3} mm (TE CONNECTIVITY SENSORS, 2017). Mjerna frekvencija LVDT-a iznosila je 100 Hz, a podaci mjerenja su pohranjeni na osobnom računalu. Izlazni podaci mjerenja LVDT-a sadrže podatke o apsolutom i relativnom trenutku mjerenja i položaju LVDT-a u određenom trenutku.

R12i bio je podešen na PPK način rada s frekvencijom mjerenja od 20 Hz. Za potrebe postizanja tražene frekvencije mjerenja, podaci mjerenja pohranjivani su direktno na unutrašnju memoriju uređaja. Izlazni podaci mjerenja R12i su sirovi podaci opažanja, s frekvencijom od 20 Hz, u razmjenskom Rinex formatu (IGS, 2012).

Kombinacije simuliranih amplituda i frekvencija osciliranja prikazane su u Tablici 1. Veće amplitude oscilacija, preko 40 mm, nisu se mogle ostvariti, jer bi one uzrokovale gibanje samog pobuđivača, što bi značajno utjecalo na preciznost mjerenja. Test za svaku kombinaciju amplitude i frekvencije trajao je minimalno 60 sekundi, kako bi se prikupio dovoljan broj mjernih točaka za svaki instrument.

Tablica 1: Kombinacije amplituda simuliranih elektrodinamičkim pobuđivačem s pripadajućim frekvencijama odrađenih u sklopu ispitivanja

Frekvencija [Hz]	Amplituda pomaka [mm]
0,5	5, 10, 20 i 40
1,0	5, 10, 20 i 40
2,0	5, 10, 20 i 40
5,0	5, 10 i 20

4.2. Obrada podataka mjerenja

Neobrađeni podaci mjerenja R12i izjednačeni su korištenjem modula za obradu GNSS mjerenja u softveru Trimble Bussines Center (TBC) (Trimble, 2022). Za potrebe obrade podataka korišteni su preuzeti podaci Virtualne Referentne Stanice (VRS) u RINEX 3.03. formatu (IGS, 2012) putem geodetski preciznog servisa pozicioniranja (GPPS) Croposa. Točnost određivanja koordinata korištenjem GPPS servisa je 1-4 cm (3D) (DGU, 2020). Kao metoda obrade podataka korištena je PPK. Prilikom izjednačenja korištene su Brze Efemeride (engl. Rapid Efemerides), koje su dostupne u roku od 12 sati nakon mjerenja. Izlazni podaci obrade podataka su 3D koordinate točaka u kartografskoj projekciji HTRS96 i apsolutno vrijeme u kojem su koordinate određene.

Za svu daljnju obradu podataka mjerenja LVDT-a i R12i korišten je programski paket Matlab 2021 (MATLAB, 2022). Prvi korak obrade bio je vremenska sinkronizacija podataka mjerenja dva uređaja, kako bi se odredili setovi mjerenja koji pridaju istim vremenskim intervalima, u kojima je pobuđivač imao oscilacije određene amplitude i frekvencije.

Setovi podataka za isti interval obrađivani su međusobno neovisno. Obrađeni podaci mjerenja R12i prebačeni su iz vremenskog u frekvencijsko područje korištenjem Welch-ovog periodograma (Welch, 1967) i brze Furijerove transformacije (FFT) (Boehme i dr., 1986) u svrhu određivanja frekvencija oscilacija. Iz spektralnih funkcija vrijednost frekvencije očitana je automatski korištenjem algoritma, kako bi se izbjegao utjecaj subjektivnosti opažača, prilikom ručnog očitavanja. Amplitude oscilacija određene su na temelju BEST-FIT funkcija i određene frekvencije oscilacija. Amplitude i frekvencije oscilacija za 3D koordinate iz mjerenja s R12i određene su za svaku koordinatu zasebno. Konačna amplituda gibanja određena je kao korijen sume amplituda gibanja po koordinatama.

Rezultati obrade podataka su za oba uređaja za svaki interval frekvencija i amplituda oscilacija. Podaci LVDT-a uzeti su kao referentni za usporedbu s podacima R12i. Rezultati obrade prikazani su u Tablici 2.

5. Rezultati

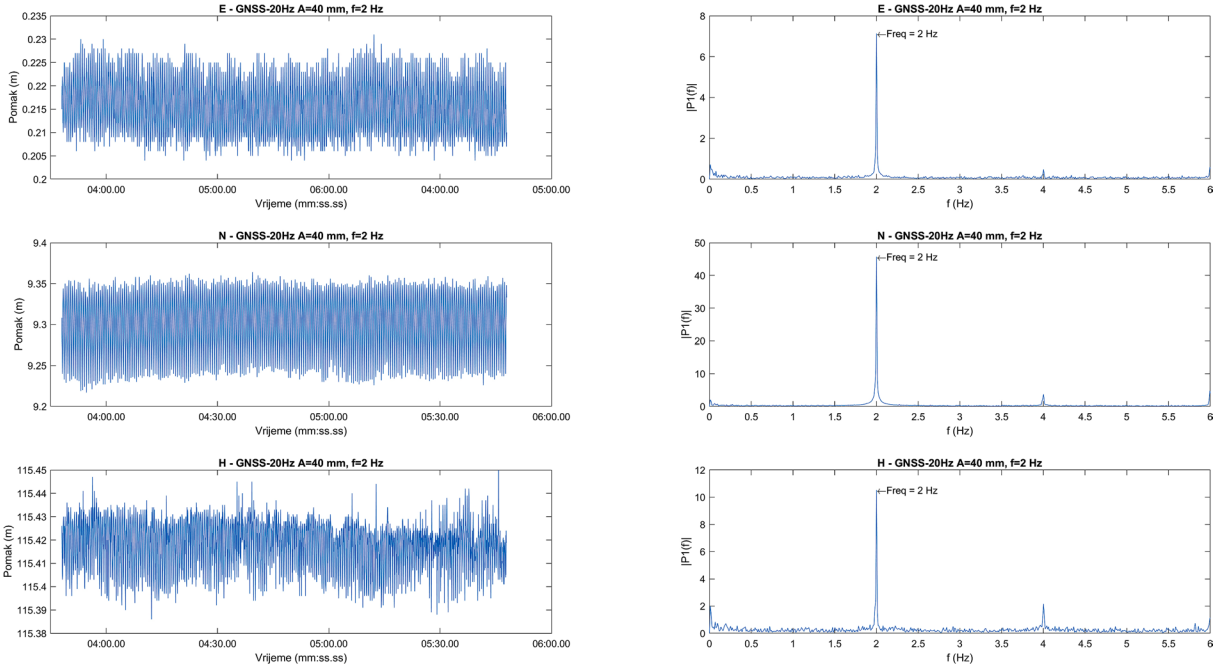
Referentne vrijednosti amplituda i frekvencija oscilacija određene su iz podataka mjerenje LVDT-a. Vrijednosti odstupanja su razlike između referentne amplitude i frekvencije i onih određenih iz podataka mjerenja R12i. Pregled svih rezultata, usporedbe referentnih amplituda, izraženih u mm i frekvencija, izraženih u Hz, prikazani su u Tablici 2. Dio rezultata mjerenja i određivanja frekvencija za zadanu amplitudu od 40 mm i frekvenciju od 2 Hz prikazan je na Slici 3 i za zadanu amplitudu od 5 mm i frekvenciju od 1 Hz prikazan je na Slici 4.

6. Zaključak

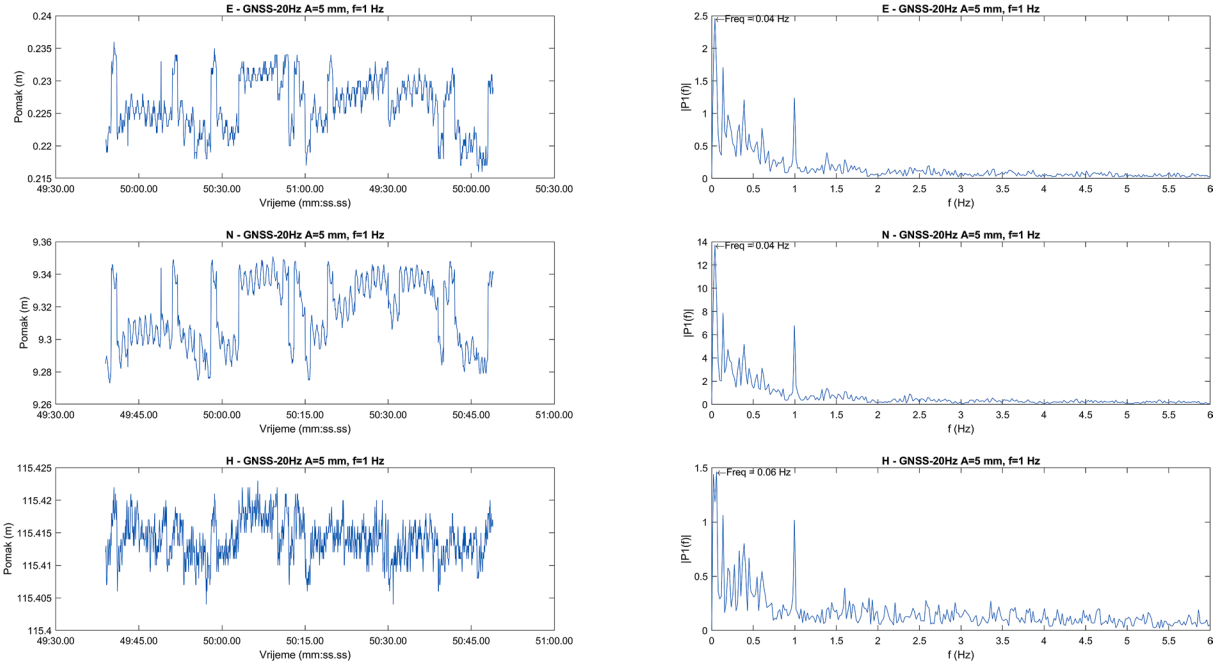
Prema prikazanim rezultatima određivanja amplituda i frekvencija simuliranih oscilacija, prikazanim u Tablici 1., može se zaključiti da se GNSS Trimble R12i, s frekvencijom mjerenja od 20 Hz, može uspješno koristiti za mjerenja dinamičkih pomaka i vlastitih frekvencija objekta za potrebe monitoringa građevina, kao što je prikazano na Slici 3. Ograničenje u korištenju R12i je određivanje pomaka iznosa ± 5 mm ili manjih, gdje, u PPK načinu rada, nije bilo moguće odrediti zadane frekvencije, kao što je prikazano na Slici 4 i vidljivo u rezultatima u Tablici 2. Na toliko malim pomacima, utjecaj šuma mjerenja onemogućuje precizno određivanje dinamičkih pomaka, samim time i frekvencija istih pomaka. U svim kombinacijama frekvencija, s pomacima većim od 5 mm, uspješno su i precizno određeni iznosi dinamičkih pomaka i frekvencije osciliranja. Ukoliko se primjeni Nyquistov teorem (Shannon, 1949) o frekvenciji mjerenja, može se zaključiti da se korištenjem R12i mogu mjeriti dinamički pomaci veći od 5 mm i koji imaju frekvenciju oscilacija do 10 Hz. Vrijednosti minimalnog pomaka od 5 mm je u skladu s izračunatom preciznošću određivanja 2D koordinata za R12i i PPK metodu. Odstupanja amplituda od referentnih vrijednosti su u skladu s preciznošću određivanja 3D koordinata za

Tablica 2: Usporedba referentnih vrijednosti i vrijednosti određenih iz podataka mjerenja R12i

Testni set 2. - "Dijagonalni pomak"					
Određena amplituda [mm]	Referentna amplituda [mm]	Odstupanje amplitude [mm]	Određena vlastita frekvencija [Hz]	Referentna frekvencija [Hz]	Odstupanje frekvencije [Hz]
41	40	1	0,50	0,50	0,00
33	40	-7	1,00	1,00	0,00
51	40	11	2,00	2,00	0,00
9	10	-1	0,50	0,50	0,00
12	20	-8	0,50	0,50	0,00
3	5	-2	0,50	0,50	0,00
13	10	3	1,00	1,00	0,00
16	20	-4	1,01	1,00	0,01
13	5	8	0,04	1,00	-0,96
15	10	5	2,00	2,00	0,00
28	20	8	2,00	2,00	0,00
9	5	4	1,01	2,00	-0,99
6	10	-4	5,00	5,00	0,00
15	20	-5	5,00	5,00	0,00
5	5	0	5,00	5,00	0,00



Slika 3: Rezultati uspješnog određivanja frekvencije pri oscilacijama sa amplitudom od 40 mm i frekvencijom od 2 Hz



Slika 4: Rezultati neuspješnog određivanja frekvencije pri oscilacijama sa amplitudom od 5 mm i frekvencijom od 1 Hz

R12i i PPK metodu. R12i i softver za obradu su komercijalno dostupni proizvodi od strane tvrtke Trimble, te je njihova primjena krajnje pojednostavljena i ne zahtjeva veliko predznanje. U daljnjim istraživanjima planira se obrada većeg broja setova podataka te detaljno ispitivanje utjecaja šuma mjerenja na ostvarive rezultate.

ZAHVALA - ACKNOWLEDGEMENT: This research is partially supported through project KK.01.1.1.02.0027, a project co-financed by the Croatian Government and the European Union through the European Regional Development Fund-the Competitiveness and Cohesion Operational Programme.

Literatura

Barnes, J., Rizos, C., Lee, H. K., Roberts, G. W., Meng, X., Cosser, E., & Dodson, A. H.(2005): The integration of GPS and pseudolites for bridge monitoring. International Association of Geodesy Symposia, 128, 83–88.

Boehme, T. K., & Bracewell, R. (1986): The Fourier Transform and its Applications. In The American Mathematical Monthly (Vol. 73). McGraw-Hill New York.

DGU (2020): Prilozi Pravilnika o načinu izvođenja osnovnih geodetskih radova, p. 121. Državna geodetska uprava.

IGS. (2012): RINEX: The Receiver Independent Exchange Format Version 3.03 International. IGS Workshop 2012, 104, 1–74.

Li, X. (2004): Integration of GPS, accelerometer and optical fiber sensors for structural deformation monitoring. Proceedings of the 17th International Technical Meeting of the Satellite Division of the Institute of Navigation, ION GNSS 2004, 211–224.

Marendić, A., Kapović, Z., & Paar, R. (2013): Mogućnosti geodetskih instrumenata u određivanju dinamičkih pomaka građevina. Geodetski List, 67 (90)(3), 175–190.

MATLAB (2022): version 9.10.0 (R2021a). Natick, Massachusetts: The MathWorks Inc.

Meng, X., Dodson, A. H., & Roberts, G. W. (2007): Detecting bridge dynamics with GPS and triaxial accelerometers. Engineering Structures, 29(11), 3178–3184.

Ogaja, C., Li, X., & Rizos, C. (2007): Advances in structural monitoring with Global Positioning System technology: 1997–2006. Journal of Applied Geodesy, 1(3).

Ogaja, C., Wang, J., & Rizos, C. (2003): Detection of wind-induced response by wavelet transformed GPS solutions. Journal of Surveying Engineering, 129(3), 99–104.

Roberts, G., Meng, X., & Dodson, A. (2001): The use of kinematic GPS and triaxial accelerometers to monitor the deflections of large bridges. 10th FIG International Symposium on Deformation Measurements, 268–275.

Shannon, C. E. (1949): Communication in the Presence of Noise. Proceedings of the IRE, 37(1), 10–21.

TE CONNECTIVITY SENSORS (2017): Linear variable differential transformer (LVDT).

Trimble (2022): Trimble Business Center Technical Notes.

Trimble Geospatial (2020): Trimble R12i Datasheet (p. 4). p. 4.

Welch, P. D. (1967): The Use of Fast Fourier Transform for the Estimation of Power Spectra. IEEE Transactions on Audio and Electroacoustics, (2), 70–73.

Wyn Roberts, G., Dodson, A., Roberts, G. W., Cosser, E., & Meng, X. (2004): Algorithms and Stochastic models for Positioning, Tracking and Navigation View project Shift2Rail View project High Frequency Deflection Monitoring of Bridges by GPS. Article in Journal of Global Positioning Systems, 3(1), 226–231.

Testing the Capabilities of 20 Hz GNSS PPK Measurements for Measuring Displacements and Natural High Frequencies of Objects

Abstract

Monitoring of constructions, buildings, or parts of the Earth's surface is an activity of periodic or continuous observations to estimate an object's general state, usability, and stability. The main objective of monitoring is to determine statistically significant deformations between two or more measuring epochs. Part of object monitoring is measuring the natural frequencies of objects. Any changes from the designed frequencies can be a sign of structural damage of construction or objects. The use of the newest generation of geodetic instruments enables the measurements of dynamic displacements of points in addition to measuring static displacements of points. The natural frequencies of objects can also be determined based on dynamic displacements of certain points in a time series. Within the scope of this paper, the achievable precision of determining the simulated dynamic displacements and natural frequencies using the Trimble's latest generation GNSS device, the R12i model was tested. GNSS device measurement data were collected at a frequency of 20 Hz. The method of collecting raw GNSS device measurement data and subsequent processing of measurements is Post-Processed Kinematic (PPK) method. The tests consisted of determining the simulated dynamic displacements with frequencies from 0,5 Hz to 5,0 Hz and amplitudes of motion from 5 mm to 40 mm. The displacements were simulated using a long stroke shaker, while the displacement reference values were measured using an inductive sensor (LVDT). Part of the test results of determining the dynamic displacements and natural high frequencies are presented in this paper.

Keywords: *dynamic displacements, monitoring, natural frequencies, PPK, Trimble GNSS R12i*

SESIJA 5

Uređenje morskog okoliša

Prostorno planiranje morskih područja i granice na moru

Bojan Linardić[1], Robert Paj[2], Margareta Premužić[3], Ivan Landek[4]

[1] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, bojan.linardic@mpgi.hr

[2] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, robert.paj@mpgi.hr

[3] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, margareta.premuzic@mpgi.hr

[4] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, ivan.landek@mpgi.hr

Sažetak

Europska komisija je 2012. usvojila dokument „Plavi rast – mogućnosti za održivi rast mora i pomorstva", kojim se ističe važnost mora i obale za ukupno gospodarstvo Europske unije i potiče iskorištavanje neiskorištenog potencijala europskih oceana, mora i obala za otvaranje novih radnih mjesta, istraživanje, razvoj i rast. Dok se neki sektori, poput pomorskog prometa, već potiču kroz druge europske inicijative, „Plavi rast" fokusiran je na pet sektora: plavu energiju, akvakulturu, pomorski, primorski i kruzing turizam, morske mineralne resurse i plavu biotehnologiju. Sve navedene aktivnosti vezane su uz prostor mora, a kako bi se zaštitio okoliš i ostvarili maksimalni učinci, nužno je kvalitetno prostorno planiranje. U radu je podrobnije opisana ova inicijativa, koja je za Hrvatsku, kao pomorsku zemlju, od izuzetnog značaja. Naglasak je stavljen na EU Direktivu 2014/89/EU o uspostavi okvira za prostorno planiranje morskih područja (MSP) i njezin prijenos u hrvatsko zakonodavstvo te obveze koje iz nje proizlaze. U radu se prikazuje postojeći sustav prostornog planiranja i očekivane promjene koje će donijeti novi propisi, a poseban naglasak stavljen je na pitanje unutarnjih granica na moru.

Ključne riječi: *EU direktiva, granice na moru, MSP, prostorno planiranje*

1. Uvod

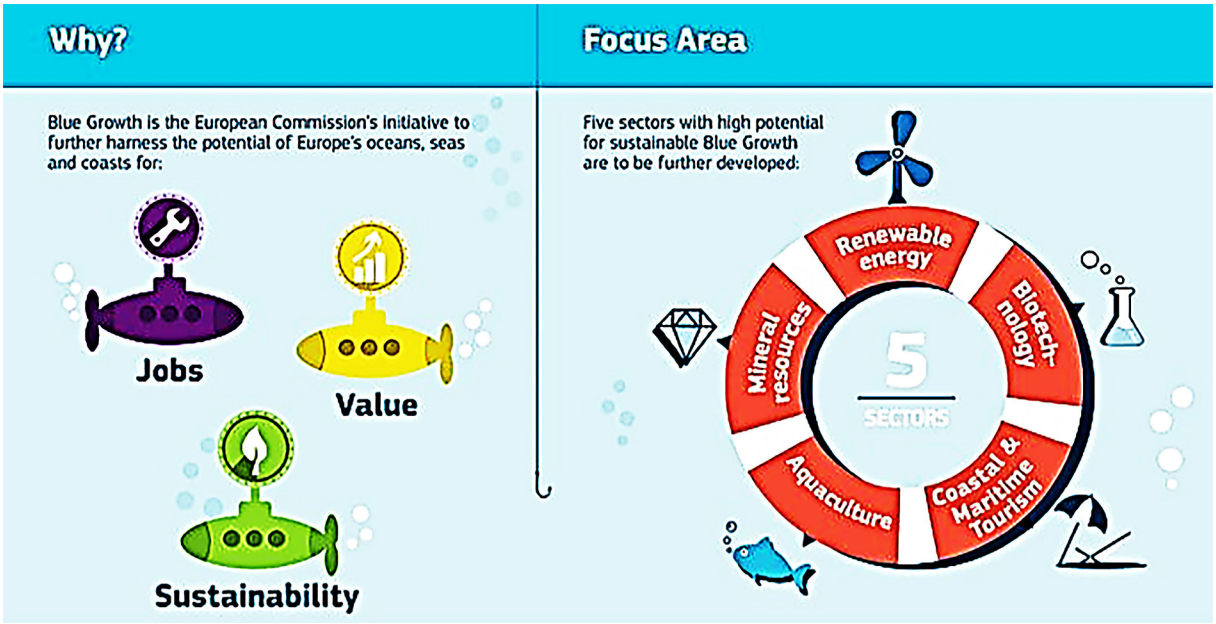
Nakon globalne financijske krize 2008., Europska komisija u ožujku 2010. godine usvaja Strategiju za pametan, održiv i uključujući rast Europa 2020. U Strategiji su istaknuti glavni ciljevi kojima bi se povećao održivi rast europskog gospodarstva u predstojećem desetljeću, a koji uključuju: povećanje zapošljavanja, istraživanje i razvoj, ekologiju, povećanje stupnja obrazovanja i smanjenje siromaštva europskih građana.

Čak 22 od 27 država članica EU ima morsku obalu, a dvije trećine europskih granica su granice na moru. Prema podacima iz 2019. godine „Plava ekonomija" u EU obuhvaća 4,45 milijuna radnih mjesta, godišnju promet od oko 667 milijardi eura i bruto dodanu vrijednost od oko 184 milijarde eura (URL 1). Oko 75% europskog izvoza se prevozi pomorskim putem, kao i oko 37% unutarnjeg prometa roba u EU (URL 2). Razna područja ljudskog djelovanja na moru (npr. pomorsko gospodarstvo, transport, brodogradnja i dr.) predmeti su raznih politika koje se provode na razini Europske unije. Godine 2008. donosi se „Integrirana pomorska politika" (IPP) EU, koja predstavlja holistički pristup svim politikama EU-a koje se odnose na more. Temelji se na ideji da Unija može ostvariti veću korist od svog pomorskog prostora uz manji utjecaj na okoliš koordiniranjem svog širokog spektra međusobno povezanih aktivnosti povezanih s oceanima, morima i obalama. Cilj IPP-a je jačanje tzv. plave ekonomije, koja obuhvaća sve gospodarske aktivnosti na moru.

U okviru IPP-a, 2012. godine Europska komisija usvaja dokument „Plavi rast – mogućnosti za održivi rast mora i pomorstva" (URL 2). Kako se navodi, dokument predstavlja pomorsku dimenziju Europe 2020 i treba doprinijeti međunarodnoj kompetitivnosti EU, optimalnom korištenju resursa, stvaranju radnih mjesta i novih izvora rasta, uz očuvanje bioraznolikosti i zaštitu morskog okoliša. Kako su neki sektori „plave ekonomije" (npr. pomorski promet i ribarstvo) pokriveni drugim europskim sektorskim politikama, „Plavi rast" se usredotočio na pet sektora: plava energija, akvakultura, pomorski, primorski i kruzing turizam, morski mineralni resursi i plava biotehnologija (Slika 1).

2. EU Direktiva 2014/89/EU

Sve veći utjecaj ljudi na mora i oceane, kao i rastuća potražnja za morskim prostorom za potrebe raznih komercijalnih (ribarstvo, turizam, energija i dr.) i nekomercijalnih (ekologija, klimatologija dr.) djelatnosti, povećava potrebu za planskim upravljanjem prostorom mora. Stoga EU Parlament i Vijeće donose 23.



Slika 1: Dio info-grafike „Plavi rast" Europske komisije (izvor: URL 3).

srpnja 2014. Direktivu 2014/89/EU (URL 4) o uspostavi okvira za prostorno planiranje morskog područja. Ovom Direktivom nastoji se promicati održiv rast pomorskih gospodarstava i korištenje morskih resursa boljim upravljanjem konfliktima i većom sinergijom između različitih pomorskih aktivnosti. Direktiva se u preambuli poziva na ranije navedene, kao i druge dokumente i politike EU vezane uz morska područja i obalu te se navodi da će prostorno planiranje morskog područja pridonijeti učinkovitom upravljanju pomorskim aktivnostima i održivom korištenju morskih i obalnih resursa stvaranjem okvira za dosljedno, transparentno, održivo i na dokazima utemeljeno odlučivanje, uz očuvanje i poboljšanje stanja okoliša. Direktiva traži od država članica uspostavu i vođenje prostornog planiranja morskih područja, pri čemu je potrebno u obzir uzeti interakciju kopna i mora, ali ostavlja slobodu članicama u osmišljavanju i određivanju opsega, sadržaja, formata i opsega primjene prostornih planova područja mora. Traži se suradnja država članica koje dijele morske vode, kako bi se osigurala usklađenost i koordiniranost prostornih planova morskog područja širom dotične morske regije. Propisano je da svaka država članica odredi tijelo ili više tijela koja su nadležna za provedbu direktive, kao i da se kopije prostornih planova morskih područja s relevantnim dokumentima dostavljaju Europskoj komisiji. Države članice dužne su donijeti zakonske i druge propise potrebne za usklađenje s direktivom do 18. rujna 2016., a prostorne planove izraditi i donijeti što je prije moguće, a najkasnije do 31. ožujka 2021. godine.

Države članice na koje se odnosi direktiva imale su različiti pristup uvođenju direktive u nacionalno zakonodavstvo, gdje su neke države donosile posebne zakonske i podzakonske akte ili druge dokumente zakonske snage, dok je većina prostorno planiranje područja mora ugradila u postojeće zakone koji pokrivaju područje prostornog planiranja ili mora i okoliša. Kao nadležna tijela za provođenje direktive, države članice uglavnom su odredile ministarstva nadležna za okoliš, more, prostorno planiranje, regionalni razvoj ili infrastrukturu, a nekoliko država je nadležnost spustilo na nivo uprava. Zanimljivo je da je nadležno tijelo za provedbu direktive u Estoniji ministarstvo financija.

3. Ukratko o sustavu prostornog uređenja u Republici Hrvatskoj

Sustav prostornog uređenja RH uređen je Zakonom o prostornom uređenju (Narodne novine, 2013). Zakonom su propisani: ciljevi, načela i subjekti prostornog uređenja, praćenje stanja i uvjeti planiranja prostora, prostorni planovi, njihova izrada, postupak donošenja i provedba i dr. Prema Zakonu, stručne poslove prostornog uređenja za državu obavlja Ministarstvo putem Zavoda za prostorni razvoj, a za županije (i Grad Zagreb) obavljaju zavodi za prostorno uređenje županija (i Grada Zagreba). Veliki gradovi imaju mogućnost osnivanja gradskog zavoda za prostorno uređenje, a za manje gradove i općine, stručne poslove prostornog planiranja obavljaju stručne osobe i tvrtke ovlaštene prema Zakonu o poslovima i djelatnostima prostornog uređenja i gradnje (Narodne novine, 2015). Za potrebe izrade, donošenja, provedbe i nadzora prostornih planova, trajnog praćenja stanja u prostoru i području prostornog uređenja te izrade izvješća o stanju u prostoru, uspostavljen je informacijski sustav prostornog uređenja (ISPU).

4. Uvođenje Direktive 2014/89/EU u hrvatsko zakonodavstvo

Nadležnost za provođenje Direktive 2014/89/EU u Republici Hrvatskoj pripala je Ministarstvu prostornoga uređenja, graditeljstva i državne imovine, a

Direktiva je uvedena u zakonsku regulativu kroz izmjene i dopune Zakona o prostornom uređenju, koje su usvojene u srpnju 2017. godine. Zakonom o prostornom uređenju propisano je da se prostorni planovi donose se na državnoj, područnoj (regionalnoj) i lokalnoj razini, tako da je promjenama zakona ranije propisanim prostornim planovima pridodana i komponenta planiranja morskog područja. Tako je propisano da se morsko područje planira:

1. državnim planom prostornog razvoja,
2. prostornim planom zaštićenog ekološkog i ribolovnog područja,
3. prostornim planom epikontinentalnog pojasa Republike Hrvatske,
4. prostornim planovima nacionalnih parkova i parkova prirode koji obuhvaćaju morsko područje,
5. prostornim planovima županija koje obuhvaćaju morsko područje i prostornim planovima uređenja gradova, odnosno općina, unutar njihovih granica određenih sukladno posebnim propisima i prikazanim u Registru prostornih jedinica koji se vodi na temelju posebnih propisa kojima se uređuje državna izmjera i katastar nekretnina,
6. generalnim urbanističkim planovima i urbanističkim planovima uređenja koji obuhvaćaju morsko područje.

Pri tome treba posebno obratiti pažnju na točku 5. gdje je navedeno da su granice lokalne i regionalne samouprave određene sukladno posebnim propisima i prikazane u Registru prostornih jedinica koji se vodi na temelju posebnih propisa kojima se uređuje državna izmjera i katastar nekretnina, što je opisano u nastavku. U izmjenama i dopunama Zakona, uz općenite upute o izradi i donošenju prostornih planova morskog područja, propisana je suradnja sa susjednim državama, kao i dostava prostornih planova morskih područja Europskoj komisiji.

5. Granice na moru – Republika Hrvatska

Republika Hrvatska je pomorska zemlja s izrazito razvedenom obalom i velikim brojem otoka, otočića i hridi. Ukupna duljina obalne crte je oko 5835 km, od čega 1777 km obale kopna i 4058 km obale otoka (URL 5). Područje hrvatskog dijela Jadranskog mora obuhvaća epikontinentalni pojas, zaštićeni ekološko-ribolovni pojas (ZERP), teritorijalno more i unutarnje vode. Granica epikontinentalnog pojasa utvrđena je sporazumom Jugoslavije i Italije iz 1968. godine i određena je po načelu ekvidistancije, odnosno kao „crta sredine". Vanjska granica ZERP-a privremeno je određena po granici epikontinentalnog područja dok se ne utvrdi međunarodnim ugovorom sa susjednim državama, a granica teritorijalnog mora 12 morskih milja od početne linije (vanjske granice unutarnjih voda). Bočne granice na moru prema republikama Sloveniji i Crnoj Gori nisu bilateralno utvrđene, a morska granica s Bosnom i Hercegovinom utvrđena je sporazumom iz 1999. godine (Klemenčić i Topalović, 2009). Odlukom Hrvatskog sabora, 2021. godine je proglašen isključivi gospodarski pojas Republike Hrvatske u Jadranskom moru u privremenim granicama koje odgovaraju granicama ZERP-a. Konačne granice utvrditi će se međunarodnim ugovorima o razgraničenju sa susjednim državama.

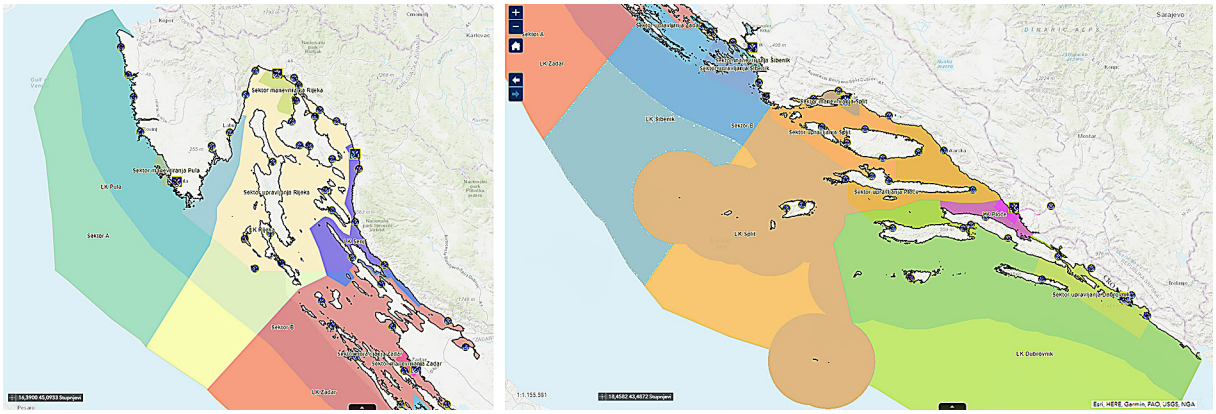
Na Jadranskom moru su tri nacionalna parka (Brijuni, Kornati i Mljet), koji obuhvaćaju i područje mora na udaljenosti od 500 m do 1 morske milje od obale, a granice su definirane opisno (u posebnom zakonu za svaki nacionalni park) i ucrtane na topografskoj karti 1:25 000.

6. Granice na moru – Jedinice regionalne i lokalne samouprave

Uz hrvatsku obalu Jadranskog mora prostire se 7 županija i 120 gradova i općina (Pribičević, 2005). Kako bi se moglo provesti prostorno planiranje morskih područja na regionalnom (županijskom) i lokalnom (gradovi i općine) nivou, nužno je znati i granice područja za koja se prostorno planiranje provodi. Međutim, granice na moru županija, gradova i općina nisu nikada službeno utvrđene!

U Zakonu o područjima županija, gradova i općina u Republici Hrvatskoj (Narodne novine, 2006), granice županija nisu posebno definirane, već se samo navode općine i gradovi koji su u sastavu županije. Istim Zakonom, definirano je da granice između općina, odnosno gradova predstavljaju u pravilu granice rubnih katastarskih općina, osim ako se granice rubnih katastarskih općina ne podudaraju s granicama rubnih naselja. U tom slučaju smatra se da granicu predstavlja granica rubnih naselja prikazana u službenoj evidenciji prostornih jedinica.

Službena evidencija prostornih jedinica u Republici Hrvatskoj je Registar prostornih jedinica (RPJ). Zakonom o državnoj izmjeri i katastru nekretnina (Narodne novine, 2018a) propisano je da je Državna geodetska uprava (DGU) nadležna za uspostavu i vođenje katastra nekretnina. U istom Zakonu se navodi da se u RPJ vode podaci o: državi, županiji, Gradu Zagrebu, gradu, općini, naselju, dostavnom području poštanskog ureda, jedinici mjesne samouprave, zaštićenim područjima, katastarskoj općini, statističkome krugu, popisnome krugu, ulici i trgu, zgradi i pripadajućim kućnim brojevima te o drugim prostornim jedinicama za koje je to određeno posebnim propisima. U Pravilniku o RPJ (Narodne novine, 2020) uz prostorne jedinice navedene u zakonu, izričito se navode i katastarska područja na moru, a propisuje se i da se u svrhu iskazivanja pripadnosti otoka, otočića i hridi jedinicama lokalne samouprave u grafičkom dijelu registra prikazuju linije iz kojih ova pripadnost postaje vidljiva, ali da te linije nisu granice jedinica lokalne samouprave na moru.



Slika 2: Granice lučkih kapetanija (izvor: HHI, Portal GeoAdriatic).

7. Granice lučkih kapetanija

U Zakonu o lučkim kapetanijama (Narodne novine, 2018b) navodi se da lučke kapetanije obavljaju poslove sigurnosti plovidbe za područja pojedinih županija te se granice lučkih kapetanija navode opisno. Granice ucrtane prema opisu iz zakona najčešće se koriste pri prikazivanju granica županija na moru, ali i tu često postoje odstupanja. Tako se, na primjer, morsko područje Splitsko-dalmatinske županije često prikazuje s odvojenim dijelom oko otoka Palagruže, dok je prema opisu iz zakona to jedno, neprekinuto morsko područje (Slika 2).

8. Katastarsko područje na moru

U Zakonu o državnoj izmjeri i katastru nekretnina iz 1999. godine uveden je pojam katastarskog područja na moru, koje obuhvaća obalno more (unutarnje morske vode i teritorijalno more) i epikontinentalni pojas Republike Hrvatske. Novim Zakonom iz 2018. godine katastarsko područje na moru prošireno je i na dio kopna koji je u režimu pomorskog dobra. Također, Zakonom iz 1999. propisano je da područje i ime katastarske općine odnosno katastarskog područja na moru određuje DGU u sporazumu s ministrom nadležnim za poslove pravosuđa, dok je u Zakonu iz 2018. godine (i izmjenama iz 2021.) katastarsko područje na moru odvojeno od katastarske općine, tako da područje, granice i ime katastarskog područja na moru određuje odlukom glavni ravnatelj, uz prethodnu suglasnost ministra nadležnog za poslove mora. U Zakonu se navodi i da se jedinstveni identifikator katastarske čestice sastoji od matičnog broja katastarske općine, odnosno katastarskog područja na moru i broja katastarske čestice.

Iako je katastarsko područje na moru propisano već više od 20 godina, nikada nije stvarno utvrđeno ni detaljnije pojašnjeno što točno predstavlja. Iz navoda u Pravilniku o sadržaju i obliku katastarskog operata katastra nekretnina (Narodne novine, 2008), kojim je propisano da se imena katastarskih područja na moru određuju prema imenima jedinica regionalne samouprave, može se pretpostaviti da se katastarsko područje na moru odnosi na morsko područje županija. U praksi se katastarske čestice u moru ili katastarske čestice pomorskog dobra numeriraju unutar najbliže katastarske općine na kopnu (Slika 3).



Slika 3: Primjer katastarske čestice na moru koja je numerirana unutar katastarske općine (izvor: katastar.hr).

9. Zaključak

Iako se Direktivom 2014/89/EU to posebno ne traži, Republika Hrvatska je zakonom propisala prostorno planiranje morskih područja na svim nivoima (od državnog do lokalnog), što predstavlja značajan izazov za hrvatske prostorne planere, kao i za nositelje izrade prostornih planova. S obzirom na preuzete obveze, ali i imperative i ciljeve koje si kao uređeno društvo postavljamo i želimo doseći, pitanje unutarnjih granica na moru trebalo bi pokrenuti s mrtve točke i riješiti u dogledno vrijeme. Prvi korak bit će rješavanje morskih granica županija, koje su donekle već utvrđene kroz Zakon o lučkim kapetanijama, ali ih treba i formalno-pravno usvojiti. Rješavanje granica gradova i općina na moru predstavlja složenije pitanje, koje zahtjeva suradnju državnih, regionalnih i lokalnih institucija. Državna geodetska uprava, koja mora biti uključena u te procese, također treba pokrenuti rješavanje pitanja katastarskih područja na moru, jer postojeća praksa postupanja katastarskih ureda nije u skladu sa zakonskim propisima.

Literatura

Klemenčić, M., Topalović, D. (2009): Morske granice u Jadranskom moru, Geoadria, 14 (2), 311–324.

Narodne novine (2006): Zakon o područjima županija, gradova i općina u Republici Hrvatskoj, br. 86/06, 125/06, 16/07, 95/08, 46/10, 145/10, 37/13, 44/13, 45/13 i 110/15, Zagreb.

Narodne novine (2008): Pravilnik o sadržaju i obliku katastarskog operata katastra nekretnina, br. 142/08, 148/09, Zagreb.

Narodne novine (2013): Zakon o prostornom uređenju, br. 153/13, 65/17, 114/18, 39/19, 98/19, Zagreb.

Narodne novine (2015): Zakon o poslovima i djelatnostima prostornog uređenja i gradnje, br. 78/15, 118/18, 110/19, Zagreb.

Narodne novine (2018a): Zakon o državnoj izmjeri i katastru nekretnina, br. 112/18, 39/22, Zagreb.

Narodne novine (2018b): Zakon o lučkim kapetanijama, br. 118/18, Zagreb.

Narodne novine (2020): Pravilnik o Registru prostornih jedinica, br. 37/20, Zagreb.

Pribičević, B. (2005): Pomorska geodezija, Geodetski fakultet Sveučilišta u Zagrebu, Zagreb.

URL 1: Publications Office of the European Union,

https://ec.europa.eu/oceans-and-fisheries/publications/eu-blue-economy-report-2022_en, (20.7.2022.).

URL 2: EUR-Lex,

https://eur-lex.europa.eu/legal-content/EN/ALL/?uri=CELEX%3A52012DC0494, (20.7.2022.).

URL 3: European Commission – Blue Growth,

https://ec.europa.eu/assets/mare/infographics/, (20.7.2022.).

URL 4: Službeni list Europske unije, Direktive,

https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32014L0089&from=EN, (20.7.2022.).

URL 5: Geografija.hr, Koliki je indeks razvedenosti obalne crte Hrvatske?

https://geografija.hr/koliki-je-indeks-razvedenosti-obalne-crte-hrvatske-2/, (20.7.2022.).

Maritime Spatial Planning and Borders at Sea

Abstract

In 2012, the European Commission adopted the document "Blue Growth opportunities for marine and maritime sustainable growth", which emphasizes the importance of the sea and the coast for the overall economy of the European Union and encourages the use of the unused potential of the European oceans, seas and coasts for the creation of new jobs, research, development and growth. While some sectors, such as maritime transport, are already encouraged through other European initiatives, "Blue Growth" is focused on five sectors: blue energy, aquaculture, maritime, coastal and cruise tourism, marine mineral resources and blue biotechnology. All the mentioned activities are related to the sea area, and in order to protect the environment and achieve maximum effects, high-quality spatial planning is necessary. This initiative, which is extremely important for Croatia as a maritime country, is described in more detail in the paper. Emphasis is placed on the EU directive 2014/89/EU on establishing a framework for maritime spatial planning (MSP) and its transfer into Croatian legislation and the obligations arising from it. The paper presents the existing system of spatial planning and the expected changes that will be brought about by the new regulations, with special emphasis placed on the issue of internal borders at sea.

Keywords: *borders at sea, EU directive, MSP, spatial planning*

Mogućnosti primjene programa Copernicus za potrebe prostornog planiranja Republike Hrvatske

Bojan Linardić[1], Margareta Premužić[2], Robert Paj[3], Ivan Landek[4]

[1] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, bojan.linardic@mpgi.hr

[2] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, margareta.premuzic@mpgi.hr

[3] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, robert.paj@mpgi.hr

[4] Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, Zavod za prostorni razvoj, Ulica Republike Austrije 14, Zagreb, Hrvatska, ivan.landek@mpgi.hr

Sažetak

Upravljanje razvojem i planiranje kako kopnenog tako i morskog te obalnog područja vrlo je važno za razvoj cijele Zemlje. U hrvatskom sustavu prostornog uređenja planira se kopneno i morsko područje, a prostorno planiranje morskih površina tradicionalno je sastavni dio prostornog planiranja u Republici Hrvatskoj i obuhvaća većinu tema i zahtjeva uključenih u Europske i međunarodne propise, primarno Direktivu o uspostavi okvira za prostorno planiranje morskih područja (MSP – Maritime Spatial Planning) – 2014/89/EU. Prostorno planiranje je sve više pod povećanim zahtjevima od strane različitih subjekata i direktiva kao što je implementacija strategije Plavog razvoja koja potiče održivi razvoj mora i morskog sektora. U svrhu dobrog upravljanja neophodno je prikupiti vrlo precizne informacije o prostoru. Parametri koji se odnose na morski okoliš brzo se mijenjaju, a njihovo se praćenje temelji na opsežnim podacima o promatranju u stvarnom vremenu. Promatranje Zemlje sa satelita potencijalno je važan izvor informacija za praćenje morskog okoliša i za razvoj morskog gospodarstva. Zahvaljujući svojem kapacitetu za satelitsko opažanje i praćenje promjena svjetskih oceana i regionalnih mora, program za opažanje Zemlje Copernicus, kao jedna od glavnih inicijativa svemirske politike Europske unije i Europske svemirske agencije, omogućuje prikupljanje preciznih podataka o Zemlji i pomaže u praćenju prostora kopna te oceana i mora. Program Copernicus omogućio je da satelitski podaci opažanja Zemlje postanu dostupni svima, čime se otvaraju nove mogućnosti i za izradu prostornih analiza i bolje planiranje prostora te donošenje odluka od strane nacionalnih i lokalnih vlasti. Program sa svojim servisima omogućuje široki spektar promjena u prostornom planiranju, a u kombinaciji s drugim izvorima informacija (in-situ mjerenja, daljinska istraživanja) može doprinijeti nacionalnim i lokalnim samoupravama u poboljšanju njihove dostupnosti i ažurnosti. Podaci sa satelita koriste se za periodično osvježavanje informacija o Zemlji što predstavlja moćan alat i za prostorno planiranje. Prostornom i vremenskom rezolucijom koju pružaju Copernicus Sentinel misije, moguće je koristiti u širokom spektru primjena za prostorno planiranje. U ovom radu opisani su načini kojima Copernicus podaci mogu doprinijeti pri upravljanju prostorom, ali i njegovu razvoju s naglaskom na primjene u obalnom i morskom prostornom planiranju te primjeni MSP Direktive.

Ključne riječi: *Copernicus, MSP, prostorno planiranje*

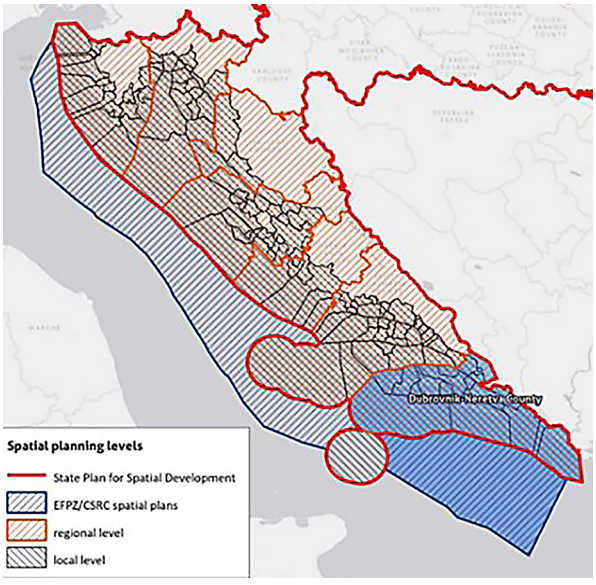
1. Uvod

Prostorno planiranje ključni je instrument upravljanja prostornim razvojem u sustavu prostornog uređenja. Planiranje razvoja i korištenja prostora zahtijeva interdisciplinarni pristup, pri čemu prostorni plan nije samo usklađivanje neovisnih cjelina, već podrazumijeva funkcionalnu suradnju i međusobnu metodičku prilagodbu te objedinjavanje različitih znanosti i struka na istom zajedničkom zadatku. Sustav prostornog uređenja u Republici Hrvatskoj definiran je Zakonom o prostornom uređenju (Narodne novine, 2013) i podzakonskim aktima. Izrada i donošenje Državnog plana prostornog razvoja određeni su Zakonom o prostornom uređenju. Strategija prostornog razvoja Republike Hrvatske (Narodne novine, 2017) temeljni je državni dokument za usmjerenje razvoja u prostoru. U srpnju 2017. godine stupila je na snagu izmjena i dopuna ovog Zakona, kojom je ujedno omogućen potpuni prijenos EU MSP (Maritime Spatial Planning) Direktive u zakonodavstvo Republike Hrvatske. Direktiva o uspostavi okvira za prostorno planiranje morskih područja MSP – 2014/89/EU donesena je 23. srpnja 2014. U članku 3. Europske direktive 2014/89/EU propisano je da pomorsko prostorno planiranje znači proces kojim relevantna

tijela država članica analiziraju i organiziraju ljudske aktivnosti u morskim područjima radi postizanja ekoloških, gospodarskih i društvenih ciljeva. Samo jasna ukupna vizija korištenja morskog prostora i morskih resursa osigurava njegovo učinkovitije korištenje, a sve u skladu s nacionalnim i internacionalnim ciljevima. Planiranje je dinamička djelatnost, a zbog novih spoznaja u vezi s učincima pojedinih aktivnosti te promjenama u prirodnim sustavima Zemlje i mora, zahtijeva kontinuirano praćenje i ocjenjivanje. Promjena društvenih, ekonomskih i političkih uvjeta tijekom vremena također utječe na postupak prostornog planiranja. Suvremene metode korištene kod MSP procesa zahtijevaju povezivanje s podatkovnim infrastrukturama iz globalnih inicijativa kao što je Copernicus, program Europske unije za promatranje Zemlje kao i drugima inicijativama, npr. IODE2 (International Oceanographic Data and Information Exchange) i EMODnet4 (European Marine Observation and Data Network), koje mogu značajno doprinijeti procesu prostornog planiranja. Podatkovni proizvodi dobiveni iz globalnih/međunarodnih inicijativa obično imaju širu pokrivenost od područja planiranja, ali često pružaju manje detaljne informacije. Za usporedbu, podaci dobiveni na regionalnoj i lokalnoj razini, razvijeni kroz znanstveno-stručne institucije i projekte, mogu pružiti višu razinu detalja, ali mogu pokriti puno manja područja od opsega plana morskog područja. Stoga je potrebno uključiti informacije iz globalnih i međunarodnih inicijativa, dopunjene lokalnim podacima i informacijama, čime se osigurava najbolja moguća pokrivenost u smislu prostornog opsega i razine detalja potrebnih za definiranje uvjeta za planiranje. Trenutno ne postoji jedinstveni MSP plan za cijelo hrvatsko morsko područje, već je čitavo područje Republike Hrvatske obuhvaćeno različitim područnim i lokalnim prostornim planovima koji obuhvaćaju i kopnena i morska područja.

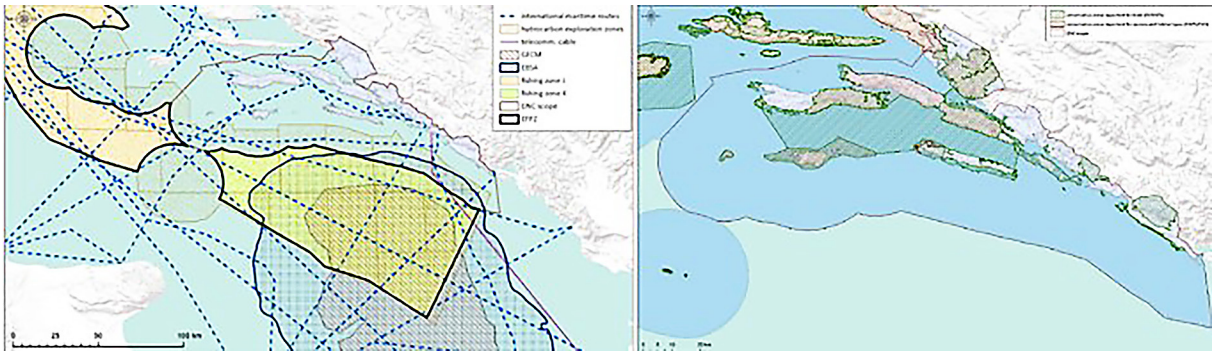
2. Studija prostornog planiranja područja Dubrovačko-neretvanske županije

U skladu s odredbama Zakona o prostornom uređenju, donesena je Odluka o izradi Državnog plana prostornog uređenja za cijelo kopneno i morsko područje (do vanjske granice teritorijalnih voda) Republike Hrvatske (Narodne novine, 2018). U sklopu SUPREME (Supporting maritime spatial Planning in the Eastern Mediterranean) projekta, obavljena je studija prostornog područja Dubrovačko-neretvanske županije, a koja uključuje prostorno-statističku analizu stanja morskog i obalnog područja Dubrovačko-neretvanske županije, a sama analiza usklađena je s kategorijama mora iz Direktive 2014/89/EU. Podkomponenta također predviđa pregled razvojnih ciljeva i vizija na regionalnoj, nacionalnoj i europskoj razini kako bi se identificirao najpristupačniji oblik prostornog razvoja u skladu s općim strateškim okvirom. Projektna razina studije prilagođena je postojećem napretku i uspješnosti prostornog planiranja mora jer je Republika Hrvatska već integrirala i implementirala prostorno planiranje mora kroz postojeći sustav temeljen na Zakonu o prostornom uređenju. Na europskoj razini postoji snažan pritisak da se pospješi rast sektora pomorskog gospodarstva. Prema inicijativi Plavi rast Europske komisije postoji značajan potencijal u europskim oceanima, morima i obalama i kada su osigurana odgovarajuća ulaganja i istraživanja, pomorski sektori mogu pridonijeti međunarodnoj konkurentnosti EU-a, otvaranju radnih mjesta i novim izvorima rasta, istovremeno čuvajući biološku raznolikost i zaštitu okoliša mora. Velika i brzo rastuća potražnja za pomorskim prostorom za različite namjene postavila je pitanje cjelovitog planiranja i upravljanja morima. Direktiva o uspostavljanju okvira za pomorsko prostorno planiranje iz 2014. godine stavlja za cilj da svaka država članica EU uspostavi i provede proces pomorskog prostornog planiranja, koji će rezultirati pomorskim prostornim planom ili planovima. Propisi vezani za korištenje morskih područja postoje, ali su rađeni postupno i pretežno unutar pojedinih sektora, kao što su pomorstvo i luke, ribarstvo i dr. Neophodno je stoga obaviti analize u svrhu izbjegavanja preklapanja ili potencijalnih konflikata te procijeniti kumulativne učinke na prostor (European MSP Platform, 2022). Prema MSP Direktivi obavljena je analiza prostornog područja Dubrovačko-neretvanske županije prema razinama prostornog planiranja u Republici Hrvatskoj (Slika 1), a koja sadrži: Državni plan prostornog razvoja koji je u postupku donošenja i državni plan Ekološko-ribolovnog zaštićenog područja i Kontinentalnog pojasa Republike Hrvatske.



Slika 1: Analize prostornog područja Dubrovačko-neretvanske županije u relaciji s razinama prostornog planiranja (SUPREME Case Study, 2018).

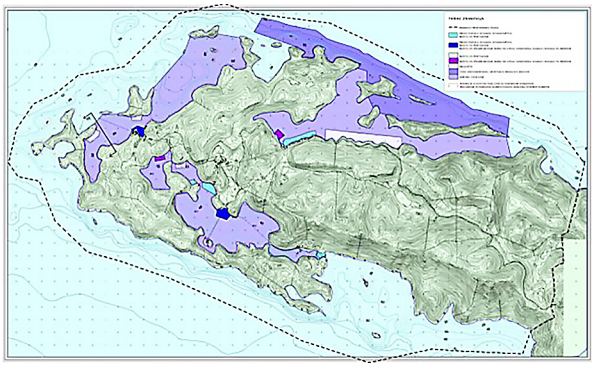
Uvođenje prostornog planiranja morskih područja za Hrvatsku je neophodno s obzirom na duljinu obale i sve veću uzurpaciju obalnog i morskog prostora. MSP je više od procesa koji regulira aktivnosti na moru. To je analitički pristup postavljanja čovjeka prema aktivnostima u morskom području. Hrvatska je kao pomorska zemlja ratificirala Protokol o integriranom upravljanju obalnim područjem te preuzela obveze Barcelonske konvencije. Međutim, još nije izrađen odgovarajući dokument koji bi omogućio kvalitetno



Slika 3: Planiranje prostornog područja Dubrovačko-neretvanske županije prema MSP Direktivi, (a) područje transporta, eksploatacije ruda i ribolova, (b) ekološka mreža Natura 2000 (SUPREME Case Study, 2018).

upravljanje prostorom morske površine. MSP predstavlja nastavak prostornog uređenja kopnenog područja i nedvojbeno mora razmotriti prostrano obalno okruženje i tamošnje aktivnosti.

Prostorni planovi za zaštićena područja kojima upravljaju nacionalna tijela, a koji obuhvaćaju i kopnena i morska područja izrađeni su za određena zaštićena područja RH. Primjer prostornog plana od državnog značaja je područje Nacionalnog parka Mljet donesen 2019. godine.



Slika 2: Prostorni plan Nacionalnog parka Mljet – kartografski prikaz korištenja i namjene prostora mora u mjerilu 1:25 000 (URL 1).

Različiti kartografski prikazi prostornog plana NP Mljet prikazuju planiranje prostora kopna i mora u mjerilu 1:25 000 gdje su doneseni sljedeći prikazi: korištenje i namjena prostora kopna s prikazom građevinskih i poljoprivrednih te šumskih područja, cesta, luka, pristaništa i dr. Zbog obuhvata morskog područja donesen je kartografski prikaz korištenja i namjene prostora mora gdje su prikazana mjesta za pristajanje, zona organiziranog ribolova i dr. (Slika 2). Zatim se prikazuju: prometni i telekomunikacijski sustavi, vodoopskrbni sustav, sustav otpadnih voda, elektroopskrbni sustav, građevinska područja, vegetacija i zbog specifičnosti samog područja prikaz uvjeta za korištenje, uređenje i zaštitu prostora gdje se navode područja zaštićenog podmorja, arheološki lokaliteti i dr.

Na podnacionalnoj razini, svi planovi obalnih županija uključuju odredbe za svoja morska područja (do vanjske granice teritorijalnog mora) koje se odnose na različite namjene mora. Prostorni planovi na područnom i lokalnom nivou već su doneseni: Prostorni plan Dubrovačko-neretvanske županije i lokalni prostorni planovi gradova/općina te urbanistički planovi. Na primjeru analize prostornog područja Dubrovačko-neretvanske županije u okviru propisa prostornog planiranja Republike Hrvatske i EU MSP Direktive definirana su različita područja planiranja: demografska situacija i urbanizacija, ribarstvo, morska kultura, istraživanje i eksploatacija ruda, minerala, energetika, morski transport, turizam, istraživački radovi, vojne aktivnosti, morski okoliš i zaštita prirode, podmorska i obalna kulturna baština, klimatske promjene i rizici, kopnena i zračna povezanost, podmorska i udaljena infrastruktura.

Na Slici 3a prikazano je prostorno planiranje za područje transporta, eksploatacije ruda i ribolova. S druge strane na Slici 3b prikazana su ekološki važna područja iz ekološke mreže Natura 2000 koju čini sustav međusobno povezanih ekološki važnih područja koja pridonose očuvanju prirodne ravnoteže i biološke raznolikosti. Očuvanje područja i zaštićena područja u praksi se osiguravaju ugradnjom odgovarajućih uvjeta zaštite prirode u prostorne planove i planove upravljanja prirodnim dobrima. Nedostatak relevantnih i službenih prostornih podataka, pogotovo o morskom dnu i podmorju je jedan od problema prostornog planiranja mora u Republici Hrvatskoj, a što bi se trebalo riješiti na nacionalnom nivou i u skladu s EU MSP Direktivom. Satelitske snimke prikupljene metodama daljinskih istraživanja sve više postaju izvor informacija za različite aplikacije vezane za upravljanje prirodnim resursima, urbano planiranje, upravljanje zemljištem i dr., pa se očekuje njihova primjena i kod prostornog planiranja područja državne razine i morskih područja. Osim toga, satelitske snimke osiguravaju brzo prikupljanje podataka za velika područja te daju ažurnije informacije od tradicionalnih karata u analognom ili digitalnom formatu.

3. Program Copernicus

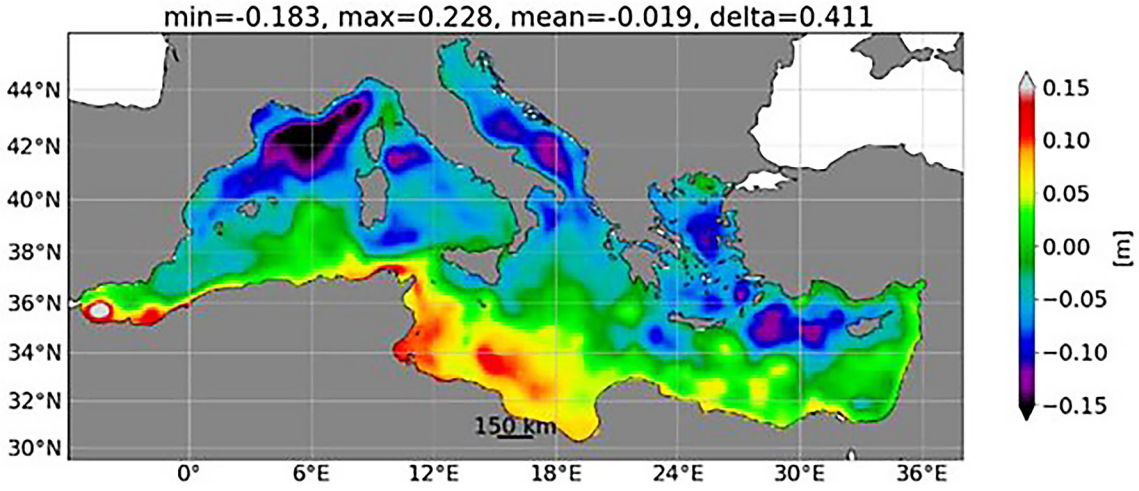
Program Copernicus uspostavljen je Uredbom EU br. 377/2014 Europskog parlamenta i vijeća (UREDBA EU 377/2014, 2014). Kao jedna od glavnih inicijativa svemirske politike Europske unije (EU) i Europske svemirske agencije (ESA) omogućuje prikupljanje preci-

znih podataka o Zemlji i pomaže u praćenju prostora kopna te oceana i mora. Copernicus pruža informacije o upotrebi zemljišta i klasifikaciji pokrova zemljišta, širenju gradova, gradskim zelenim površinama, urbanim toplinskim otocima i dr. Copernicus može pomoći i u praćenju stabilnosti infrastrukture, procjeni novih gradilišta, procjeni gustoće naseljenosti itd. Program je politikom otvorenog pristupa podigao korištenje satelitskih snimaka na novu razinu jer su one postale dostupne svima i u svakom trenutku. Danas su ažurni skupovi prostornih podataka i njihova vizualizacija od iznimne važnosti za analize blizu stvarnog vremena kao i za bolje donošenje odluka od strane nacionalnih i lokalnih vlasti, a sve dostupnije su strategije iskorištavanja velike količine podataka (engl. Big Data exploitation) i relevantni alati za njihovu obradu i analizu koji mogu uvelike poboljšati sposobnosti razumijevanja iz sirovih podataka generirajući nove analize i omogućiti kvalitetno upravljanje prostorom. Program Copernicus može doprinijeti pametnoj upravi pružanjem geoprostornih informacija i podataka koji se kombiniraju s drugim izvorima informacija te na taj način poboljšati dostupnost, transparentnost i učinkovitost javnih usluga i pružanja e-usluga građanima. Copernicus podaci pomažu pri donošenju odluka i procjenama od početnog planiranja pa kroz cijeli proces jer omogućuju vizualizaciju i procjenu utjecaja na okolinu, praćenje urbanog razvoja gradova, praćenje promjena na zemljištu te identificiranje najboljih lokacija za izgradnju nove infrastrukture. Prostornom i vremenskom rezolucijom koju pružaju, Copernicus Sentinel misije moguće je koristiti u širokom spektru primjena za regionalno i urbano planiranje. Praćenje gradnje, urbano planiranje, nadzor kulturne baštine kao i usklađenost s okolišem tipične su aplikacije u kojima Copernicus generira podatke i razvija relevantna rješenja. Kombiniranjem satelitskih snimaka Sentinel satelita s visokom prostornom rezolucijom moguće je pratiti upotrebu i izgrađenosti zemljišta i širenje naselja, otkrivanje nelegalne gradnje i devastacije prostora. Parametri koji se odnose na morski okoliš brzo se mijenjaju, a njihovo se praćenje temelji na opsežnim podacima o promatranju u stvarnom vremenu. Promatranje Zemlje stoga je važan izvor informacija za praćenje morskog okoliša i za razvoj morskog gospodarstva. Zahvaljujući svojem kapacitetu za praćenje fizičkih i biogeokemijskih svojstava svjetskih oceana i regionalnih mora, Copernicus podržava niz različitih primjena kao što su procjena kvalitete vode, kartiranje ribolovnih zona ili praćenje štetnog cvjetanja algi. Promatranje Zemlje može pridonijeti i zaštiti morske bioraznolikosti te pomoći u praćenju erozije obale. Program Copernicus osigurava podatke sa Sentinel satelita. Za prostorno planiranje važne su prve tri misije. Sentinel-1 misija pruža podatke za potrebe kopnenog i morskog praćenja. Radarski instrumenti omogućavaju dobivanje podataka po danu i po noći u svim vremenskim uvjetima u vremenskoj rezoluciji od 6 dana međutim zahtijevaju naknadnu obradu podataka. Sentinel-2 čini konstelacija od dva identična satelita u istoj orbiti, osigurava podatke kopnenog i obalnog područja u visokoj prostornoj rezoluciji u optičkoj domeni. Omogućava snimke vegetacije, tla te vodenih površina u višespektralnim snimcima. Sentinel-3 je misija s više instrumenata za mjerenje topografije morske površine, temperature površine mora i kopna te boje oceana. Koristi se za predviđanje vremena na oceanima kao i za neprekidno praćenju okoliša i klime. Najviše se u praksi koriste Sentinel-2 sateliti opremljeni multispektralnim kamerama za neprekidno praćenje kopna i mora. Satelitski podaci potencijalno mogu biti značajni za kartiranje morskih površina s obzirom na slobodan pristup i često obnavljanje podataka. Uz globalnu pokrivenost Zemljine površine i dostupnost kroz 10 dana s jednim satelitom i 5 dana s dva satelita, Sentinel-2 pruža visoku razinu kvalitetne multispektralne slike s prostornim rezolucijama u rasponu od 10 m do 60 m. Sentinel-2 sateliti nose optičke instrumente koji prikupljaju 13 spektralnih kanala, od toga 4 kanala s rezolucijom 10 m, 6 kanala s 20 m rezolucijom i 3 kanala sa 60 m prostornom rezolucijom. Prostorna rezolucija Sentinel-2 satelita ovisna je o određenom spektralnom kanalu koji se koristi kao i njihovoj kombinaciji, kod 10 m prostorne rezolucije to su B2 (490 nm) – plava, B3 (560 nm) – zelena, B4 (665 nm) – crvena i B8 – blizuinfracrvena (842 nm) (URL 2). ESA je omogućila besplatan pristup i korištenje Sentinel proizvoda. Podaci koje dostavljaju Sentinel sateliti mogu se preuzeti preko klasičnih centara za pristup podacima, kao što su ESA-in Copernicus centar s otvorenim pristupom podacima (Copernicu Open Access Hub) ili EUMETSAT-ov (European operational satellite agency for monitoring weather, climate and the environment) pristup podacima programa Copernicus. Kako bi se olakšao i standardizirao pristup, Sentinel podaci dostupni su preko Copernicus Data and Information Access Service (DIAS) okoline. Pet platformi koje se nazivaju DIAS omogućuju centraliziran pristup podacima i informacijama programa Copernicus te alatima za obradu. Pet je aktualnih platformi DIAS: Mundi, ONDA, CREODIAS, Sobloo i WekEO. Korisnici mogu pretraživati, obrađivati i preuzimati podatke i informacije programa Copernicus. Sve platforme DIAS omogućuju pristup podacima Sentinela i informacijama iz šest operativnih usluga programa Copernicus te omogućuje korisnicima da razvijaju i udomljavaju (engl. hosting) vlastite aplikacije, pri čemu ne moraju preuzimati velike datoteke s nekoliko pristupnih točaka i lokalno ih obrađivati. U većini slučajeva podaci i informacije mogu se pregledati ili pretraživati bez prethodne registracije, a za preuzimanje je potrebna registracija. Satelitske misije mogu biti dovoljan izvor podataka, no može ih se dopuniti in-situ mjerenjima (GNSS, mareografi) u svrhu prikupljanja dodatnih potrebnih podataka za kvalitetno planiranje i upravljanje prostorom. In-situ mreže za praćenje sastoje se od različitih senzora postavljenih na kopnu, u moru ili zraku, a koje prikupljaju podatke o okolišu na koje se oslanjaju Copernicus servisi. Mreže su georeferencirane, a prikupljaju i pomoćne podatke čija je svrha kalibracija i provjera satelitskih podataka. In-situ infrastruktura za praćenje uključuje senzore postavljene na obalama rijeka, senzore na letjelicama te senzore smještene na brodove ili bove. Dio in-situ infrastrukture čine i bespilotne letjelice. Program pohranjuje podatke registrirane senzorima i daje velik broj pouzdanih i ažuriranih informacija o stanju planeta Zemlje. Podaci i informacije se ko-

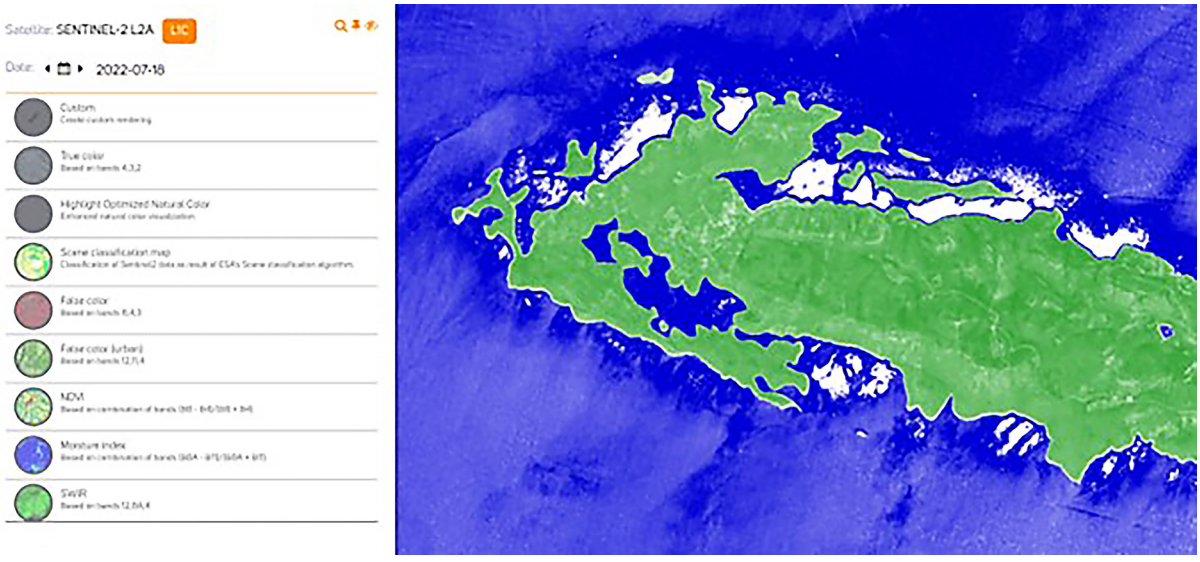
riste za statističke analize, izradu topografskih karata i dr. iz kojih se iščitavaju indikatori za modeliranje prošlih, sadašnjih i budućih trendova. Razmjena podataka obavlja se kroz različite internacionalne servise: ROOSes (Regional Operational Oceanographic Systems), EMODnet (European Marine Observations and Data network). Visoko kvalitetne dugoročne vremenske serije podataka dostupne su kroz mrežu SeaDataNet – NODCs (National Oceanographic Data Centres) (URL 3). Cilj je uspostava cjelovite i javno dostupne baze podataka na kojoj će se temeljiti daljnje pomorsko prostorno planiranje, a za što je potrebno uključiti različite struke (seizmička, geodetska, hidrografska, geofizička i geotehnička mjerenja morskog prostora i podmorja) i subjekte od nacionalnog do lokalnog nivoa. Sve to uz korištenje Copernicus servisa uvelike doprinosi, obogaćuje i poboljšava prostorno planiranje od nacionalnog do lokalnog nivoa, kao i točnosti te pouzdanosti analiza.

3.1. Copernicus alati za praćenje morskih površina

Iako vodene površine prekrivaju 71% Zemljine površine, ipak njihov potencijal za ekonomski i gospodarski razvoj relativno je neiskorišten. Europska unija u tu svrhu pokušava implementirati dugoročnu strategiju "Plavi rast" u svrhu podrške održivog razvoja na moru i u morskom sektoru. Morsko je područje trodimenzionalan prostor sastavljen od morskog dna, morskog stupca i površine te kao višedimenzionalan zahtjeva praćenje sve tri komponente kao i njihovo korištenje u različitim razdobljima ili sezonama, a tijekom prostornog planiranja potrebno je voditi računa o tim različitostima. Copernicus je u sklopu svog programa ponudio i servis praćenja mora koji daje redovite i sustavne informacije o stanju i dinamici mora i oceana u svrhu njihove zaštite i učinkovitijeg upravljanja morskim okolišem i resursima. Primjerice, podaci o strujama, vjetrovima i morskom ledu pomažu unapređenju pomorskih ruta, operacijama spašavanja doprinoseći sigurnosti na moru i dr. Servis također



Slika 4: Model srednje dinamičke visine topografije iz 2020. godine (URL 4).



Slika 5: Kartografski prikaz satelitskih snimaka područja NP Mljet korištenjem NDWI metode spektralne analize i preglednika CREODIAS.

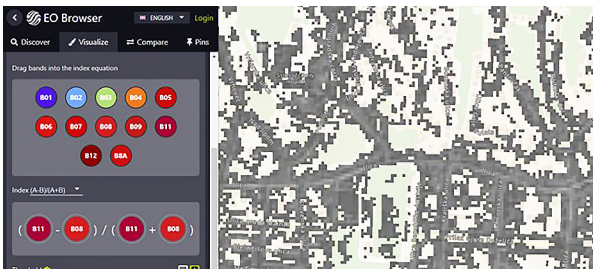
doprinosi zaštiti i održivom upravljanju živih morskih resursa posebice za uzgoj riba, istraživanje ribarstva ili regionalne ribarske organizacije. Povećanje globalne srednje razine mora (mean sea level – MSL) jedna je od najnepovoljnijih posljedica klimatskih promjena. Precizno praćenje mora ključno je za razumijevanje socioekonomskih posljedica povezanih s brzim porastom klimatskih promjena. Točno praćenje ove varijable neophodno je za razumijevanje promjena u širokom rasponu vremenske i prostorne skale, od sezonskih do razdoblja desetljeća i od regionalnih do svjetskim razmjera (von Schuckmann i dr., 2016). Mareografi su in-situ instrumenti korišteni za utvrđivanje morskih mijena i mjerenje razine mora više od jednog stoljeća, a od 1990-ih varijacije u razini mora rutinski se određuju visoko preciznom satelitskom altimetrijom (Copernicus Sentinel-3). Jedna od važnijih primjena opažanja sa satelita je nadgledanje otvorenih voda s visokom točnošću. Različiti pristupi kartiranju morske površine razvijeni su u svrhu razlučivanja morske površine iz multispektralnih snimaka Sentinel-1 (Slika 4).

Satelitski kanali mogu se kombinirati na više načina, ovisno o značajci koja se mora istaknuti u snimci. Budući da ljudske oči mogu vidjeti samo unutar vidljivog raspona, većina slika sastoji se od kombinacije crvenog, zelenog i plavog kanala za oponašanje vidljivog spektra. Ova kombinacija spektralnih kanala poznata je kao "prava" ili "prirodna" boja. Indeks normalizirane razlike vode (NDWI – Normalized Difference Water Index) koristi se za isticanje značajki otvorenih voda na satelitskoj snimci, omogućujući vodenom tijelu da se "ističe" u odnosu na tlo i vegetaciju (Du i dr., 2016).

Metoda bazirana na spektralnom indeksu morske površine, posebno metoda NDWI računata iz zelene i blizuinfracrvene koje su obje 10 m prostorne rezolucije i MDNWI metoda (Modified Normalized Difference Water Index) računata iz zelene i SWIR kanala (Shortwave-Infrared) koja je 20 m prostorne rezolucije, su najviše korištene metode za analize morskih površina. U posljednjih desetak godina MNDWI metoda široko je primijenjena u proizvodnji karata morskih područja različitih mjerila (Slika 5).

3.2. Copernicus alati za praćenje kopnene površine

U svrhu praćenja i analize kopnenih površina najviše se koriste Copernicus Sentinel-1 (radarske) i Sentinel-2 (optičke) satelitske snimke dostupne na jednom od otvorenih servisa za preuzimanje podataka, npr. Copernic Open Access Hubu. Copernicus pruža geografske informacije o pokrovu kopna i vezanim varijablama kao što su npr. stanje vegetacije ili vodeni ciklus. Podržane su primjene u raznim područjima, kao što su: prostorno planiranje, upravljanje šumama, upravljanje vodama, poljoprivreda i dr. Servis je postao operativan 2012., a obuhvaća pet glavnih sastavnica. Sustavnim praćenjem biofizičkih parametara prvenstveno se dobiva niz kvalificiranih biogeofizičkih proizvoda o stanju i promjenama kopnene površine. Proizvodi se koriste za praćenje vegetacije, usjeva, hidrološkog ciklusa, energetskog proračuna i dr. Kartiranjem pokrova zemljišta i upotrebe zemljišta dobiva se klasifikacija pokrova zemljišta s različitim razinama pojedinosti i to u europskom i globalnom kontekstu (CORINE). Tematsko kartiranje posebno zanimljivih područja pruža prilagođene i detaljne informacije o posebnim područjima od interesa npr. obalna područja, specifični ekološki problemi (Natura 2000). Copernicus podaci čine mozaik satelitskih snimaka visoke (10 m) i vrlo visoke rezolucije (2 m) te referentni skupovi podataka koji osiguravaju homogenu europsku pokrivenost za neke ključne geoprostorne značajke, kao što su hidrografija (EU-Hydro) i digitalni model površine (EU-DEM). Za nadgledanje urbanih područja često se koriste multispektralne snimke (od vidljivog do blizu i kratkovalnih infracrvenih valova). Takav pristup uključuje pikselnu i objektnu klasifikaciju i korištenje spektralnih indeksa u analizama podataka. Vegetacijski indeks koristi se jer predstavlja provjerenu i uvaženu metodu analize. Očekuje se kako će područja s većim vegetacijskim indeksima prikazivati nenaseljene prostore dok će niži vegetacijski indeksi prikazivati ponajprije urbana područja. S druge strane sve više se u analizama urbanih područja primjenjuju i SAR (synthetic-aperture radar) satelitske snimke uzimajući u obzir mikrovalne parametre urbanih sredina, dok se ponekad koriste i termalne infracrvene značajke urbanih područja. Urbanisti također mogu koristiti Copernicus servise i proizvode za procjenu trenutne "zelenosti" grada i identificiranje područja gdje je potrebno više zelenih površina unutar funkcionalnih urbanih područja (Urban Atlas).

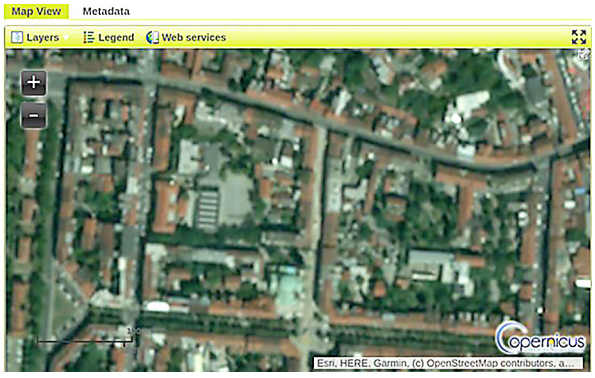


Slika 6: Kartografski prikaz satelitske snimke korištenjem NDBI metode spektralne analize i preglednika EO.

Osim prethodno navedenih komponenti uspostavlja se i nova komponenta za praćenje gibanja tla u Europi (European Ground Motion Service) koja će omogućiti podatke o pomacima tla, uključujući odrone i slijeganja tla te deformacije infrastrukture. Europska lokalna i regionalna tijela imaju veliku odgovornost u području urbanističkog planiranja i utječu na prostorno planiranje na lokanoj i regionalnoj razini. Rast urbanih područja bez procesa planiranja dovodi do stvaranja složenih urbanih problema. Stoga učestalo kartiranje urbanih sredina i praćenje urbanog rasta postaje sve važnije kod prostornog planiranja.

Tijekom posljednjih nekoliko desetljeća, usvajaju se novi pristupi održivog urbanog oblika kao što su "pametni rast" i "kompaktni grad", ali su razvijene i nove metode i tehnike za praćenje i analizu fenomena urbanog širenja i njegovih posljedica. Konvencionalne tehnike snimanja i kartiranja su skupe i dugotrajne za procjenu urbanog rasta, stoga su statističke tehnike

zajedno s GNSS i GIS alatima te primjena daljinskih istraživanja učinkoviti i vrijedni alat za studije urbanog rasta kao i planiranje, praćenje i procjenu urbanog širenja i promjena tijekom vremenskog perioda. Kod procesa urbanog planiranja često se koristi metoda spektralne analize, gdje se najviše u praksi koristi spektralni indeks koji ističe urbana područja NDBI (Normalized Difference Built-up Index), a koji koristi NIR i SWIR kanale kako bi se naglasile izgrađene površine. Omjer se temelji na ublažavanju učinaka razlika u osvijetljenosti terena kao i atmosferskih učinaka (Slika 6). Copernicus satelitske snimke s visokom prostornom i vremenskom rezolucijom omogućavaju usporedbu i praćenje stanja u prostoru kao i detektiranje promjena u prostoru kroz vrijeme. Kombinacijom snimaka i korištenjem filtera za redukciju oblaka te standardiziranih indeksa omogućeno je praćenje upotrebe zemljišta te same izgrađenosti kao i širenje urbanih područja, otkrivanje nelegalne gradnje, devastacije prostora i dr. (Slika 7).



Slika 7: Mozaik satelitskih snimaka vrlo visoke rezolucije iz 2018. – True Colour 2 m (URL 5).

Prostorno planiranje i praćenje upotrebe zemljišta implementirano je i u ISPU (Informacijski Sustav Prostornoga Uređenja) Republike Hrvatske, gdje jedan od modula predstavlja implementaciju satelitskih snimaka za područje RH te obradu i analizu istih u svrhu praćenja upotrebe zemljišta i njene izgrađenosti, širenje naselja, otkrivanje nelegalne gradnje, devastacije prostora i dr. Kombinacijom podataka iz različitih izvora a koji su od značaja za prostorno planiranje i prostor općenito stvorena je vrlo kvalitetna baza podataka za upravljanje prostorom, a Copernicus sustav kao živući sustav može doprinijeti kvalitetnom praćenju promjena te posljedično ažurnim i kvalitetnim podacima za korisnike prostornih podataka.

4. Zaključak

Prostorno planiranje Republike Hrvatske, a posebno prostorno planiranje morskog područja (MSP) proces je koji okuplja više sudionika kako bi se donosile koordinirane odluke o tome kako održivo planirati i koristiti kopnene i morske resurse. Europski parlament i Vijeće usvojili su zakonodavstvo za stvaranje zajedničkog okvira za pomorsko prostorno planiranje u Europi, a prema inicijativi Plavi rast Europske komisije postoji značajan potencijal u europskim oceanima, morima i obalama. Direktivu o uspostavi okvira za prostorno planiranje morskih područja implementirala je i Republika Hrvatska. Copernicus se kao program Europske unije za promatranje Zemlje i njegova okoliša pokazao kao dobar alat za prikupljanje podataka iz satelitskih opažanja a sadrži kvalitetnu prostorno vremensku rezoluciju. Usluge pružanja informacija besplatne su i javno dostupne korisnicima. Copernicus pruža informacije o upotrebi zemljišta i klasifikaciji pokrova zemljišta, širenju gradova, gradskim zelenim površinama, urbanim toplinskim otocima i dr. Stoga Copernicus podaci mogu pomoći pri donošenju odluka i procjenama od početnog planiranja pa kroz cijeli proces jer omogućuju vizualizaciju i procjenu utjecaja na okolinu, praćenje urbanog razvoja gradova, praćenje promjena na zemljištu te identificiranje najboljih lokacija za izgradnju nove infrastrukture kao i detektiranje područja devastacije i nelegalne gradnje. Prostornom i vremenskom rezolucijom koju pružaju, Copernicus Sentinel misije moguće je kvalitetno koristiti u širokom spektru primjena za regionalno i urbano planiranje. Copernicus je u sklopu svog programa ponudio i servis praćenja mora koji daje redovite i sustavne informacije o stanju i dinamici mora i oceana u svrhu njihove zaštite i učinkovitijeg upravljanja morskim okolišem i resursima. Danas su ažurni skupovi prostornih podataka i njihova vizualizacija od iznimne važnosti za analize blizu stvarnog vremena kao i za bolje planiranje i donošenje odluka. U svrhu poticanja i olakšavanja procesa prostornog planiranja od strane nacionalnih i regionalnih/lokalnih vlasti neophodno je uključiti ažurne informacije iz globalnih i međunarodnih inicijativa, kao što je Copernicus, dopunjene lokalnim podacima i informacijama, čime se osigurava najbolja moguća pokrivenost u smislu prostornog i vremenskog opsega i razine detalja potrebne za upravljanje razvojem i planiranje kako kopnenog tako i morskog i obalnog područja.

Literatura

Direktiva EU 2014/89/EU (2014): DIREKTIVA 2014/89/EU EUROPSKOG PARLAMENTA I VIJEĆA od 23. srpnja 2014. o uspostavi okvira za prostorno planiranje morskog područja, Službeni list Europske unije, L 257/135.

Du, Y., Zhang, Y., Ling, F., Wang, Q., Li, W., Li, X. (2016): Water Bodies' Mapping from Sentinel-2 Imagery with Modified Normalized Difference Water Index at 10-m Spatial Resolution Produced by Sharpening the SWIR Band, Remote Sensing, 8 (4), 354.

European MSP Platform (2022): Croatia Maritime Spatial Planning Country Information.

Narodne novine (2013): Zakon o prostornom uređenju, br. 153/13, 65/17, 114/18, 39/19, 98/19, Zagreb.

Narodne novine (2017): Strategija prostornog razvoja Republike Hrvatske, br. 106/17, Zagreb.

Narodne novine (2018): Odluka o izradi Državnog plana prostornog uređenja za cijelo kopneno i mor-

sko područje (do vanjske granice teritorijalnih voda) Republike Hrvatske, br. 39/18, Zagreb.

SUPREME Case Study (2018): Addressing MSP Implementation in Case Study Areas Case Study Dubrovnik – Neretva County, Agreement EASME/EMFF/2015/1.2.1.3/01/S12.742087 – SUPREME.

Uredba EU 377/2014 (2014): UREDBA (EU) br. 377/2014 EUROPSKOG PARLAMENTA I VIJEĆA od 3. travnja 2014. o uspostavi programa Copernicus i o stavljanju izvan snage Uredbe (EU) br. 911/2010, Službeni list Europske unije, L 122/44.

von Schuckmann, K. i dr. (2016): The Copernicus Marine Environment Monitoring Service Ocean State Report, Journal of Operational Oceanography, 9 (sup2), 235–320.

URL 1: Prostorni Plan NP Mljet, https://mpgi.gov.hr/prostorno-uredjenje-3335/prostorni-planovi-8193/prostorni-planovi-drzavne-razine/prostorni-planovi-nacionalnih-parkova/prostorni-plan-np-mljet/3323, (14.7.2022.).

URL 2: Sentinel-2, https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions/spatial, (14.7.2022.).

URL 3: Seadata, https://www.seadatanet.org, (14.7.2022.).

URL 4: Marine Copernicus, https://marine.copernicus.eu, (15.7.2022.).

URL 5: Land Copernicus, https://land.copernicus.eu, (15.7.2022.).

Possibilities of Copernicus Program Implementation in the Spatial Planning of the Republic of Croatia

Abstract

Management of development and planning of land, sea and coastal areas is very important for the development of the whole country. In the Croatian spatial planning system, land and sea areas are planned, and spatial planning of marine areas is traditionally an integral part of spatial planning in the Republic of Croatia and includes most of the topics and requirements included in European and international regulations, the primary directive on the establishment of a framework for spatial planning of marine areas (MSP – Maritime Spatial Planning) – 2014/89/EU. Spatial planning is constantly under increased demands from various entities and directives, such as the implementation of the Blue Development strategy, which encourages the sustainable development of the sea and the marine sector. For the purpose of good management, it is necessary to collect very precise information about the space. Parameters related to the marine environment are changing rapidly, and their monitoring is based on extensive real-time observational data. Earth observation from satellites is a potentially important source of information for monitoring the marine environment and for the development of the marine economy. Thanks to its capacity for satellite observation and monitoring of changes in the world's oceans and regional seas, the Copernicus Earth observation program, as one of the main initiatives of the space policy of the European Union and the European Space Agency, enables the collection of precise data about the Earth and helps to monitor land, ocean and maritime space. The Copernicus program made it possible for satellite Earth observation data to become available to everyone, which opens up new possibilities for creating spatial analyzes with better spatial planning and decision-making by national and local authorities. The program with its services enables a wide range of changes in spatial planning, and in combination with other sources of information (in-situ measurements, remote sensing) can contribute to national and local governments in improving their availability and up-to-dateness. Satellite data is used to periodically update information about the Earth, which is a powerful tool for spatial planning. With the spatial and temporal resolution they provide, the Copernicus Sentinel missions can be used in a wide range of spatial planning applications. This paper describes the ways in which Copernicus data can contribute to spatial management, but also to its development, with an emphasis on applications in coastal and marine spatial planning and the application of the MSP Directive.

Keywords: *Copernicus, MSP, spatial planning*

Uspostava GIS rješenja i Jedinstvene nacionalne baze podataka pomorskog dobra Republike Hrvatske

Olga Bjelotomić Oršulić[1], Stjepan Grđan[1], Marijana Iviček[2], Boris Fantulin[2], Nina Perko[2]

[1] IGEA d.o.o., Frana Supila 7/b, Varaždin, Hrvatska, olga.bjelotomicorsulic@igea.hr

[2] Ministarstvo mora, pomorstva i infrastrukture, Prisavlje 14, Zagreb, Hrvatska, marijana.ivicek@pomorstvo.hr

Sažetak

Pomorsko dobro je opće dobro od interesa za Republiku Hrvatsku i ima njezinu osobitu zaštitu te je resurs iznimne vrijednosti za državu, njene stanovnike i gospodarstvo. Za učinkovito i održivo upravljanje pomorskim dobrom, uspostavljena je Jedinstvena nacionalna baza podataka pomorskog dobra Republike Hrvatske koja putem web GIS aplikacije centralno objedinjuje točne i službene podatke položaja i obuhvata pomorskog dobra, granica pomorskog dobra, koncesija, luka i lučkih područja prateći poslovni proces provođenja i obrade zahtjeva stranaka i odluka Vlade. Centralni jedinstveni informacijski sustav kroz web GIS aplikativno rješenje omogućuje jednostavan pristup putem interneta svim registriranim korisnicima diljem Hrvatske, centralnu pohranu svih podataka pomorskog dobra te učinkovito i održivo upravljanje pomorskim dobrom i pratećom ekonomijom. Ovaj rad daje prikaz strukture i mogućnosti jedinstvenog integriranog geoinformacijskog sustava pomorskog dobra i koncesija Republike Hrvatske.

Ključne riječi: *granice pomorskog dobra, jedinstvena nacionalna baza podataka pomorskog dobra, koncesije, pomorsko dobro, web GIS rješenje*

1. Uvod

Republika Hrvatska je zemlja s površinom kopna od 56 594 km^2 i obalnog mora (unutrašnje morske vode i teritorijalno more) 31 067 km^2 (URL 1), pri čemu je udio površine obalnog mora veći od 35% što Hrvatsku svrstava u pomorske zemlje. Hrvatska je donošenjem Zakona o pomorskom dobru i morskim lukama (NN 158/03, 100/04, 141/06, 38/09, 123/11, 56/16, 98/19) i drugih zakonskih i podzakonskih akata kreirala pravni okvir za upravljanje pomorskim dobrom, prije svega za uspostavljanje evidencija koje sadrže podatke o pomorskom dobru i njegovom korištenju, u smislu određivanja lokacije pojedinih područja značajne za sigurnost plovidbe, upravljanje pomorskim dobrom, zaštitu mora i interesa Republike Hrvatske.

Kako bi se osiguralo učinkovito upravljanje nad pomorskim dobrom, nadležna tijela pomorske uprave trebaju u digitalnom obliku raspolagati potrebnim podacima i evidencijama, upravnim i neupravnim postupcima, kao i tehničkim informacijskim sustavima kojima se osigurava efikasno prikupljanje, čuvanje, distribucija i analitika geodistribuiranih podataka u pomorstvu na organizirani način (u skladu s poslovnim procesima, organizacijskom strukturom, tehnološkim mogućnostima i tehničkim standardima za prikupljanje i razmjenu podataka), a sve u cilju učinkovite primjene i nadzora primjene Zakona o pomorskom dobru i morskim lukama (u daljnjem tekstu ZPDML), te drugih propisa kojima se uređuje uporaba morskog prostora. Tehnološki zahtjevi u pogledu modernizacije upravljanja i optimalnog korištenja pomorskog dobra danas nužno uključuju nove IT tehnologije; novi su načini prikupljanja podataka (kako tehnološki tako i organizacijski), novi se standardi uvode u predmetnu djelatnost, novi su načini vođenja prikaza podataka i svi oni se temelje na podatku u digitalnom obliku. Upravo iz tih razloga razvijen je i uspostavljen sveobuhvatni informacijski centralni sustav podataka pomorskog dobra Republike Hrvatske mrežno povezan s drugim sastavnicama i dionicima kroz različite korisničke uloge s ciljem jedinstvenog centralnog mjesta upravljanja svim podacima pomorskog dobra.

1.1. Pravni temelji

U domeni pomorskog dobra, morskih luka i davanja koncesija nad pomorskim dobrom, trenutno su važeći sljedeći zakonski propisi:

- Pomorski zakonik (NN 181/04, NN 76/07, NN 146/08, NN 61/11, NN 56/13, NN 26/15, NN 17/19)
- Zakon o pomorskom dobru i morskim lukama (NN 158/03, NN 100/04, NN 141/06, NN 38/09, NN 123/11, NN 56/16, NN 98/19),
- Zakon o hidrografskoj djelatnosti (NN 68/98, 110/98, 163/03, 71/14),

- Pravilnik o službenim pomorskim i navigacijskim kartama i publikacijama, njihovom sadržaju, načinu i uvjetima izrade, izdavanja i održavanja (NN 42/2016),
- Pravilnik o evidentiranju i obilježavanju pomorskog dobra (NN 29/2005),
- Uredba o postupku utvrđivanja granice pomorskog dobra (NN 8/2004),
- Pravilnik o upisniku koncesija na pomorskom dobru (NN 176/04),
- Uredba o postupku davanja koncesije na pomorskom dobru (NN 23/2004, NN 101/2004, NN 39/2006, NN 63/2008, NN 102/2011, NN 125/2010, NN 83/2012, NN 10/2017),
- Konvencija UN o pravu mora i
- INSPIRE direktiva
- Pravilnik o kriterijima za određivanje namjene pojedinog dijela luke otvorene za javni promet županijskog i lokalnog značaja, način plaćanja veza, uvjete korištenja, te određivanja maksimalne visine naknade i raspodjele prihoda (NN 94/07, NN 79/08, NN 114/12, NN 47/13)
- Uredba o uvjetima kojima moraju udovoljavati luke (NN 110/04)
- Uredba o razvrstaju luka otvorenih za javni promet i luka posebne namjene (NN 110/04, NN 82/07)
- Uredba o postupku davanja koncesijskog odobrenja na pomorskom dobru (NN 36/04, NN 63/08, NN 133/13, NN 63/14)

Postojeći Zakon o pomorskom dobru i morskim lukama (u daljnjem tekstu ZPDML) propisuje da pomorskim dobrom upravlja, vodi brigu o zaštiti i odgovara Republika Hrvatska neposredno ili putem jedinica područne regionalne samouprave, odnosno jedinica lokalne samouprave. Pod upravljanjem pomorskim dobrom podrazumijeva se održavanje, unapređenje, briga o zaštiti pomorskog dobra u općoj upotrebi, te posebna upotreba i gospodarsko korištenje pomorskog dobra na temelju koncesija.

Prema članku 3. ZPDML Pomorsko dobro je opće dobro od interesa za Republiku Hrvatsku i ima njezinu osobitu zaštitu. Pomorsko dobro čine unutarnje morske vode i teritorijalno more, njihovo dno i podzemlje, te dio kopna koji je po svojoj prirodi namijenjen općoj upotrebi ili je proglašen takvim, kao i sve što je s tim dijelom kopna trajno spojeno na površini ili ispod nje, a dijelom kopna smatra se: morska obala, luke, nasipi, sprudovi, hridi, grebeni, plaže, ušća rijeka koje se izlijevaju u more, kanali spojeni s morem, te u moru i morskom podzemlju živa i neživa prirodna bogatstva.

Iz same zakonske definicije vidljiva je podjela pomorskog dobra na tri sastavnice: vodena komponenta, podmorje i obalna komponenta. Vodena komponenta obuhvaća unutrašnje morske vode i teritorijalno more Republike Hrvatske, dok njihovo dno čini podmorje. Obalna komponenta se sastoji od dijela kopna koji je po svojoj prirodi namijenjen općoj upotrebi ili je proglašen takvim.

Temeljna pravna karakteristika pomorskog dobra je da je to opće dobro od osobitog interesa za Republiku Hrvatsku. Prema članku 5. ZPDML na pomorskom dobru ne može se stjecati pravo vlasništva ni druga stvarna prava po bilo kojoj osnovi, a građevine i drugi objekti na pomorskom dobru koji su trajno povezani s pomorskim dobrom smatraju se pripadnošću pomorskog dobra.

Prema članku 10. ZPDML pomorskim dobrom upravlja, vodi brigu o zaštiti i odgovara Republika Hrvatska neposredno ili putem jedinica područne (regionalne) samouprave, odnosno jedinica lokalne samouprave u skladu s odredbama istog Zakona. Pod upravljanjem



Slika 1: NIPP podaci od interesa za pomorstvo

pomorskim dobrom podrazumijeva se održavanje, unapređenje, briga o zaštiti pomorskog dobra u općoj upotrebi, te posebna upotreba ili gospodarsko korištenje pomorskog dobra na temelju koncesije ili koncesijskog odobrenja. O dijelu pomorskog dobra u općoj upotrebi koje se nalazi na njenom području, vodi brigu o zaštiti i održava jedinica lokalne samouprave.

1.2. INSPIRE direktiva

Ulaskom u Europsku Uniju (EU) bilo je potrebno unaprijediti legislativu izmjenama postojećih zakona kao i donošenjem određenih podzakonskih akata. S obzirom na INfrastructure for SPatial Information (INSPIRE) Direktivu, kroz Nacionalnu infrastrukturu prostornih podataka (NIPP) definirana je i morska infrastruktura prostornih podataka (MIPP/MSDI) koja predstavlja razvojni okvir za prikupljanje, dijeljenje i upravljanje razmjenom podataka i mrežnih usluga u skladu s propisima o Nacionalnoj infrastrukturi prostornih podataka. INSPIRE je direktiva 2007/2/EZ Europskoga parlamenta i Vijeća Europske Unije od 14. ožujka 2007. koja se odnosi na prostorne podatke i podržava kreiranje politike vezane uz okoliš. INSPIRE direktiva je stupila na snagu 15. svibnja 2007. godine te tvori okvir za NIPP unutar država članica EU. Zbog toga se smjernice INSPIRE-a mogu smatrati obveznim za bilo koje daljnje aktivnosti NIPP-a. MIPP je nastao kao posljedica potreba i zahtjeva za interoperabilnosti podataka i informacija između kopnenog, priobalnog i pomorskog okoliša.

Prostorni podaci subjekata NIPP-a od interesa za pomorstvo obuhvaćaju kartografske podloge Državne geodetske uprave, podloge prostornih planova Ministarstva prostornoga uređenja, graditeljstva i državne imovine, granice zaštićenih područja i područja pod posebnim režimom Ministarstva gospodarstva i održivog razvoja, te prognostičke karte Državnog hidrometeorološkog zavoda, prikazano na Slici 1.

2. Upravljanje pomorskim dobrom

Sustav upravljanja pomorskim dobrom Republike Hrvatske razložen je na više dionika u okviru resornih ministarstava i uprava te u okviru regionalne i lokalne samouprave, državnih i županijskih lučkih uprava, lučkih kapetanija i državne uprave u cjelini.

Na nacionalnoj razini za pomorsko dobro Republike Hrvatske upravne i stručne poslove obavlja Uprava pomorstva u okviru Ministarstva mora, prometa i infrastrukture (MMPI). Takvo ustrojstvo u okviru resornog Ministarstva treba upravljati pomorskim dobrom na prostoru većem od 1/3 površine Republike Hrvatske.

Vlada Republike Hrvatske u okviru svoje nadležnosti daje koncesije na pomorskom dobru, te na osnovu zakonskih ovlaštenja donosi odgovarajuće uredbe, dok se na županijskoj i lokalnoj razini upravlja pomorskim dobrom kroz upravne odjele nadležne za poslove pomorstva.

Uspostavljeni centralni informacijski sustav omogućuje integraciju s županijskim i lokalnim jedinicama čime je omogućeno sveobuhvatno kvalitetno i učinkovito upravljanje i gospodarenje obalnim i morskim resursima od strane svih dionika pomorskog dobra. Time je omogućeno daljnje nadograđivanje i povezivanje sustava upravljanja i gospodarenja pomorskim dobrom s drugim dionicima i sustavima prostornih podataka i servisa te uspostavu konzistentnog sustava za upravljanja i zaštitu pomorskog dobra na prostoru pomorskog dobra Republike Hrvatske mrežno povezanog s vanjskim sustavima drugih državnih tijela.

Tri su ključna prostorna podatka u svrhu učinkovitog upravljanja pomorskim dobrom:

- Granice pomorskog dobra
- Granice lučkih područja luka otvorenih za javni promet i luka posebne namjene
- Granice koncesija na pomorskom dobru

Sveobuhvatni integrirani informacijski sustav obuhvaća upravljanje nad svim prostornim podacima pomorskog dobra kroz određivanje granica pomorskog dobra i lučkih područja te upravljanje lučkim i koncesijskim sustavom.

2.1. Granice pomorskog dobra

Člankom 14. Zakona o pomorskom dobru i morskim lukama određeno je da granicu pomorskog dobra utvrđuje Povjerenstvo za granice Ministarstva nadležnog za poslove pomorstva, a na prijedlog Županijskog povjerenstva za granice. Za svaku županiju osniva se posebno povjerenstvo za izradu prijedloga granice pomorskog dobra.

Županijsko povjerenstvo izrađuje prijedlog granice pomorskog dobra temeljem godišnjeg plana upravljanja pomorskim dobrom ili iznimno temeljem zahtjeva, a Povjerenstvo Ministarstva utvrđuje granicu pomorskog dobra i to rješenjem u upravnom postupku. Dakle granica pomorskog dobra utvrđuje se Rješenjem Povjerenstva Ministarstva u upravnom postupku temeljem odredbi Zakona o pomorskom dobru i morskim lukama, Uredbe o postupku utvrđivanja granice pomorskog dobra i Pravilnika o evidentiranju i obilježavanju pomorskog dobra. Rješenje između ostalog sadrži opis granice pomorskog dobra i popis zemljišnoknjižnih i katastarskih čestica koje se nalaze na pomorskom dobru koje se utvrđuju.

2.2. Luke

Prema članku 42. Zakona o pomorskom dobru i morskim lukama, ovisno o namjeni kojoj služe, luke se dijele na:

- ❑ luke otvorene za javni promet (LOJP), koje se dijele prema veličini i značaju za RH:
  - luke osobitoga /međunarodnoga) gospodarskog interesa za RH,
  - luke županijskog značaja i
  - luke lokalnog značaja.

- luke za posebne namjene (LPN), koje se ovisno o djelatnostima dijele na:
  - vojne luke,
  - luke nautičkog turizma,
  - industrijske luke,
  - brodogradilišne luke,
  - sportske, ribarske i druge luke slične namjene.

Granicu pomorskog dobra i lučkog područja luka posebne namjene utvrđuje Povjerenstvo za granice Ministarstva, na prijedlog županijskog povjerenstva za granice.

Vlada Republike Hrvatske utvrđuje lučko područje u lukama otvorenim za javni promet u skladu s prostornim planom. Radi upravljanja LOJP od osobitog gospodarskog značaja za RH osniva se lučka uprava.

Županijska skupština utvrđuje lučko područje za sve luke otvorene za javni promet županijskog i lokalnog značaja na svom području, u skladu s prostornim planom i uz suglasnost Vlade Republike Hrvatske.

2.3. Koncesije na pomorskom dobru

Gospodarsko korištenje pomorskog dobra je korištenje pomorskog dobra za obavljanje gospodarskih djelatnosti, sa ili bez korištenja postojećih građevina i drugih objekata na pomorskom dobru, te sa ili bez gradnje novih građevina i drugih objekata na pomorskom dobru. Prema članku 7. ZPDML, za posebnu upotrebu ili gospodarsko korištenje dijela pomorskog dobra može se dati koncesija fizičkim i pravnim osobama.

Prema članku 16. ZPDML, koncesija je pravo kojim se dio pomorskog dobra djelomično ili potpuno isključuje iz opće upotrebe i daje na posebnu upotrebu ili gospodarsko korištenje pravnim osobama i fizičkim osobama registriranim za obavljanje obrta. Pravo i obveze na temelju koncesije nastaju sklapanjem ugovora o koncesiji.

Sukladno ZPDML-u članak 36., koncesije se upisuju u upisnik koncesija koje vodi Ministarstvo (koncesije koje daje Vlada RH), ili nadležno upravno tijelo u županiji (koncesije koje daje županijska skupština). Također, člankom 72. ZPDML propisana je obveza lučke uprave da vodi upisnik koncesija.

3. Uspostava web GIS rješenja Jedinstvene nacionalne baze podataka pomorskog dobra Republike Hrvatske

Implementirano web GIS rješenje za podatke pomorskog dobra Republike Hrvatske obuhvaća funkcionalnosti unosa, izmjene i upravljanje podacima pomorskog dobra, utvrđivanje granica pomorskog dobra, lučkih područja i koncesija, evidentiranje svih trenutno aktualnih koncesijskih prava na pomorskom dobru, granica pomorskog dobra ili granica lučkih područja za alfanumerički i grafički dio upravljanja podacima pomorskog dobra, pregled i pretraživanje po prilagođenim parametrima, grafički prikaz prostornog obuhvata kroz web GIS preglednik, generiranje prilagođenih izvještaja, rješenja ili službenih izvadaka, te administracijsko upravljanje korisnicima različitih razina i pripadajućih ovlasti. Web GIS rješenje dostupno je 24/7 svaki dan putem interneta.

Realizacija i implementacija aplikativnog rješenja odnosno GIS sustava za upis i vođenje evidencije postojećih grafičkih i opisnih podataka o podacima pomorskog dobra, osigurava:

- vizualizaciju granica, područja i koncesija pomorskog dobra i prikaz opisnih podataka u Web GIS pregledniku koji omogućuje autentifikaciju korisnika i razinu pregleda ovisno o dodijeljenim pravima korisnika,
- evidenciju i ažuriranje postojećih i novih granica, područja i koncesija pomorskog dobra sa pripadajućim opisnim podacima,
- strukturiranje, povezivanje i pridruživanje prateće dokumentacije potrebne za donošenje rješenja, obavijesti, izvadaka i ostale dokumentacije.

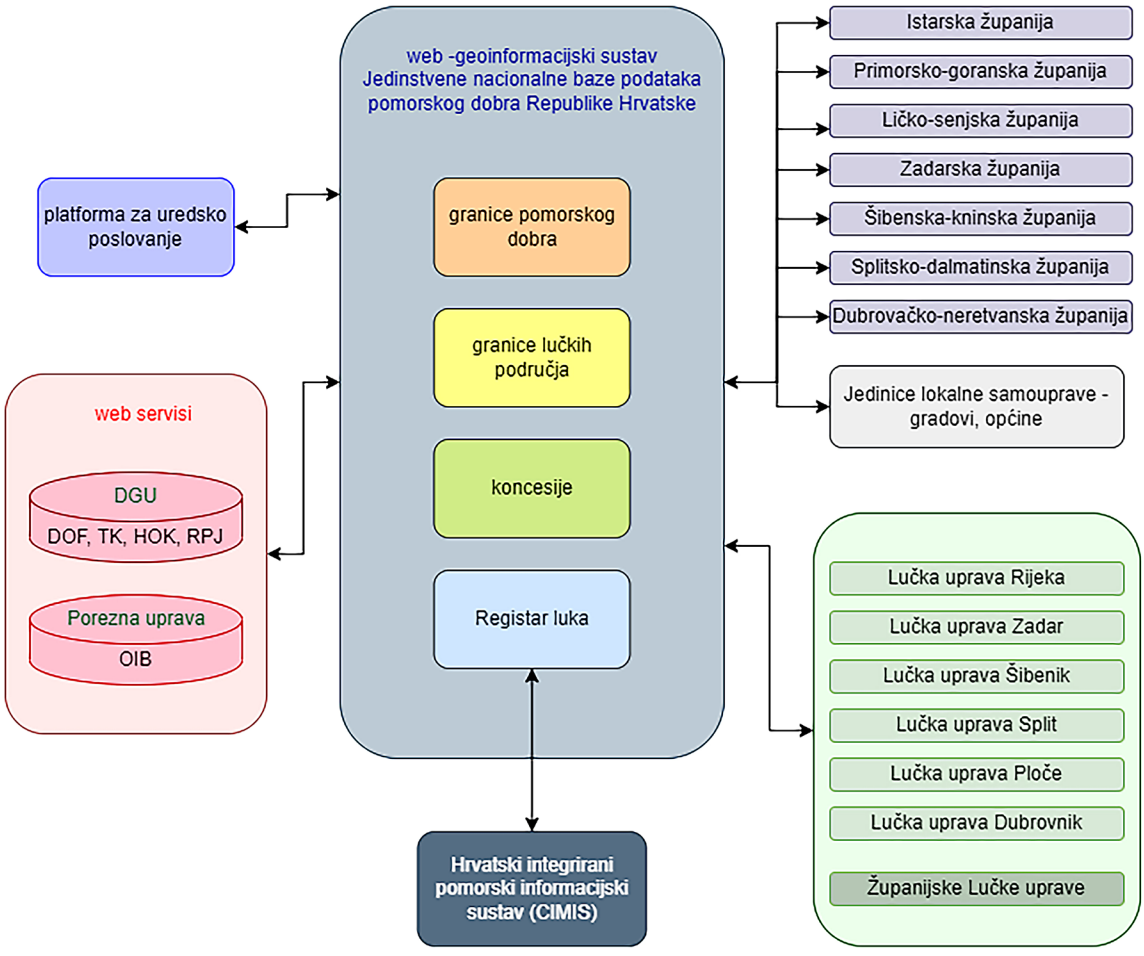
Arhitektura aplikativnog web GIS rješenja za upravljanje nad Jedinstvenom nacionalnom bazom podataka pomorskog dobra Republike Hrvatske prikazano je na Slici 2 gdje su lijevo prikazane integracije sa servisima Državne geodetske uprave (DGU) u svrhu grafičkog prikaza kartografskih podloga, sa Poreznom upravom u svrhu preuzimanja OIB podataka i vezanih podataka o osobi, te s platformom za uredsko poslovanje u cilju objedinjenog upravljanja dokumentima i pismenima i vezanim prilozima u procesu uredskog poslovanja. U donjem dijelu sheme prikazana je integracija sa internim sustavom Ministarstva, s kojim se razmjenjuju dokumenti i informacije potrebni za održavanje Registra luka. Desno su prikazane integracije sa jedinicama područne(regionalne) i lokalne samouprave te lučkim upravama, koje usko surađuju na procesima upravljanja pomorskim dobrom te kroz odgovarajuću razinu pristupa mogu upravljati svojom domenom pomorskog dobra kroz centralno web GIS aplikativno rješenje.

Aplikativno GIS rješenje podržava funkcionalnosti autentifikacije korisnika sukladno danim ovlastima definiranim od strane administratora kroz administracijski modul, te evidentiranje granica pomorskog dobra u Bazi pomorskog dobra na kopnenom (priobalnom) dijelu, na moru kao i za luke i lučka područja.

Modul za granice pomorskog dobra i lučka područja podržava upis i izmjenu granice i područja kroz upis prostornih podataka iz različitih koordinatnih sustava:

- HTRS96/TM – Službeni koordinatni sustav RH,
- WGS84 – World Geodetic System 1984,
- GK 5 – Gauss-Krüger 5 Zona i
- GK 6 – Gauss-Krüger 6 Zona.

Kroz web GIS rješenje omogućeno je pretraživanje granica pomorskog dobra prema različitim kriterijima odnosno prema atributnim podacima pomorskog dobra – po upisu kriterija i po izvršenom upitu pretra-



Slika 2: Arhitektura web-GIS rješenja za upravljanje pomorskim dobrom

ge prikazuju se rezultati pretrage georeferencirani sa kartom što znači da odabirom pojedinog zapisa iz rezultata, pogled na karti se automatski pozicionira i prikaže granicu odabranog pomorskog dobra.

Također, kroz aplikaciju je omogućeno pridruživanje i povezivanje prateće dokumentacije iz upravnog postupka za donošenje rješenja – korisnici s pravima za upis i izmjenu podataka kroz sučelje Web GIS preglednika mogu učitavati i pridruživati prateću dokumentaciju različitih formata, pregledavati, preuzimati i brisati učitanu dokumentaciju.

Modul Upisnik koncesija upravlja postupkom upisa, evidentiranja i upravljanja dodijeljenim koncesijama nad pomorskim dobrom i prati životni tijek koncesija kroz pripadajuće rokove, naknade, založna prava, terete i ostale parametre. Upisnik koncesija je javna knjiga koja se sastoji od Glavne knjige, zbirke isprava i Dnevnika upisnika, a Glavna knjiga se sastoji od uložaka. Glavna knjiga je organizirana po uzoru na Zemljišnu knjigu i sastoji od listova A, B i C:

- U list A Uloška Glavne knjige upisuje se:
  - Odluka o koncesiji, Ugovor o koncesiji, opis područja (karata) i ukupna površina pomorskog dobra, namjena i rok koncesije, građevinske i uporabne dozvole,
- U list B Uloška Glavne knjige upisuje se:
  - ime i/ili naziv ovlaštenika koncesije, adresa odnosno sjedište i matični broj,
  - prijenos koncesije,
  - prestanak koncesije.
- U list C Uloška Glavne knjige upisuje se
  - zalog na koncesiji i potkoncesija.

Pored Ministarstva, Upisnik koncesija koriste i Upravno tijelo za poslove pomorstva u županiji za koncesije koje daje županijska skupština, Lučka uprava za koncesije koje daje lučka uprava, općina/grad - ukoliko je mu je povjereno ovlaštenje za davanje koncesije.

Modul Registar luka sadrži podatke obuhvata luka i kroz jedinstveno web GIS aplikativno rješenje povezan je s CIMIS (eng. Croatian integrated maritime information system) aplikacijom za integrirano upravljanje morskim informacijama.

4. Zaključak

Pomorsko dobro Republike Hrvatske je resurs iznimne vrijednost za državu, njene stanovnike i gospodarstvo. Za učinkovito i održivo gospodarenje pomorskim dobrom, potrebno je imati točne evidencije položaja i obima pomorskog dobra, granica pomorskog dobra, koncesija, luka i lučkih područja, te efi-

kasan sustav provođenja upravnih i neupravnih postupaka. Uspostavljeno web GIS aplikativno rješenje omogućuje centralnu pohranu svih podataka pomorskog dobra, alfanumeričkih i grafičkih, jednostavan pristup preko Interneta, dijeljenje određenih informacija sa određenim dionicima sukladno njihovoj razini pristupa i ovlasti, te učinkovito i održivo upravljanje pomorskim dobrom i pratećom ekonomijom. Uspostava ovakvog sveobuhvatnog informacijskog sustava upravljanja Jedinstvenom nacionalnom bazom podataka pomorskog dobra Republike Hrvatske od strateške je važnosti za učinkovito gospodarenje pomorskim dobrom. Razvojem i implementacijom ovog sustava ostvareni su preduvjeti za javni dio geoportala podataka pomorskog dobra i dijeljenje podataka kroz NIPP, tj. sukladno INSPIRE direktivi.

Literatura

NN (158/03, 100/04, 141/06, 38/09, 123/11, 56/16, 98/19): Narodne novine, Zakon o pomorskom dobru i morskim lukama, na snazi od 1.1.2020.

URL 1: Hrvatska ukratko, https://croatia.eu/index.php?view=article&id=6&lang=1, (24.6.2022.)

Establishment of a Web GIS Solution and a Unique National Database of Maritime Domain of the Republic of Croatia

Abstract

The maritime domain is a public domain of interest of the Republic of Croatia and it has its special protection regarding it is a resource of exceptional value for the state, its inhabitants and the economy. For the efficient and sustainable management of the maritime domain, a unique national database of the spatial maritime domain data of the Republic of Croatia was established, which through a web GIS application centrally consolidates accurate and official data of the location and area of maritime domain including borders of the maritime domain, concessions, ports and port areas, following by business process of implementation and processing requests from third parties and Government decisions. The central unified geo-information system through the web GIS application solution enables easy access via the Internet to all registered users throughout Croatia, central storage of all maritime property data and efficient and sustainable management of maritime property and the accompanying economy. This paper presents the structure and possibilities of a unique integrated geo-information system of maritime property and concessions of the Republic of Croatia.

Keywords: *boundaries of maritime property, maritime concessions, maritime property, unique national database of maritime property, web GIS solution*

Prostorno planiranje na moru

Jelena Kilić Pamuković[1], Katarina Rogulj[2], Ivana Racetin[3], Ljerka Vrdoljak[4]

[1] Fakultet građevinarstva, arhitekture i geodezije Sveučilišta u Splitu, Matice hrvatske 15, Split, Hrvatska, jkilic@gradst.hr

[2] Fakultet građevinarstva, arhitekture i geodezije Sveučilišta u Splitu, Matice hrvatske 15, Split, Hrvatska, katarina.rogulj@gradst.hr

[3] Fakultet građevinarstva, arhitekture i geodezije Sveučilišta u Splitu, Matice hrvatske 15, Split, Hrvatska, iracetin@gradst.hr

[4] Hrvatski hidrografski institut, Ul. Zrinsko Frankopanska 161, Split, Hrvatska, ljerka.vrdoljak@hhi.hr

Sažetak

Europski parlament i Vijeće Europske unije donijeli su Direktivu 2014/89/EU 23. srpnja 2014. godine kojom se uspostavlja okvir za prostorno planiranje na moru (engl. Maritime spatial planning – MSP) u EU. MSP je posljednjih godina postao predmetom mnogih znanstvenih i stručnih istraživanja. Odnosi se na javni proces analize i raspodjele prostorne i vremenske distribucije ljudskih aktivnosti u morskim područjima radi postizanja ekoloških, ekonomskih i društvenih ciljeva. MSP je također usmjeren na participativni pristup koji zahtijeva uključivanje svih relevantnih dionika u proces donošenja odluka. Vrlo je važno uključiti sve relevantne dionike u što ranijoj fazi procesa planiranja kako bi se postiglo široko prihvaćanje procesa i podrška provedbi. Hrvatska, iako izrazito pomorska zemlja, još uvijek nema cjeloviti pravni okvir za postavljanje MSP-a te ne postoji jedinstveni plan za cjelokupno hrvatsko morsko područje. Okosnicu zakonodavstva o prostornom uređenju u Hrvatskoj čini Zakon o prostornom uređenju. Izmjena i dopuna ovoga Zakona (Narodne novine, 2013) stupila je na snagu u srpnju 2017. godine, čime je također omogućen potpuni prijenos MSP Direktive u zakonodavstvo Republike Hrvatske. Ovaj rad dat će teorijski okvir o MSP-u te pregled o statusu MSP-a u zemljama članicama EU, s posebnim naglaskom na područje Republike Hrvatske.

Ključne riječi: *Europska unija, prostorno planiranje na moru, Republika Hrvatska*

1. Uvod

Prostorno planiranje na moru (engl. Maritime spatial planning – MSP) je posljednjih godina postalo predmetom velikog interesa za pomorske zemlje. Razlog su sve veći zahtjevi u zaštiti morskog okoliša. Proces uspostave morskih zaštićenih područja (MZP) značajno kasni za uspostavom onih na kopnu, a razlozi uglavnom leže u činjenici da su mora i oceani ljudima dugo bili nepoznati i da su smatrani beskonačnim resursom (URL 1). MSP se može definirati kao proces analize i organiziranja vremenskih i prostornih ljudskih aktivnosti u morskom okolišu radi postizanja ekoloških, ekonomskih i društvenih ciljeva (URL 2). Sustavno razumijevanje morskog područja zahtijeva integraciju velike količine različitih prostornih i neprostornih podataka. Ciljevi upravljanja morskih područjem trebali bi se ostvariti korištenjem odgovarajućeg načina prikupljanja podataka iz različitih izvora, koji uključuju okolišne, društvene, kulturne i ekonomske podatke, prikupljene u skladu s propisima EU (Depellegrin i dr., 2017). Rezultat bi trebao biti baza znanja koji bi omogućila osim uvida u podatke vanjskih izvora i kreiranje novih podataka kao rezultat različitih metoda, uključujući i one temeljene na umjetnoj inteligenciji. Neusklađenost subjekata koji koriste morski i priobalni prostor nametnula je potrebu za pronalaskom metodologije koja će omogućiti sinergiju različitih korisnika prostora i prirodnih resursa. Metodologija bi obuhvaćala cijeli proces upravljanja, od planiranja djelovanja na moru pa to provedbe, nadzora, evaluacije, istraživanja, sudjelovanja javnosti i na kraju financiranja svih aktivnosti (Zekić i Luttenberger, 2017). Upravljanje morskim područjem zahtijeva adekvatnu politiku kao i integraciju različitih sektorskih pristupa i interesa u koherentan skup mjera. Takav integrirani pristup bi omogućio učinkovitu koordinaciju različitih upravljačkih tijela uključenih u procese donošenja odluka. Iz svega navedenog, sve veći zahtjevi u upravljanju prostorom, koji direktno utječe na kvalitetu života svih korisnika istoga, su usmjereni u primjeni participativnog pristupa odlučivanja i upravljanja. Participativni pristup nalaže uključivanje svih relevantnih dionika, od upravljačkih tijela pa do dionika kao korisnika promatranog prostora, u procese donošenja odluka. Skupine dionika bi uključivale i nevladine organizacije kao i svakog pojedinca koji je zainteresiran za razvoj pojedinog područja. Upravo to lokalno i regionalno znanje je od posebne važnosti za detaljno razumijevanje problematike, a može biti dostupno samo preko generacija ljudi koji žive na tom prostoru (Jajac i dr., 2018). Ovisno o složenosti izazova koji se mora riješiti tijekom procesa prostornog planiranja pojedine aktivnosti na

moru, učinkovito bi bilo planirati više faza uključivanja dionika omogućujući opsežnu razmjenu mišljenja i raspravu o uključenim pitanjima (Schaefer i Barale, 2011). Važno je istaknuti i znanstvena znanja koja su tradicionalno marginalizirana u sustavima prostornog upravljanja, pa tako i prostornog upravljanja na moru. Proces donošenja krajnjih odluka je izrazito složen proces ukoliko se uzimaju u obzir svi relevantni podaci, svi utjecajni kriteriji često međusobno konfliktni i naizgled neusporedivi te ukoliko se teži uključivanju svih dionika na koje utječu donesene odluke. Upravo znanstveno znanje, koje uključuje i specifično znanje o konkretnog problemu, može olakšati proces integracije navedenih elemenata u jedinstveni sustav odlučivanja, a sve u cilju definiranja jedinstvenog cilja djelovanja. Međusobna suradnja je posebno važna i između znanstvenika različitih područja, a u cilju pronalaženja jedinstvenih alata koje treba koristiti kao osnovu za kreiranje politika i upravljanja u europskom kontekstu (de Jonge i dr., 2012). Zbog velikog broja različitih podataka i višesektorskih i višerazinskih dionika te njihovih različitih potreba i korištenja morskog područja, MSP je organiziran kao prostorno eksplicitni proces donošenja odluka kako bi se uspostavilo racionalno koordinacija između različitih ciljeva, s velikim naglaskom na održivo korištenje morskih resursa (Ehler i Douvere, 2009).

U radu će biti prikazani primjeri dobre prakse prostornog planiranja na moru na razini Europske unije s posebnim naglaskom na status uspostave MSP sustava u Republici Hrvatskoj.

2. Prostorno planiranje na moru u zemljama članicama Europske unije

Europski parlament i Vijeće Europske unije donijeli su Direktivu 2014/89/EU 23. srpnja 2014. godine kojom se uspostavlja okvir za prostorno planiranje na moru (engl. Maritime spatial planning – MSP) u EU. Europska unija ima 22 države članice s pristupom moru. Prema Direktivi o MSP-u 22 državne članice Europska unije obvezne su bile izraditi nacionalne pomorske prostorne planove najkasnije do 31. ožujka 2021. godine. No, unatoč obvezi, državne članice su trenutno u različitim fazama uspostave MSP-a, a planovi su u pripremi, usvojeni ili u reviziji (URL 3). Samo njih 6 je ispunilo rok: Belgija, Danska, Nizozemska, Finska, Latvija i Portugal. Ostalih 16 nije na vrijeme poslalo svoje planove: Njemačka, Francuska, Hrvatska, Cipar, Estonija, Grčka, Irska, Italija, Litva, Malta, Poljska, Slovenija, Švedska, Rumunjska, Bugarska i Španjolska (URL 4). Postoji značajna razlika između država članica na razini do koje su načela MSP-a razvijena i/ili provedena. Iz toga razloga Direktiva EU-a o MSP-u daje mogućnost državama članicama slobodu u osmišljavanju i određivanju formata i sadržaja svojih pomorskih prostornih planova, uključujući institucionalne aranžmane i raspodjelu pomorskih aktivnosti. Omogućena je autonomija država u donošenju odluka, međutim uvjetovana je obvezom koja je postavljena za usklađenost politike i institucija s određenim zahtjevima iz Direktive o (Zervaki, 2015):

(a) opći okvir za realizaciju MSP-a u morskim vodama EU: planovi bi trebali biti utemeljeni na poboljšanom pristupu temeljenom na ekosustavu, uzimajući u obzir ne samo okoliš, ekonomske i socijalni aspekti, već i sigurnosne aspekte,

(b) interakcija kopno-more: Direktiva, iako isključuje Integralno upravljanje obalnim područjem (IUOP) iz svog područja primjene, ima za cilj promicati usklađenost između MSP-a i praksi postojećih država u IUOP-u ili ekvivalentnim formalnim ili neformalnim praksama,

(c) prekogranična suradnja MSP-a: države članice koje graniče s morskim vodama obvezne su surađivati dok, u slučaju država članica koje graniče s trećim državama, postoji umjerenija referenca na suradnju budući da je definirano da će države članice „po mogućnosti nastojati surađivati s trećim zemljama".

Nije dovoljno MSP opisati kao postupak prostornog planiranja na moru. MSP je koncept integralnog donošenja odluka i upravljanja korištenjem pomorskog prostora. Dakle, može se reći da je MSP je skup radnji koje vode do (između ostalog) određivanja zona za određene aktivnosti s ciljem stvaranja preduvjeta za ljudsko djelovanje. Da bi ovi postupci bili definirani na ispravan način potrebni su široko stručno i znanstveno znanje o problematici i sveobuhvatni podaci kao što su podaci o geološkim svojstvima promatranog područje, utjecaja na okoliš aktivnosti koje se izvode u tom području te postojanje i intenzitet ostalih aktivnosti na istom području. S obzirom na različitost europskih pomorskih regija (geološko bogatstvo, baza znanja, ekonomski razvoj, način brige o okolišu, kulturološki elementi), nije moguće definirati jedinstveni način organiziranja MSP-a. Iz svega navedenog, Europska komisija je izradila Smjernice za izradu prostornog planiranja na moru u obliku deset instrumenata koji se mogu koristiti za organiziranje MSP-a na ispravan način (URL 5).

Ključne smjernice su (URL 5):

1. Definiranje i korištenje MSP-a prema području i vrsti aktivnosti,
2. Definiranje jasnih ciljeva prilikom uspostave MSP-a,
3. Razvijanje MSP-a na transparentan način,
4. Poticanje sudjelovanja dionika u svih fazama upravljanja,
5. Koordinacija između država članica,
6. Pravno osigurati nacionalni MSP,
7. Provesti prekograničnu suradnju i konzultacije,
8. Uključiti praćenje i evaluaciju aktivnosti u postupak planiranja,
9. Postizanje koherentnosti između kopnenog i pomorskog prostornog planiranja – odnos s IUOP-om,
10. Stvorite snažnu bazu podataka i znanja.

Ključne smjernice omogućuje uspostavljanje MSP-a na ispravan način. S obzirom da je morsko područje trodimenzionalan prostor koji obuhvaća morsko

dno, morski stupac i površinu, potrebno je voditi računa o koordinaciji aktivnosti na njemu (Zekić i Luttenberger, 2017). Jednako tako, nije potrebno uspostaviti MSP za cijelo morsko područje pojedine države, već za u velikoj mjeri iskorištena i ranjiva područja. Vodeći računa o svim smjernicama, u Priručniku o morskom prostornom planiranju: Korak po korak prema ekosustavnom upravljanju definirana je proces uspostave MSP-a u državama članicama u deset ključnih koraka (URL 6):

1. Identifikacija potreba i uspostava ovlasti,
2. Dobivanje financijske potpore,
3. Organiziranje postupka prije planiranja,
4. Organizacija sudjelovanja dionika,
5. Definiranje i analiza postojećih uvjeta,
6. Definiranje i analiza budućih uvjeta,
7. Priprema i odobravanje morskog prostornog planiranja,
8. Implementacija i primjena morskog prostornog planiranja,
9. Monitoring i evaluacija,
10. Prilagodba postupka morskog prostornog planiranja.

U Tablici 1 je prikazano trenutno stanje uspostave MSP-a u pojedinim državama članicama Europske unije (URL 3).

Tablica 1: Status MSP-a pojedine zemlje u Europi.

	Naziv (radnog) plana	Radna verzija	Buduće planiranje (vizija)	Konačna verzija MSP plana	Implementacija
Njemačka	(a) MSP za Baltičko more (b) MSP za Sjeverno more	Prva radna verzija (zima 2019/2020)	Različite verzije planova (proljeće 2019.)	2021.	2021.–2022.
Španjolska	Koordinacijski plan za morski prostor	2020.	Nova radna verzija plana	Početak 2022.	2022.
Francuska	Strateški dokument za morski zaljev	Objavljena u rujnu 2018.	Nacrt plana za svaki morski zaljev (siječanj 2018.)	–	Planirano za 2022.
Belgija	MSP za belgijski dio Sjevernog mora	Objavljena 28. lipnja 2018.	Dugoročno planiranje	7. prosinca 2018.	Stupio na snagu 20. ožujka 2020.
Nizozemska	Program – Sjeverno more (2022.–2027.)	Ožujak 2021.	Prostorno planiranje bazirano na studiji iz svibnja 2018.	Ožujak 2022.	2022.
Portugal	Nacionalni plan za prostorno planiranje na moru	Druga verzija plana (2019)	Prva verzija plana (2018)	2019.	2021.
Grčka	–	2021.	Nacionalna strategija za prostorno planiranje na moru	–	–
Švedska	MSP za Botnički zaljev, Sjeverno more i Skagerrak	Zima 2017.	–	Predan prijedlog vladi (prosinac 2019.)	2022.
Italija	–	Započeto: strateški ciljevi uključeni u Upute za izradu MSP-a	Definiranje regija i kartiranje	–	–
Hrvatska	–	Državni plan za prostorni razvoj	Strategija za prostorni razvoj (2017.)	–	–

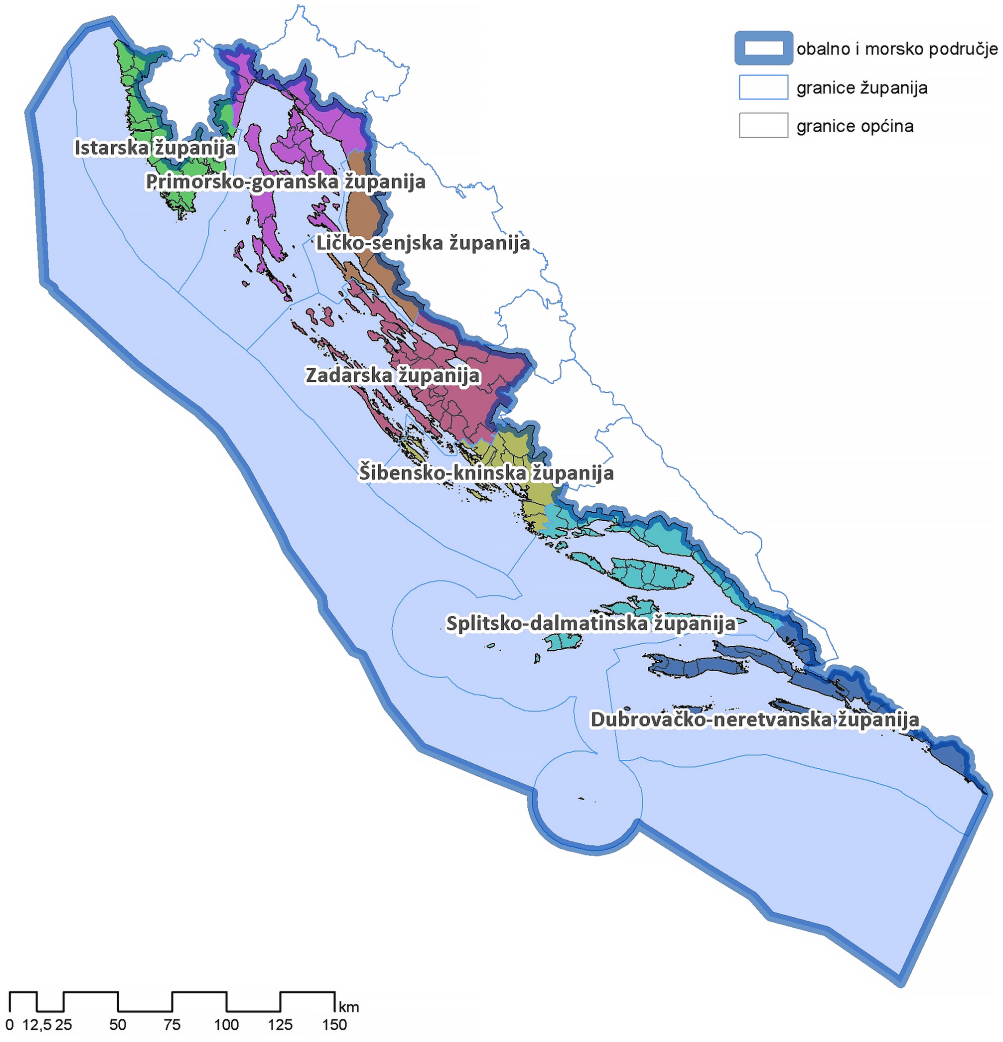
3. Prostorno planiranje na moru u Hrvatskoj

Hrvatske nacionalne vode zauzimaju površinu od 31 479 km² (35,7% cjelokupnog teritorija), dok je obalna crta duga 6278 km. Obala se sastoji od 1880 km na kopnu i 4398 km na otocima. Ima 1244 otoka, otočića, hridi i grebeni (otoci i otočići 602, stijene i grebeni 642). Samo 47 otoka je stalno naseljeno (URL 7).

Trenutno ne postoji jedinstven plan MSP-a za cjelokupno hrvatsko morsko područje, već je cijelo područje Republike Hrvatske obuhvaćeno različitim prostornim planovima koji obuhvaćaju i kopnena i morska područja. Temeljem zahtjeva Zakon o prostornom uređenju započeta je izrada Državnog plana prostornog uređenja za cjelokupno kopneno i morsko područje (do vanjske granice teritorijalnih voda) Republike Hrvatske. Također su izrađeni i prostorni planovi za zaštićena kopnena i morska područja (pod upravom nacionalnih tijela) te planovi županija koji uključuju odredbe za različite aktivnosti na morskom području (pod upravom podnacionalnih tijela) (URL 7).

Zakon o prostornom uređenju predstavlja zakonodavnu osnovu prostornog uređenja kako kopnenog, tako i morskog područja. Izmjenama i dopunama Zakona (Narodne novine, 2013) koje su stupile na snagu 2017. godine omogućen je potpuni prijenos EU MSP Direktive u zakonodavstvo Republike Hrvatske. One uključuju odredbe koje se odnose na definiciju, ciljeve i načela MSP-a, suradnju Hrvatske s ostalim državama članicama EU na području MSP-a u Jadranskom moru, suradnju sa zemljama koje nisu članice EU i definiranje nadležnih tijela za MSP. Prema Zakonu o prostornom uređenju (čl. 49, a-f), planovi koji uključuju morska područja su (URL 7):

1. Državni plan prostornog razvoja koji obuhvaća cjelokupno područje Republike Hrvatske, do vanjske granice teritorijalnog mora. Izrada plana započela je odlukom Vlade RH 26. travnja 2018. (NN 39/2018),
2. Prostorni plan ekološko-ribolovne zaštitne zone Republike Hrvatske,
3. Prostorni plan epikontinentalnog pojasa Republike Hrvatske,
4. Prostorni planovi nacionalnih parkova i parkova prirode koji obuhvaćaju morska područja,
5. Prostorni planovi županija i gradova ili općina koji uključuju morska područja, a gdje se planiranje utvrđuje u skladu s posebnim propisima,



Slika 1: Prostorni obuhvat Strategije (URL 8).

6. Generalni urbanistički planovi i urbanistički planovi uređenja koji obuhvaćaju morska područja.

Direktivom 2008/56/EZ nalaže se državama članicama poduzimanje mjera za postizanje ili održavanje dobrog stanja morskog okoliša najkasnije do 2020. godine. Direktiva predstavlja 'okolišni stup' u svim politikama EU orijentiranim k održivom upravljanju i korištenju prirodnih resursa morskog okoliša. Cilj je razvitak i primjena strategija o moru u okviru kojih se primjenjuje ekosustavni pristup upravljanja ljudskim djelatnostima (URL 8).

Donošenjem Uredbe o uspostavi okvira za djelovanje RH u zaštiti morskog okoliša (NN 136/11) te Uredbe o izradi i provedbi dokumenata Strategije upravljanja morskim okolišem i obalnim područjem (NN 112/14, 39/17, 112/18), u nacionalno zakonodavstvo transponirana je Okvirna direktiva morske strategije 2008/56/EZ. Uredbom se uređuju polazne osnove i mjerila za izradu, razvoj, provedbu i praćenje provedbe Strategije zaštite morskog okoliša ili tzv. „Morske strategije" koja svoju zakonsku obvezu izrade ima u Zakonu o zaštiti okoliša (NN 80/13, 78/15, 12/18, 118/18).

Osnovna svrha Direktive prenesena Uredbom je postizanje i održavanje dobrog stanja morskog okoliša do 2020. godine putem ostvarivanja općih ciljeva zaštite morskog okoliša koji uključuju (URL 8):

- zaštitu, očuvanje, omogućavanje oporavka i obnavljanje morskih i obalnih ekosustava te održivo korištenje ekosustavnih usluga;
- očuvanje zaštićenih područja u moru i ekološki značajnih područja EU NATURA 2000;
- smanjenje onečišćenja u morskom i obalnom okolišu u cilju očuvanja zdravlja ljudi, ekosustava i omogućavanja korištenja mora i obale;
- uspostavljanje i/ili održavanje ravnoteže između ljudskih aktivnosti i prirodnih resursa primjenom ekosustavnog pristupa.

Uredbom (članak 4., stavak 1.) je definiran prostorni obuhvat Strategije (Slika 1) te se navodi da se ona primjenjuje na „...morski okoliš i obalno područje... koji su pod suverenitetom Republike Hrvatske, odnosno u kojima Republika Hrvatska ostvaruje suverena prava i jurisdikciju." Po toj definiciji, prostorni obuhvat Strategije uključuje 140 obalnih gradova i općina, unutarnje morske vode, teritorijalno more, Zaštićeni ekološko-ribolovni pojas (ZERP), epikontinentalni pojas, odnosno morsko dno i podmorje nad kojima Republika Hrvatska obnaša suverena prava (URL 9).

Obzirom da je najveći broj pritisaka, osim na morski okoliš, koncentriran na području uskog obalnog pojasa, do 1000 metara od obalne crte, značajan broj mjera usmjeren je na metodološka unaprjeđenja i upravljačka rješenja kojima se može osigurati zaštita tog prioritetnog područja. Također, budući da se u izradi Strategije primjenjuje i ekosustavni pristup, integralno će se sagledavati i širi prostor od onoga koji je definiran Uredbom, poglavito prostor obalnih županija, ali i svih važnijih obalnih i morskih ekosustava čije granice mogu dosezati i izvan formalnog prostornog obuhvata Strategije (na primjer, područja važna za bioraznolikost, vodne sustave i sl.) (URL 9).

4. Zaključak

Poticaj za ovo istraživanje proizašao je iz Direktive 2014/89/EU Europskog parlamenta i Vijeća od 23. srpnja 2014. kojom se uspostavlja okvir za MSP u EU. Svrha Direktive je pomoć državama članicama da razviju pomorske prostorne planove za bolju koordinaciju različitih aktivnosti na moru na učinkovit i održiv način. MSP obuhvaća cjelokupni postupak održivog upravljanja morskim područjem temeljenog na postizanju ekoloških, ekonomskih i društvenih ciljeva. Svrha MSP-a nije samo izrada planova za morska područja, već je cilj unaprjeđenje cijelog procesa donošenja i provedbe tih planova koje se odnosi na prikupljanje, organiziranje i analizu podataka, usklađivanje znanstvenog i upravljačkog znanja te lokalnog znanja stanovnika na promatranom području, primjena participativnog pristupa upravljanja te na kraju korištenje metodologija i metoda koji će omogućiti jednostavnu integraciju svega navedenog u adaptivan i robustan sustav upravljanja. MSP bi trebao pružiti alternativu tradicionalnom sustavu upravljanja na način da podrži podizanje svijesti brige o okolišu na razinu svakog pojedinca kao korisnika tog prostora. Krajnji cilj je održivost, odnosno održavanje ravnoteže između iskorištavanja morskog prostora i njegove prirodne zaštite. Dugi niz godina se morsko područje iskorištavalo bez jasno definirane kontrole takvih aktivnosti. Rezultat je trajno ili privremeno narušen biodiverzitet mora. Uspostavom MSP definiraju se aktivnosti i mjere koje imaju za cilj sprječavanje opasno za morski okoliš, sprječavanje nastanka štete, otklanjanje postojeće štete te težnja povratku morskog okoliša u stanje prije štete. U radu su dani primjeri dobrih europskih praksi u uspostavi MSP-a, no također su prikazani i podaci u kojima je vidljivo da većina zemalja Europske unije još uvijek nema ispunjene preduvjete za implementaciju MSP-a. Tu spada i Hrvatska kao izrazito pomorska zemlja koja još uvijek nema cjeloviti pravni okvir za uspostavljanje MSP-a. Zadnjim izvješćem o trenutnom stanju uspostave MSP-a u Republici Hrvatskoj iz veljače 2022. godine su dati detaljni podaci o sadašnjim koracima, ali i budućim ciljevima koji bi trebali dovesti do razvoja integralnog održivog sustava upravljanja morskim područjem. S obzirom da smjernice nalažu koordinaciju aktivnosti između zemalja Europske unije, no također i pomorskih zemalja u Europi koje nemaju obvezu u uspostavljanju nacionalnog MSP-a, primjeri dobre prakse upravljanja aktivnostima na moru trebaju dati poticaj svim tim zemljama u trenutnoj zaštiti morskog okoliša.

Literatura

de Jonge, V. N., Pinto, R., Turner, R. K. (2012): Integrating ecological, economic and social aspects to generate useful management information under the EU Directives 'ecosystem approach', Ocean & Coastal Management, 68, 169–188.

Depellegrin, D., Menegon, S., Farella, G., Ghezzo, M., Gissi, E., Sarretta, A., Venier, C., Barbanti, A. (2017): Multi-objective spatial tools to inform maritime spa-

tial planning in the Adriatic Sea, Science of the Total Environment, 609, 1627–1639.

Ehler, C. N., Douvere, F. (2009): Marine Spatial Planning: a Step-by-step Approach Toward Ecosystem-based Management, IOC Manual and Guides br. 53 (Intergovernmental Oceanographic Commission and Man and the Biosphere Programme).

Jajac, N., Kilić, J., Rogulj, K. (2018): Integral approach to the sustainable decision making within maritime spatial planning – DSC to the planning of anchorages on the island of Šolta, Croatia, Sustainability, 1–27.

Narodne novine (2013): Zakon o prostornom uređenju, br. 153/13, 65/17, Zagreb.

Schaefer, N., Barale, V. (2011): Maritime spatial planning: opportunities & challenges in the framework of the EU integrated maritime policy, Journal of Coastal Conservation, 237–245.

Zekić, A., Luttenberger, A. (2017): Doprinos morskog prostornog planiranja zaštiti morskog okoliša, Pomorski zbornik, Posebno izdanje, 283–296.

Zervaki, A. (2015): Introducing Maritime Spatial Planning Legislation in the EU: Fishing in Troubled Waters?, Maritime Safety and Security Law Journal, 1, 95–114.

URL 1: Institut plavi svijet, https://www.plavi-svijet.org/zastita/morska-zasticena-podrucja-i-prostorno-planiranje-na-moru/, (1.6.2022.).

URL 2: Europski parlament i Vijeće (EPC), 2014. Direktiva 2014/89/EU Europskog parlamenta i vijeća od 23. srpnja 2014. o uspostavljanju okvira za pomorsko prostorno planiranje, http://eur-lex.europa.eu/legal-content/EN/TXT/?uri=celex%3A32014L0089, (1.6.2022.).

URL 3: The European Maritime Spatial Planning Platform,

https://maritime-spatial-planning.ec.europa.eu/countries-overview, (12.6.2022.).

URL 4: Wind Europe, https://windeurope.org/newsroom/news/maritime-spatial-planning-most-countries-late-offshore-wind-must-remain-a-priority/, (12.6.2022.).

URL 5: Study on the economic effects of Maritime Spatial Planning, http://www.partiseapate.eu, (16.6.2022.).

URL 6: Marine Spatial Planning: A Step-by-Step Approach toward Ecosystem-based Management, UNESCO IOC, 2008, https://unesdoc.unesco.org/ark:/48223/pf0000186559, (16.6.2022.).

URL 7: The European Maritime Spatial Planning Platform,

https://maritime-spatial-planning.ec.europa.eu/countries/croatia, (20.6.2022.).

URL 8: Republika Hrvatska, Ministarstvo gospodarstva i održivog razvoja, https://mingor.gov.hr/o-ministarstvu-1065/djelokrug/uprava-vodnoga-gospodarstva-i-zastite-mora-2033/strategija-upravljanja-morskim-okolisem-i-obalnim-podrucjem-1441/1441, (22.6.2022.).

URL 9: Strategija upravljanja morskim okolišem i obalnim područjem Republike Hrvatske, https://esavjetovanja.gov.hr, (22.6.2022.).

Maritime Spatial Planning

Abstract

The European Parliament and the Council of the European Union adopted Directive 2014/89/EU on 23 July 2014, which establishes a framework for maritime spatial planning (MSP) in the EU. MSP has become the subject of many scientific and professional research in recent years. It refers to the public process of analysis and distribution of spatial and temporal distribution of human activities in marine areas in order to achieve environmental, economic and social goals. MSP is also focused on a participatory approach that requires the involvement of all relevant stakeholders in the decision-making process. It is very important to involve all relevant stakeholders at the earliest possible stage of the planning process in order to achieve broad acceptance of the process and support for implementation. Croatia, although a highly maritime country, still does not have a comprehensive legal framework for setting up MSP and there is no single plan for the entire Croatian maritime area. The backbone of the legislation on physical planning in Croatia is the Law on Physical Planning. Amendments to this Act (Official Gazette, 153/13, 65/17) entered into force in July 2017, which also enabled the full transposition of the MSP Directive into the legislation of the Republic of Croatia. This paper will provide a theoretical framework on MSP and an overview of the status of MSP in EU member states, with special emphasis on the territory of the Republic of Croatia.

Keywords: *European Union, maritime spatial planning, Republic of Croatia*

Analiza trenutnog stanja i potrošnje energije mobilnih usluga jadranskih marina

Katarina Rogulj[1], Jelena Kilić Pamuković[2], Ivo Lozić[3]

[1] Fakultet građevinarstva, arhitekture i geodezije, Sveučilište u Splitu, Matice hrvatske 15, Split, Hrvatska, katarina.rogulj@gradst.hr

[2] Fakultet građevinarstva, arhitekture i geodezije, Sveučilište u Splitu, Matice hrvatske 15, Split, Hrvatska, jkilic@gradst.hr

[3] Fakultet građevinarstva, arhitekture i geodezije, Sveučilište u Splitu, Matice hrvatske 15, Split, Hrvatska, ivo.lozic@gradst.hr

Sažetak

Analiza trenutnog stanja mobilnih usluga marina Jadranskog mora provedena je s ciljem procjene potrošnje energije i emisija CO2 povezanih s pilot lokacijama marina koje sudjeluju u Interreg projektu DEEP-SEA te je služila kao osnova za usmjeravanje razvoja investicijskih planova za svako pilot područje projekta. Temelji se na metodologijama definiranim u dokumentu SECAP (Sustainable Energy and Climate Action Plans), priručniku za upravljanje mobilnošću SUMP (Sustainable Urban Mobility Plans) te EEA (European Environmental Agency) smjernicama za popisivanje svih onečišćivača zraka, za izračun prometnih i pomorskih tokova te povezanih emisija CO2. Analiza uključuje prostornu analizu marina Jadranskog mora temeljenu na cjelovitom okviru mobilnosti, broju putnika koji koriste vozila u marinama te obujmu aktivnosti nautičke mobilnosti na svakom pilot mjestu. Potrošnja energije generirana pomorskim i cestovnim prometom te posljedične emisije CO2 procjenjuju se korištenjem formula i tablica koje se odnose na najnovije pokazatelje prema EEA smjernicama (emisijski faktori za cestovni promet). Prikupljanje podataka potpomognuto je upitnicima i podatkovnim prilozima koji se dostavljaju djelatnicima marina i njihovim korisnicima.

Ključne riječi: *analiza trenutnog stanja, CO2 emisije, e-mobilnost, marine, potrošnja energije*

1. Uvod

Globalna mobilnost jedan je od glavnih izvora emisija CO2 i potrošnje energije. Javne uprave i operateri mobilnosti često nemaju potrebne vještine i znanja za integraciju energetske učinkovitosti u planiranje mobilnosti i investiranja, stoga je poboljšanje energetske učinkovitosti u smislu smanjenja emisije CO2 izvan ponuđenih strategija i usluga često izostavljeno. Proces planiranja ne predviđa izravnu uključenost glavnih dionika i krajnjih korisnika (Ukić Boljati dr., 2021). Iako akcijski planovi za održivu energiju (SECAP) (Kona i dr., 2018) i planovi održive mobilnosti (SUMP) (Rupprecht Consult, 2019) nastoje prevladati ove kritičnosti, njihova primjena i integracija u provedbi procesa planiranja nije uključena. To pridonosi neadekvatnoj promociji i implementaciji modela održive mobilnosti te ograničava korištenje povezanih usluga. Navedeno je osobito važno u prekograničnim područjima koja karakterizira loša suradnja, nedostatak sinergijskog planiranja prometa i usluga održive mobilnosti te segmentacija prometnog sustava. Postoji potreba za smanjenjem negativnog utjecaja na okoliš onih aktivnosti mobilnosti koje gravitiraju oko nautičkih marina, kroz sustavne, integrirane i učinkovite usluge mobilnosti duž jadranske obale. Marine se uglavnom prikazuju kao lokacije koje jako zagađuju, povećavajući emisije CO2 i potrošnju energije u prijevozu. To su opsežna područja koja bi se mogla učinkovito koristiti za infrastrukturu namijenjenu proizvodnji energije iz obnovljivih izvora te koja bi se mogla koristiti za provedbu održivih usluga. Nekoliko marina već ima stanice za električno punjenje (ECS) smještene duž dokova za napajanje jahti i brodova s dizel motorima. Svijet nautike sve više traži nove modele plovila na električni pogon koji zahtijevaju rješenja za brže punjenje (preko 22 kW). Nadalje, rješenje treba sagledati kroz već dostupna održiva rješenja za mobilnost i implementirati ih kako bi se smanjili negativni utjecaji. Cruz-Pérez i dr. (2022) u svom su istraživanju proučavali utjecaj mobilnosti unutar marina Kanarskih otoka na okoliš. Prikupljeni podaci su obrađeni i pretvoreni u tone ekvivalentnog CO2, koristeći faktore emisija iz službenih izvora. Ortega Piris i dr. (2017) izmjerili su smanjenje emisija CO2 trgovačkih brodova kao posljedicu zamjene tradicionalnih privezanih sustava novim automatskim sustavima korištenjem komparativnog istraživanja. Trstenjak i dr. (2020) istražili su glavne prepreke većoj primjeni obnovljivih izvora energije kao temelj održivosti nautičkog turizma. Ugradnja fotonaponskih modula pokazala se kao optimalno rješenje za smanjuje po-

Tablica 1: Popis marina s njihovim lokacijama i pilot područjem.

Marina	Lokacija	Pilot područje
Porat	Malinska-Dubašnica, Hrvatska	Malinska, Hrvatska
Martinis Marchi	Maslinica, Hrvatska	Maslinica, Hrvatska
Assonautica Provinciale di Trieste	Trieste, Italija	Friuli Venezia Giulia, Italija
Lepanto	Monfalcone, Italija	
Porto San Rocco	Muggia, Italija	
Lega Navale Italiana sezione Ischitella	Foce Varano, Italija	Foggia, Italija
Marina del Gargano	Manfredonia, Italija	
Touristic Port of Rodi Garganico (Maria S.S. della Libera)	Rodi Garganico, Italija	

trošnje fosilnih goriva u pogonu motora, smanjujući emisiju stakleničkih plinova i povećavajući uštedu.

Fokus ovog istraživanja je na uslugama mobilnosti marina jadranske obale koje sudjeluju u Interreg projektu DEEP SEA (Razvoj planiranja energetske učinkovitosti i mobilnih usluga marina na Jadranskoj obali) (URL 1), posljedičnim emisijama CO2 koje se unutar i u okolici marina generiraju te potrošnji energije. Posljedične emisije proizlaze iz mobilnosti koje se odvijaju prilikom dolaska vozila i plovila do marina, njihovim kretanjem unutar i u okolici marina te iz plovidbe.

2. Materijali i metodologija

U ovom odjeljku prikazana je analiza trenutnog stanja mobilnih usluga marina uključenih u aktivnosti DEEP-SEA projekta. U analizi je prikazana potrošnja energije i CO2 emisija generiranih mobilnim uslugama pojedinih marina potrebnih za usmjeravanje razvoja investicijskih planova za svaku marinu. Prikupljanje podataka provedeno je upitnikom za upravitelje marina i upitnikom za korisnike marina. Marine koje su sudjelovale u upitnicima dane su u Tablici 1 zajedno s lokacijom i pilot područjem, a njihov prostorni raspored prikazan je na Slici 1.

Analiza trenutnog stanja temelji se na metodologijama korištenim u okviru dokumenta SECAP, SUMP (Sustainable Urban Mobility Plans) i EAA (European Environmental Agency) (URL 2) iz 2019. godine za izračun prometnih i pomorskih tokova te s njima povezanih CO2 emisija. Za početak je bilo potrebno definirati usluge koje nudi svaka marina, nakon čega je slijedila analiza obujma prometa, uključujući cestovni i brodski prijevoz. U analizu su uključeni podaci o uslugama mobilnosti koje pružaju marine, broj putnika koji koriste cestovna vozila unutar marina te obujam aktivnosti nautičke mobilnosti u svakoj pilot lokaciji. Prikupljeni podaci datiraju iz turističke sezone 2019. godine. Promatrala se mobilnost na obali (kopnu) i off-shore (pomorstvo).

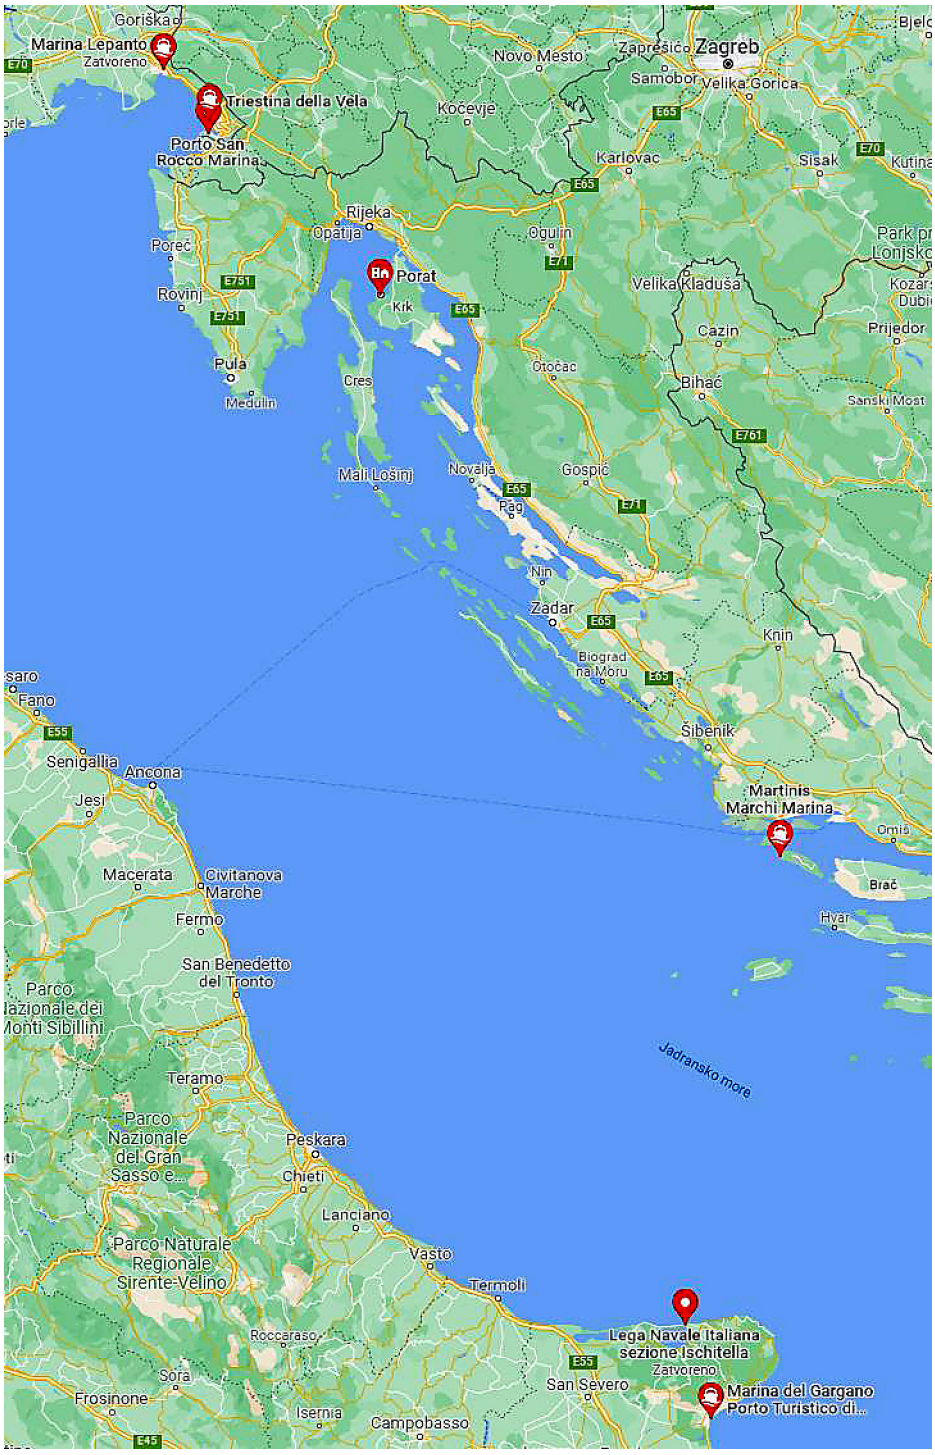
Analiza mobilnosti na obali uključuje:

1. Pristup marinama: analiza tokova prometa do i iz marina; koliko korisnika svake godine cestom stigne u pojedinu marinu; koje vozilo koriste; koliko osoba po vozilu; ukupna udaljenost od polazišta do marine i povratak; ukupna potrošnja goriva i posljedične emisije.
2. Prijevoz na licu mjesta: analiza tokova cestovnog prometa generiranog za turističke posjete (putnici koji se iskrcavaju u marini i posjećuju obližnja mjesta prije ponovnog polaska); broj posjetitelja, korištena vozila, prijeđena udaljenost, ukupna potrošnja goriva i posljedične emisije.

Analiza mobilnosti off-shore uključuje:

1. Pristajanje: potrošnja energije brodova koji pristaju u marinama i posljedične emisije.
2. Prometni tokovi brodova koji gravitiraju oko marina: ukupni broj plovila podijeljenih prema upotrebi (duge/kratke vožnje, iznajmljene/privatne), vrsti plovila (jedrilica/motorni brodovi), vrsti goriva, ukupnom prijeđenom putu po godini/putovanju, ukupnoj potrošnji goriva i posljedične emisije.

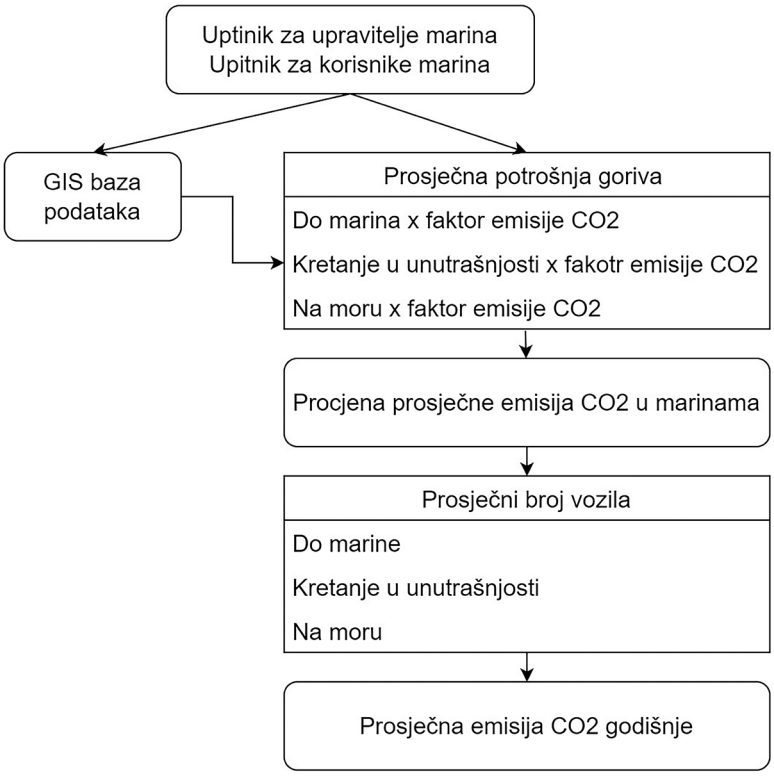
Prikupljanje podataka provedeno je putem upitnika za upravitelje marina koji su uključeni u istraživanje i upitnika za korisnike marina. Radi se o dvama različitim upitnicima za prikupljanje podataka o opskrbi električnom energijom, potrošnji, obnovljivoj energiji, količini putnika, izboru mobilnosti za pristup marini i za posjet obližnjim mjestima, podaci o plovilima itd. Upravitelji marina raspolagali su podacima prikupljenim iskustveno ili iz baza podataka koja mogu odstupati od podataka dobivenim od korisnika. Iz tog razloga, prikupljena su dva seta podataka. Formirana je potom i GIS baza podataka. Pri izračunu emisija CO2 vozila i plovila u obzir su uzeti podaci prikupljeni upitnikom za korisnike marina Porat i Martinis Marchi. Upitnik za korisnike nije proveden za marine na talijanskoj strani Jadranskog mora, no jest za upravitelje tih marina. Upitnikom za korisnike ma-



Slika 1: Prostorni prikaz marina.

rina definirale su se sljedeće potrošnje: prosječna potrošnja goriva (l) prijevoznog sredstva kojim se stiže do marina, prosječna potrošnja goriva (l) prijevoznog sredstva koje se koristi za kretanje po unutrašnjosti te prosječna potrošnja goriva (l) po putovanju plovila usidrenih u marinama.

Prosječna potrošnja goriva u litrama najprije se pretvara u prosječnu potrošnju goriva izraženu u kg, uzimajući u obzir stvarnu masu litre benzina (0,68 kg) i dizela (0,835 kg). Prosječna emisija CO2 [kg CO2] izračunata je množenjem prosječne potrošnje goriva [kg] s odabranim faktorom emisije (EF). Međutim, budući da smjernice za pomorsku plovidbu ne sadrže EF za CO2, odlučeno je primijeniti EF iz EEA vodiča iz 2019. godine za cestovni prijevoz, budući da rekreacijska plovila koriste istu vrstu goriva kao i cestovna vozila. Stoga je CO2 EF za benzin i dizel prema izvorima EEA jednak 3.169 g CO2/kg goriva. Na Slici 2 prikazan je dijagram toka proračuna godišnjih emisija CO2 u marinama.



Slika 2: Dijagram toka proračuna godišnjih emisija CO2.

3. Rezultati

Kako bi se izračunale ukupne godišnje emisije CO2 pri dolasku u marine, prosječne emisije CO2 se množe s prosječnim brojem vozila i plovila koji stignu do marina Porat i Martinis Marchi, a koji iznosi 7.050 prema izjavama upravitelja marina u povezanom upitniku. Ovu pretpostavku omogućila je činjenica da svi posjetitelji do marine Porat dolaze privatnim ili iznajmljenim vozilom ili kombijem, dok do Martinis Marchi 5% koristi privatno vozilo, a 95% dolazi brodom. No, prema podacima prikupljenima od strane korisnika, glavno prijevozno sredstvo koje posjetitelji koriste za pristup marinama su privatni ili iznajmljeni automobili (75%), a zatim brodovi (25%). Što se tiče emisija povezanih s mobilnošću na obali, prosječan broj vozila/plovila koji godišnje dođu do marina množi se s 0,45 jer se svega 45% ispitanika na upitniku izjasnilo da se kreće po marini. Nadalje, za off-shore mobilnost, godišnje emisije CO2 računaju se tako da se prosječne emisije CO2 po putovanju množe s prosječnim brojem putovanja intervjuiranih putnika u jednoj godini (67 putovanja).

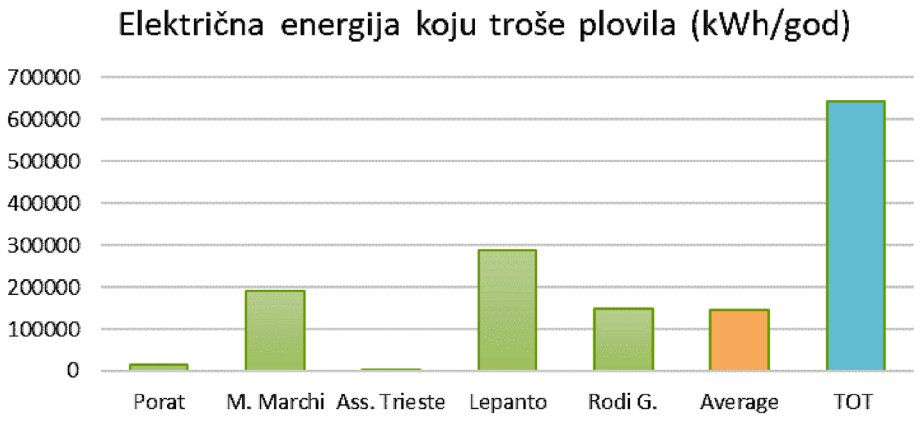
Što se tiče mjesta polaska putnika, 58% upravitelja marina izjavilo je da je ono manje od 300 km udaljeno od marine, naglašavajući time prisutnost uglavnom domaćih posjetitelja, koji dolaze iz iste države ili susjednih područja. S obzirom da se 6 od 8 marina nalazi u Italiji, većina posjetitelja dolazi iz Italije ili iz bliže okolice. Tako je 62% marina navelo Italiju kao zemlju polaska, 12% Austriju, a 9% Njemačku i Hrvatsku. Prema rezultatima upitnika kojeg su ispunili korisnici marina, u marine Porat i Martinis Marchi, 72% putnika dolazi iz Hrvatske, a ostali dolaze iz drugih dijelova Europe.

3.1. Potrošnja energije u pilot područjima

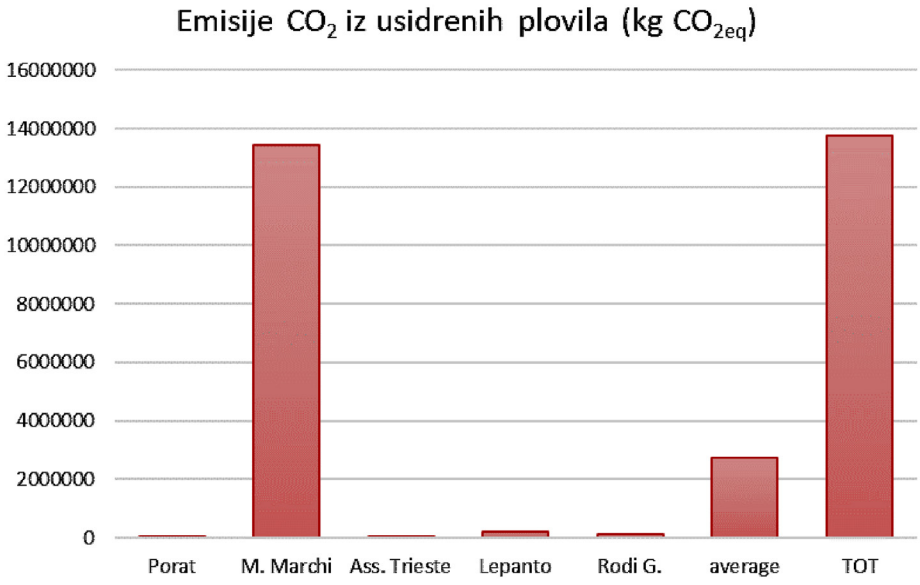
Prema povijesnim podacima o prosječnoj godišnjoj potrošnji električne energije, 5 od 8 marina, koliko ih je ispunilo navedeni podatak, godišnje potroši u prosjeku 325.000 kWh. Ovi podaci o potrošnji električne energije također su korišteni za izračunavanje odgovarajuće prosječne emisije CO2. Budući da je samo 5 od 8 marina ispunilo upitnik s postotkom električne energije koju apsorbiraju usidrena plovila, bilo je moguće procijeniti električnu energiju koju plovila troše i pripadajuće emisije CO2 samo za ove marine. Marina Lepanto ima najveću potrošnju energije, a slijede je Martinis Marchi i Rodi Garganico, kako je prikazano na Slici 3. Ukupna energija koju troše usidreni brodovi iznosi gotovo 642.000 kWh godišnje, dok je ukupna emisija CO2 za pogon tih brodova jednaka 13.777,155 tona (Slika 4).

3.2. Ukupne generirane emisije CO2

Kako je navedeno u metodologiji, za izračun emisija CO2 generiranih iz mobilnost na obali i mobilnosti off-shore, potrebni su podaci o potrošnji goriva prijevoznih sredstava u svakoj marini. Potrebne podatke iz upitnika upućenog korisnicima marina dostavile su samo dvije marine, Porat i Martinis Marchi. Podaci su potom agregirani i korišteni za procjenu emisija CO2 koje nastaju iz kopnenog pristupa marinama, kreta-



Slika 3: Električna energija troše plovila, izražena u kWh godišnje.



Slika 4: Emisije CO2 (kg CO2eq) iz pogona plovila.

nju na licu mjesta (unutar i oko marina) te pomorskog prometa. Prema upitniku, 76% ispitanika izjasnilo se da koristi dizelsko vozilo za dolazak do marine, 24% benzinsko vozilo, a električno vozilo 0%. Na temelju vrste korištenog goriva prilikom dolaska u marinu, izračunata je prosječna potrošnju goriva i posljedične emisije CO2 kako je prikazano u Tablici 2.

Sličan izračun može se napraviti za procjenu ukupnih emisija CO2 koje godišnje ispuštaju vozila koja se kreću unutar i u okolici marina. Procjena uzima u obzir da se 45% putnika kreće po unutrašnjosti, uglavnom koristeći privatna/iznajmljena vozila. Nadalje je u Tablici 3 prikazana prosječna potrošnja goriva i emisije CO2 za kretanja vozila na licu mjesta (unutrašnjost i okolica marina).

Potrošnja goriva prilikom mobilnosti korisnika na moru te posljedične emisije CO2 prikazane su u Tablici 4.

Na temelju prikazanih rezultata, ukupna prosječna emisija CO2 koju godišnje ispuštaju vozila i plovila

Tablica 2: Prosječne emisije CO2 prilikom dolaska do marina.

	Benzin	Dizel
Prosječna potrošnja goriva [kg]	2.113	21.790
Prosječna emisija CO2 [kg]	6,7	69,1
Prosječna emisija CO2 godišnje [kg CO2 godišnje]	47.217,30	486.817,24
Prosječna emisija CO2 godišnje (benzin+dizel) [t CO2 godišnje]	534,03	

Tablica 3: Prosječne emisije CO2 prilikom putovanja unutar i u okolici marina.

	Benzin	Dizel
Prosječna potrošnja goriva [kg]	329	27.701,10
Prosječna emisija CO2 [kg]	1	87,8
Prosječna emisija CO2 godišnje [kg CO2 godišnje]	3.307	278.497
Prosječna emisija CO2 godišnje (benzin+dizel) [t CO2 godišnje]	281,80	

Tablica 4: Prosječne emisije CO2 prilikom putovanja korisnika na moru.

	Benzin	Dizel
Prosječna potrošnja goriva [kg]	204,2	809,7
Prosječna emisija CO2 [kg]	0,6	2,6
Prosječna emisija CO2 godišnje [kg CO2 godišnje]	305.654	1.212.092
Prosječna emisija CO2 godišnje (benzin+dizel) [t CO2 godišnje]	1.517,75	

koja gravitiraju oko jadranskih marina Porat i Martinis Marchi iznosi 2.333,58 t/god. Kako bi se dobila robusnija analiza trenutnog stanja i rezultati bili reprezentativniji, potrebno je još prikupiti podatke od korisnika marina na talijanskoj strani jadranske obale.

4. Zaključak

Kako bi se smanjile emisije CO2 koje nastaju prometnim tokovima unutar i u okolici jadranskih marina, ključno je započeti na konkretan način podržavati širenje e-mobilnosti i općenito energetski održivih rješenja u obalnim područjima. Prema upitniku kojeg su ispunili upravitelji marina, ni jedna marina nije opremljena punionicama za e-bicikle i e-motore, niti uslugama iznajmljivanja e-bicikala ili e-skutera. Što se tiče e-plovila, samo turistička luka Rodi Garganico (Italija) ima posebne utikače za punjenje električnih brodova i jahti, s ukupnim brojem od 300 utikača. Uz to, s obzirom na odgovore korisnika marina Porat i Martinis Marchi, velika većina ispitanika izjasnila se da je zainteresirana za mogućnost dijeljenja e-bicikala i e-skutera. Dobiveni rezultati ističu potrebu da jadranske marine trebaju početi ulagati u rješenja i tehnologije održive mobilnosti, počevši od razvoja osnovnih usluga za korisnike marina. Ova bi akcija zahtijevala i infrastrukturne radove (npr. instalaciju sustava za punjenje) i kupnju električnih vozila i bicikala, ovisno o protoku prometa i broju putnika u svakoj marini. Paralelno s tim, kako se ni jedna od marina nije izjasnila da ima ad-hoc punionice za e-automobile, još jedna važna investicija bila bi predvidjeti postavljanje električnih punionica za automobile, a s obzirom na zahtjeve korisnika marina i za električna plovila. Nadalje, kako bi se poboljšala energetska tranzicija (i energetska neovisnost) marina, ključni korak bio bi razvoj i instalacija rješenja mikromreže za distribuciju energije.

Literatura

Cruz-Pérez, N., Dessimoz, M. D., Rodríguez-Martín, J., García, C., Ioras F., Santamarta, J. C. (2022): Carbon and Water Footprints of Marinas in the Canary Islands (Spain), Coastal Management.

Kona, A., Bertoldi, P., Palermo, V., Rivas, S., Hernandez, Y., Barbosa, P., Pasoyan, A. (2018): Guidebook – How to develop a Sustainable Energy and Climate Action Plan (SECAP), Bertoldi, P. (ed.), European Commission.

Ortega Piris, A., Díaz-Ruiz-Navamuel, E., Pérez-Labajos, C. A., Oria Chaveli, J. (2017): Reduction of CO2 emissions with automatic mooring systems: The case of the port of Santander, Atmospheric Pollution Research, 9(1), 76–83.

Rupprecht Consult (ed.) (2019): Guidelines for Developing and Implementing a Sustainable Urban Mobility Plan, Second Edition.

Trstenjak, A., Žiković, S., Mansour, H. (2020): Making Nautical Tourism Greener in the Mediterranean, Sustainability, 12(16), 6693.

Ukić Boljat, H., Grubišić, N., Slišković, M. (2021): The Impact of Nautical Activities on the Environment – A Systematic Review of Research, Sustainability, 13, 10552.

URL 1: Interreg Project DEEP SEA, https://www.italy-croatia.eu/web/deep-sea, (10.6.2022.).

URL 2: European Environmental Agency (EEA),

https://european-union.europa.eu/institutions-law-budget/institutions-and-bodies/institutions-and-bodies-profiles/eea_en, (11.6.2022.).

The AS IS Analysis on Current Mobility Services and Related Energy Consumption in Adriatic Marinas

Abstract

The AS IS analysis of mobile services of Adriatic marinas was conducted to assess energy consumption and CO2 emissions associated with pilot sites of marinas participating in the Interreg project DEEP-SEA and served as a basis for guiding the development of investment plans for each pilot area. It is based on the methodologies defined in the SECAP document (Sustainable Energy and Climate Action Plans), the SUMP (Sustainable Urban Mobility Plans) mobility manual and the EEA (European Environmental Agency) guidelines for air pollutants, for calculating traffic and maritime flows and related emissions of CO2. The analysis includes a spatial analysis of the marinas of the Adriatic Sea based on the overall mobility framework, the number of passengers using vehicles in the marinas and the scope of nautical mobility activities at each pilot site. Energy consumption generated by maritime and road transport and consequent CO2 emissions are estimated using formulas and tables relating to the latest indicators according to the EEA guidelines (emission factors for road transport). Data collection was supported by questionnaires and data attachments provided to marina managers and their users.

Keywords: *AS IS analysis, CO2 emissions, e-mobility, energy consumption, marinas*

Kartografski prikaz hrvatskih otoka

Adam Vinković[1], Vesna Poslončec-Petrić[2]

[1] Geodetski fakultet, Sveučilište u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, adam.vinkovic@geof.unizg.hr

[2] Geodetski fakultet, Sveučilište u Zagrebu, Kačićeva 26, Zagreb, Hrvatska, vesna.posloncec-petric@geof.unizg.hr

Sažetak

Prema Zakonu o otocima Hrvatsko otočje sastoji se od 78 otoka koji su veći od 1 km^2. Položaj i oblik hrvatskih otoka uobičajeno je na kartama prikazan uzduž morske obale. Zbog svoje razvedenosti prikaz obale u krupnijem mjerilu nije moguć. Za razliku od karte, izrada kartografske vizualizacije u obliku postera omogućuje prikaz svih otoka upotrebom vlastitog dizajna. S obzirom da je na temu konferencije, izrađena je kartografska vizualizacija svih 78 hrvatskih otoka prema njihovoj veličini. Upotrebom monokromatske metode prikaza kartografskog sadržaja, javnih prostornih podataka te geoinformacijskog sustava otvorenog koda, u ovom radu opisana je obrada podataka i izrada kartografskog prikaza kojim smo na poseban način vizualizirali hrvatske otoke.

Ključne riječi: *kartografska vizualizacija, monokromatska karta, otoci, plakat, QGIS*

1. Uvod

Koliko Hrvatska ima otoka? Prema Zakonu o otocima (Narodne novine, broj 116/18) točan odgovor je 78. Naime, članak 5 navedenog zakona definira otok kao „prirodno nastali dio kopna okružen morem, površine veće od 1 km^2", a članak 6 stavak 1 navodi da je hrvatsko otočje „jedinstvena otočna geografska cjelina koja se sastoji od 78 otoka, 524 otočića te 642 hridi i grebena". Ukupno Hrvatskoj pripadaju 1244 otoka, otočića, hridi i grebena, zbog čega se Hrvatsku s pravom naziva zemljom s tisuću otoka. Međutim, ono što hrvatsko otočje posebno krasi nije samo brojnost, već i razvedenost obale. Razvedenost morske obale definirana je položajem i oblikom linije koja čini granicu između kopna i mora.

Prikaz obale hrvatskih otoka na kartama neminovno je vezan uz prikaz položaja pojedinog otoka u odnosu na kopno. S obzirom na veliku dužinu kopnene morske obale, kartografski prikazi svih hrvatskih otoka na jednoj karti nisu mogući u krupnom mjerilu, već su uglavnom izrađeni u sitnijem mjerilu ili podijeljeni na regije ili akvatorije. Uz to, sitnija mjerila zahtijevaju generalizaciju linije što otežava detaljni prikaz razvedenosti morske obale pojedinog otoka na jednoj karti. Iz tog razloga odlučili smo se izraditi kartografsku vizualizaciju na kojoj bi pojedinačno prikazali svaki od 78 hrvatskih otoka prema površini od najvećeg do najmanjeg.

Izbor teme za prikaz motiviran je glavnom temom ovogodišnjeg 15. Simpozija ovlaštenih inženjera geodezije „Geodezija i vode". Hrvatska je u svijetu poznata po predivnoj obali i čistom moru, a hrvatski otoci obogaćuju našu obalu svojim izgledom, oblikom i brojnošću. Razmišljajući o vrsti kartografskog prikaza kojim bi naglasili izgled i oblik svakog pojedinačnog otoka kao zasebne cjeline, odlučili smo se za izradu plakata u A1 formatu papira na kojem bi smjestili sve otoke prema njihovoj površini. Pri tome nam je kao inspiracija za ovakav format i tip kartografskog prikaza poslužio plakat najvećih britanskih otoka koji je izradila britanska geodetska uprava, poznata pod nazivom Ordnance Survey, u suradnji sa Sveučilištem u Sheffieldu (URL 1).

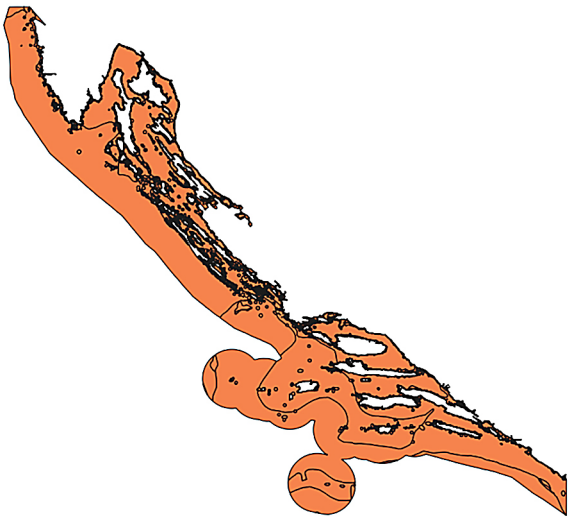
Upotreba boje pri izradi plakata također je motivirana glavnom temom konferencije. Naglasak je stavljen na upotrebu isključivo plave boje jer upravo plavu boju asociramo s morskom vodom. Jednobojni, tj. monokromatski, prikaz postignut je upotrebom tamno plave pozadine te odabirom različitih nijansi plave boje za prikaz cjelokupnog kartografskog i tekstualnog (opisnog) sadržaja na plakatu. Upotreba samo jedne boje pri izradi kartografske vizualizacije istovremeno je ograničavajući faktor pri stvaranju i izazov koji smo pokušali uspješno provesti u djelo.

2. Izvori podataka

S obzirom da su glavni objekt prikaza kartografskog sadržaja ovog projekta hrvatski otoci, obalna linija trebala je biti osnovni podatak s kojim ćemo započeti obradu podataka, tj. izradu poligona otoka kao osnovnog sloja karte. U tu svrhu povezali smo se na Web Feature Service (WFS) web portala informacijskog sustava zaštite okoliša pod nazivom 'bioportal' kojeg uspostavlja i vodi Ministarstvo gospodarstva i održivog razvoja (URL 2). Zbog nemogućnosti izrade poligona otoka na temelju sloja morske obale, iskoristili smo poligonski sloj morskog bentosa koji sadrži cjelokupno teritorijalno more RH (Slika 1). Poligonski sloj morskog bentosa će nam poslužiti kao 'negativ' unutar kojeg su otoci zapravo praznine koje treba ekstrahirati.

Za dodatne slojeve kartografske vizualizacije otoka odlučili smo se izraditi sjenčani reljef i slojnice. Sjenčani reljef i slojnice moguće je izraditi upotrebom različitih vrsta podataka, no najlakše jest obradom digitalnog modela reljefa (DMR). Prema Frančuli

(2004), DMR je skup položajno i visinski određenih točaka zemljine površine s koordinatama koje su pohranjene za računalnu obradu. Kao izvor podataka za naše područje istraživanja koristili smo europski digitalni model reljefa (EU-DEM). EU-DEM je otvoreni i javno dostupni podatak programa Copernicus kojim upravlja Europska agencija za okoliš (URL 3). Njegova prostorna rezolucija iznosi 25 x 25 m, a visinska točnost je ±7 m. Podaci EU-DEM-a nalaze se u ETRS89 referentnom koordinatnom sustavu u Lambertovoj azimutalnoj ekvivalentnoj projekciji (EPSG: 3035), a za područje cjelokupne hrvatske obale dovoljno je preuzeti jednu EU-DEM datoteku oznake E40N20.



Slika 1: Poligonski sloj morskog bentosa

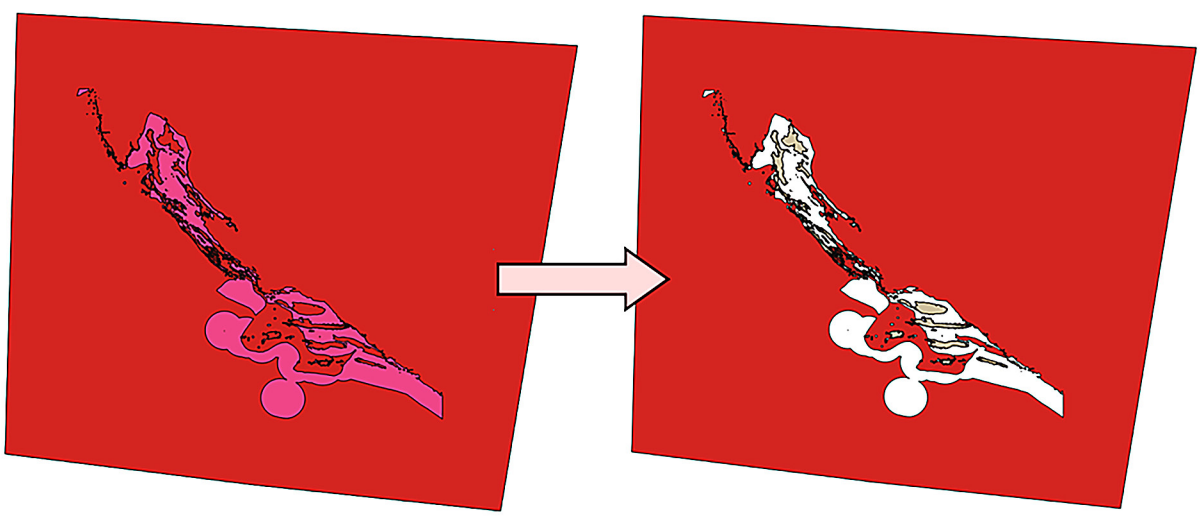
3. Obrada podataka

Cjelokupna obrada podataka koja je prethodila izradi završnog proizvoda napravljena je putem besplatnog geoinformacijskog sustava otvorenog koda QGIS 3.24. Povezivanjem na WFS servis bioportala omogućeno je pristupanje bazi podataka koja sadrži različite slojeve od kojih je jedan sloj morske obale. U idućem koraku pokušali smo od linijskog sloja morske obale izraditi poligone. Vizualnom inspekcijom linije koja predstavlja granicu između kopna i mora utvrđena je prevelika detaljnost sloja. Iznimno velik broj vrhova, tj. čvorova (eng. vertex), kao i sitne greške u topološkoj ispravnosti sloja (npr. numeracija linija i čvorova unutar sloja nije kontinuirana, već nasumična) onemogućile su izradu poligona otoka na temelju morske obale.

3.1. Obrada geometrije poligona otoka

Zbog navedenog problema pristupili smo izradi poligona otoka povezivanjem na WFS sloj morskog bentosa. Izradili smo pomoćni poligon veći od cijelog područja tako da prekriva sve otoke. Topološkom funkcijom razlike pomoćnog poligona i sloja morskog bentosa, te dijeljenjem dobivenog rezultata na pojedinačne geometrije ekstrahirali smo poligone svih postojećih otoka unutar teritorijalnog mora (Slika 2).

Dobivenom poligonskom sloju dodijeljeni su novi atributi *Povrsina* i *Tip*. Unutar atributa *Povrsina* izračunata je površina poligona na temelju geometrije svakog pojedinog objekta. Za atribut *Tip* automatski je upisana svakom objektu vrijednost *OTOK* ako je vrijednost atributa *Povrsina* veća od 1 km^2, a u suprotnom je upisana vrijednost *OTOCIC*. Filtriranjem otoka s površinom većom od 1000000 m^2, odnosno 1 km^2, uočeno da je dobiven 71 otok, tj. da nedostaje sedam otoka. Vizualnim pregledom određeni su otoci koji nedostaju, odnosno otoci koji nismo uspjeli obradom ekstrahirati iz podataka. Otoci koji nisu dobiveni razlikom poligona i morskog bentosa su: Pag, Vir, Pašman, Kornat, Arta Vela, Čiovo i Murter. Razlog tome je što su neki od njih povezani mostom s kopnom pa je linijski sloj dio kopnene morske obale (Pag, Vir, Čiovo, Murter), dok je Ugljan zajedno s Pašmanom izvezen kao jedan otok (isto zbog međusobne povezanosti mostom).



Slika 2: Ekstrahirani poligoni otoka kao rezultat razlike pomoćnog poligona i morskog bentosa

Kako bismo dobili poligone tih otoka morali smo naposlijetku pristupiti ručnoj obradi za koju se programski alat AutoCAD 2022 pokazao kao najbrže rješenje. U AutoCAD-u je učitana *shp* datoteka sa cjelokupnom morskom obalom koja je izvezena iz WFS sloja s bioportala. Očišćeni (obrisani) su svi linijski objekti osim onih koji tvore nedostajuće otoke. Čišćenjem (vizualni pregled topologije, brisanje dvostrukih linija, zatvaranje nepovezanih linija) i spajanjem svih linija koje tvore jedan otok u jednu zatvorenu linijsku geometriju, dobivena je morska obala otoka koji nedostaju. Podaci su eksportirani u *shp* datoteku i ubačeni ponovo u QGIS. S obzirom na navedenu detaljnost linija dobivenih iz sloja morske obale za nedostajuće otoke, bilo potrebno prilagoditi (uopćiti) njihovu geometriju kartografskom generalizacijom, tj. postupkom pojednostavnjivanja linije prilagoditi kartografski sadržaj mjerilu i svrsi karte (Frančula, 2003). Pojednostavnjivanje, tj. izglađivanje linije provedeno je uporabom algoritma *Visvalingam* koristeći ugrađeni modul unutar QGIS-a. Za parametar tolerancije, kojim se definira maksimalno dopušteno odstupanje između izvorne i pojednostavljene krivulje (URL 4), odabrali smo metodom pokušaja i pogrešaka vrijednost od 30 m. Nakon toga smo dobivene linije za sedam nedostajućih otoka pretvorili u poligone. Ovaj put postupak je obavljen automatizirano unutar QGIS-a jer smo prethodno uredili topologiju linija unutar AutoCAD-a. Spajanjem ovog sloja i sloja poligona dobivenih iz morskog bentosa u jedan sloj, dobiveni su poligoni za svih 78 otoka.

3.2. Obrada atributne tablice

Kako bi automatizirano upisali nazive otoka u atributnu tablicu poligonskog sloja, napravljena je zasebna *csv* datoteka s popisom otoka sortiranih prema površini. Unatoč tome što se u Zakonu o otocima nalazi prilog s popisom otoka i otočića, podaci iz priloga nisu strojno čitljivi. Stoga smo nazive otoka poredane prema površini preuzeli u tabličnom obliku s Wikipedije (URL 5). Podaci oba izvora se poklapaju s obzirom da je izvor podataka na Wikipediji upravo Zakon o otocima. Osim toga smo u atributnoj tablici poligonskog sloja otoka svakom objektu dodijelili atribut 'FID', odnosno jedinstveni identifikator (ID), pazeći pri tome na sortiranje tablice prema površini pojedinog otoka. To je bilo važno kako bi se ispravno povezali nazivi otoka iz *csv* datoteke s atributnom tablicom što je bilo nužno radi pojedinačnog filtriranja otoke za prikaz na plakatu. Nakon što smo *csv* datoteku dodali kao tablicu u QGIS, povezali smo ju (engl. join) sa slojem poligona na temelju ID-a.

Treba naglasiti kako je atribut površine pojedinog otoka određen u QGIS-u na temelju operatora *area($geometry)* koji površinu poligona izračunava u projekciji preslikavanja (u projektu je korištena službeni državni koordinati sustav HTRS96/TM). Zbog toga je kod sortiranja poligonskoj sloja otoka prema površini došlo neslaganja u redoslijedu otoka prema veličini u odnosu na preuzetu tablicu i to u nekoliko slučajeva kod površinom manjih otoka kod kojih je izrazito mala razlika u površinama. Stoga je popis otoka u tablici pregledan i ispravljen kako bi svaki objekt imao ispravno dodijeljen atribut imena otoka.

Provjerom elipsoidnih visina upotrebom operatora *$area* nije došlo do promjena u popisu otoka prema površini. Uz to smo usporedili površine izrađenih poligona otoka izračunate na elipsoidu s izračunatim površinama otoka koje su u svom istraživanju dali Duplančić Leder i dr. (2004). Površine otoka u navedenom istraživanju dobivene su digitalizacijom topografskih karata u mjerilu 1:25 000. Popisi otoka prema površini se ne podudaraju iz čega zaključujemo da podaci morske obale i morskog bentosa koje smo koristili nemaju isti izvor kao navedeno istraživanje.

3.3. Prikaz reljefa hrvatskih otoka

Reljef hrvatskih otoka prikazan je sjenčanjem i slojnicama. Postupak izrade sjenčanog reljefa unutar QGIS-a automatiziran je, jednostavan i brz proces. Potrebno je isprobati opcije glavnih parametara sjenčanja: azimut izvora svjetlosti (*Azimuth*), visina izvora svjetlosti (*Altitude*) i vertikalno izdizanje terena (*Z Factor*, eng. exaggeration). S obzirom da sjenčani reljef na prikazu otoka nismo željeli istaknuti, već samo blago naglasiti, odlučili smo se za „konzervativnije" vrijednosti parametara (Tablica 1).

Tablica 1: Vrijednost parametara sjenčanog reljefa

Parametar	Vrijednost
Azimuth	330°
Altitude	30°
Z Factor	1,4

Uz to smo odabrali opciju višesmjernog sjenčanja kojom se teren osvjetljava iz nekoliko smjerova (225°, 270°, 315° i 360°) rezultira realističnijim prikazom terena i poboljšava ravnotežu između previše eksponiranih i neosvijetljenih područja (URL 6). Glavni problem koji se pojavljuje prilikom sjenčanja reljefa u QGIS-u predstavlja pojava pravilne četverokutne mreže koja je vidljiva kao uzorak na cjelokupnoj površini DMR-a. Jedina metoda koja u potpunosti uklanja tu pojavu je *'Cubic Spline'.*

Pri izradi slojnica iz DMR-a prvotno smo odlučili izraditi slojnice s ekvidistancom od 25 m. Zbog velikog broja izvedenih linija koje predstavljaju slojnice terena i njihove međusobne gustoće, uzrokovane velikim nagibom terena na pojedinim otocima, odlučili smo za ekvidistancu od 50 m. Kao i prethodno kod linija morske obale, proveli smo generalizaciju slojnica postupkom pojednostavnjivana, a zatim i postupkom zagađivanja (eng. line smoothing) metodom Gaussovog filtriranja (URL 7) pri čemu smo parametre odabrali metodom pokušaja i pogrešaka (*sensitivity* = 1, *iterations* = 10, *preservation* = 1, *sigma* = 2). Uz to smo dodatno filtrirali slojnice s duljinom većom od 1000m, tj. izbacili smo kratke radi boljeg preglednosti.

4. Poster svih hrvatskih otoka

Izradu postera unutar QGIS-a započeli smo stvaranjem nove stranice ispisa (eng. layout) te podešava-

jući veličinu stranice. Odabrali smo A1 format papira i okomitu orijentaciju. Kao pozadinsku boju odabrali smo nijansu plave boje (HTML naziv boje: #0a597b) te definirali margine stvaranjem vodilica (eng. guides) na udaljenosti 30 mm od svakog ruba papira. U GIS sučelju definirali smo stilizaciju slojeva kojom određujemo kako ih želimo prikazati na plakatu. Poligonima otoka dodijelili smo nijansu svijetlo plave za boju ispune (#e4f1f7), bijelu liniju obruba (#ffffff) debljine 0,3 mm, neprozirnost (eng. opacity) 75%. Dodatno smo unutar opcija efekata iscrtavanja sloja (eng. draw effects) izradili vanjski sjaj (eng. outer glow) kojem smo dodijelili istu nijansu svjetlo plave (#e4f1f7) te odredili širinu 2,6 mm, radijus zamućenja 2,75 mm i neprozirnosti 50%. Slojnicama smo odredili debljinu linije od 0,1 mm i neprozirnosti 90% kako ih ne bi previše isticali na podlozi otoka. Veća debljina linije uzrokovala je međusobno preklapanje (dodirivanje) pri mjerilu koje smo naknadno definirali. Sjenčanom reljefu smo također odlučili obojati (parametar 'colorize') dodijelivši mu nijansu plave kao boju ispune (#b5e0f5) s jačinom od 50%. Svim navedenim slojevima prilagodili smo metodu grafičkog miješanja (engl. *blending mode*) koja se uobičajeno koristi za fino podešavanje miješanja slojeva te njihovog izgleda u interakciji s ostalim slojevima grafičkog prikaza (Vinković i dr., 2022).

Nakon stilizacije slojeva započeli smo izrade pojedinačnih karata svakog otoka kao glavnog sadržaja završne vizualizacije. Prvotno smo pokušali filtrirati geometriju pojedinog otoka unutar GIS sučelja prema prethodno dodijeljenom ID-u (filtriranje na temelju atributa moguće je samo za vektorske slojeve, ali ne i za rasterske). Na ovaj način ipak nismo uspjeli izraditi pojedinačne karte jer filtriranje slojeva prema atributu ne omogućuje zaključavanje sloja unutar pri izradi objekta karte unutar stranice ispisa. Promjenom filtriranog atributa dolazi do ponovnog osvježavanja karte unutar ispisa koje utječe na sve izrađene karte vidljive na toj stranici ispisa, tj. plakatu. Zatim smo pokušali automatski izraditi za svaki pojedini prikaz otoka zasebnu kartu generiranjem atlasa. Odabrali smo sloj poligona otoka kao temeljni sloj (eng. coverage layer) kojim se definira područje prikaza pojedine karte atlasa. Svakoj stranici (karti) atlasa dodjeljuje se parametar koji se može podesiti na temelju jednog od postojećih atributa temeljnog sloja. Ipak niti na ovaj način nismo uspjeli izraditi pojedinačne karte otoka na istoj stranici ispisa jer atlas omogućuje prikaz isključivo jednu kartu za svaki list ispisa.

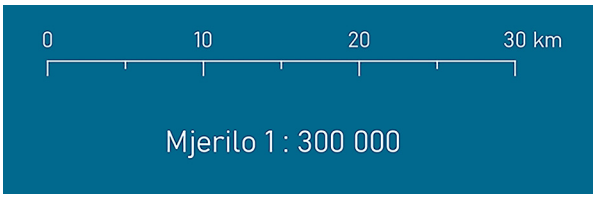
Problem vizualizacije svakog pojedinačnog otoka kao zasebne cjeline koju ćemo pojedinačno smjestiti unutar svake karte i posložiti na plakatu je riješen tako što su dupli cirani slojevi poligona otoka. Za izradu prikaza pojedinog otoka na plakatu svaki dupli cirani sloj je zasebno filtriran prema ID-u. Pri tome je bitno naglasiti da se dupliciranjem ne umnožava izvor podataka što bi dovelo do 78 zasebnih *shp* datoteka. Ovako je sve riješeno jednim izvorom podataka koji je zastupljen unutar karte sa 78 slojeva. Kako bi se isti postupak ponovio i za vektorski sloj kojim su prikazane slojnice bilo potrebno prethodno dodijeliti svakoj slojnici atributne podatke (naziv, FID) otoka kojem pripada. Taj postupak izveden je metodom povezivanja atributa po lokaciji. Iz sloja poligona otoka slojnicama su dodijeljeni atributi pod uvjetom da je zadovoljen prostorni (topološki) kriterij 'nalazi se unutar' (eng. are within). Na taj način omogućeno je filtriranje slojnica po otocima za svaki dupli cirani sloj na temelju ID-a.

Za rasterski sloj sjenčanog reljefa svaki otok pojedinačno je izveden u zasebni rasterski sloj. Za izrezivanje rastera na područje pojedinog otoka korišten je poligonski sloj otoka koji služi kao tzv. maska. Ovaj postupak automatizirano je izveden unutar QGIS-a zahvaljujući mogućnosti iteracije postupka rezanja rastera u odnosu na maskirni poligonski sloj.



Slika 3: Prikaz smještaja teksta ispod pojedine karte otoka

Za kraj izrade kartografskog sadržaja morali smo prije izrade svake karte sakriti sve slojeve koji ne pripadaju otoku čiju kartu izrađujemo unutar ispisa. Nakon toga definirali smo područje prikaza pazeći da svaka karta bude u mjerilu 1:300 000. Potom smo na temelju podataka iz atributne tablice ispod izrađene karte pojedinog otoka smjestili tekst s nazivom i površinom otoka (Slika 3). Prateći dizajn kartografskog sadržaja opet smo odabrali nijansu svjetlo plave za boju teksta (#e4f1f7), *Bahnschrisft SemiBold* font, te neprozirnost 90%. Potom smo grupirali sve otoke unutar korisnog prostora stranice ispisa poredavši ih prema površini od najvećeg prema najmanjem. Pri tome smo pazili na vizualnu ravnotežu unutar područja ispisa. Na samom dnu stranice ostavili smo prostor za elemente vanjskog opisa izrađene kartografske vizualizacije kod kojih je korišten *Banhschrift Light* font. Uz opis karte naveli smo izvore podataka i autora. U desni kut stranice postavili smo brojčano mjerilo te izradili jednostavno grafičko mjerilo (Slika 4).



Slika 4: Prikaz jednostavnog grafičkog mjerila i tekst brojčanog mjerila

Na kraju smo izradili tekst s jednostavnim nazivom vizualizacije te ga smjestili između dva prva reda s najvećim otocima. Kao završni dodatak odlučili smo se uz svaki novi redak otoka, na samom početku desne margine, izraditi strelicu i broj kojim smo označili s kojim po redu otokom prema površini započinje spomenuti redak (Slika 5). Završeni kartografski prikaz izveli smo kao sliku u *png* formatu s rezolucijom od 300 dpi.



Slika 5: Prikaz oznake brojčane vrijednosti s kojom započinje svaki novi redak i završne oznake

5. Zaključak

U radu smo prikazali izradu kartografske vizualizacije svih 78 hrvatskih otoka koji prema Zakonu o otocima imaju površinu veću od 1 km^2. Opisali smo korištene podatke, postupak obrade tih podataka te proces izrade kartografske vizualizacije. Motivirani temom konferencije odabrali smo vrstu i dizajn prikaza kojom bi prezentirali razvedenost hrvatskih otoka naglasivši izgled i oblik svakog pojedinačnog otoka. Završni proizvod je kartografska vizualizacija koja je javno dostupna (URL 8) u obliku plakata u A1 formatu papira na kojem smo smjestili sve otoke prema njihovoj površini.

Iako postoje alati za grafičku obradu koji su prilagođeni za izradu vizualnih sadržaja poput plakata, ipak smo odlučili iskoristiti mogućnost izrade karte unutar QGIS-a za izradu plakata hrvatskih otoka. Funkcionalnost ispisa karata u QGIS-u sve je bliža alatima za obradu vektorske grafike (npr. Inkscape). Pri tome je QGIS u prednosti jer omogućuje automatsku integraciju postojećeg radnog sučelja karte unutar stranice ispisa, zajedno sa svim slojevima karte i njihovim stilovima te brojnim drugim elementima karte poput tumača znakova, grafičkog mjerila, oznake sjevera, atributne tablice i sl. Uz određene prepreke prilikom izrade kartografske vizualizacije hrvatskih otoka koje smo naveli u radu, QGIS se pokazao kao odličan alat za cjelokupni proces izrade kartografskog prikaza počevši od prikupljanja i obrade podataka pa sve do završnog uređivanja dizajna plakata.

Napomena: Ovaj rad je motiviran istraživanjem u okviru Twinning Open Data Operational – TODO projekta financiranom u okviru Horizon2020 Twinning programa (Grant Agreement Number 857592 – TODO).

Literatura

Duplančić Leder, T., Ujević, T., Čala, M. (2004): Coastline Lengths and Areas of Islands in the Croatian Part of the Adriatic Sea Determined from the Topographic Maps at the Scale 1:25 000, Geoadria, 9 (1), 5-32.

Frančula, N. (2000): Kartografska generalizacija (skripta), Geodetski fakultet u Zagrebu.

Frančula, N. (2004): Digitalna kartografija (skripta), 3. prošireno izdanje, Geodetski fakultet u Zagrebu.

Narodne novine (2018): Zakon o otocima, NN 116/2018, Hrvatski Sabor.

Vinković, A., Župan, R., Ivković, M. i Biljecki, Z. (2022): Izrada karte Švicarske upotrebom metode sjenčanog reljefa u švicarskom stilu, Geodetski list, 76 (99) (1), 53-70.

URL 1: Britain's largest islands, https://www.ordnancesurvey.co.uk/newsroom/blog/britains-largest-islands, (26.6.2022).

URL 2: Bioportal WFS servis, http://services.bioportal.hr/wfs, (26.6.2022).

URL 3: Digital Elevation Model over Europe (EU-DEM) – European Environment Agency, https://www.eea.europa.eu/data-and-maps/data/eu-dem, (26.6.2022).

URL 4: Module Line Simplification / SAGA-GIS Module Library Documentation (v2.2.5), https://saga-gis.sourceforge.io/saga_tool_doc/2.2.5/shapes_lines_4.html, (26.6.2022).

URL 5: Popis otoka Hrvatske – Wikipedija, https://hr.wikipedia.org/wiki/Popis_otoka_Hrvatske#cite_note-2, (26.6.2022).

URL 6: Hillshade in QGIS – BNHR, https://bnhr.xyz/2019/01/22/hillshade-in-qgis.html, (26.6.2022).

URL 7: Module Line Smoothing / SAGA-GIS Module Library Documentation (v2.2.0), https://saga-gis.sourceforge.io/saga_tool_doc/2.2.0/shapes_lines_7.html, (26.6.2022).

URL 8: HRotoci_A1: http://www2.geof.hr/~avinkovic/HRotoci/HRotoci_A1.png, (26.6.2022).

Cartographic Visualization of the Croatian Islands

Abstract

According to the Law on Islands, the Croatian archipelago consists of 78 islands that are larger than 1 km^2. The position and shape of Croatian islands is usually shown on maps along the seacoast. Due to its indentation, the representation of the coast on a larger scale is not possible. Unlike a map, creating a map visualization in the form of a poster allows the representation of all islands using your individual map design. Given the conference topic a cartographic visualization of all 78 Croatian islands according to their size was created. Using monochromatic mapping as a method of displaying cartographic content, public spatial data, and an open source geoinformation system, this paper describes processing of data and creation of a cartographic product visualizing the Croatian islands in a special way.

Keywords: *cartographic visualization, islands, monochromatic map, poster, QGIS*

SESIJA 6

Suvremeni katastar i prostorno uređenje

Geodetski poslovi u izradi tehničke dokumentacije za Popis stanovništva 2021. godine

Renata Žeželj[1], Ines Štimac[2], Filip Pavelić[3], Stjepan Miletić[4]

[1] Zavod za fotogrametriju d. d., Borongajska cesta 71, Zagreb, Hrvatska, renata.zezelj@zzf.hr

[2] Zavod za fotogrametriju d. d., Borongajska cesta 71, Zagreb, Hrvatska, ines.stimac@zzf.hr

[3] Zavod za fotogrametriju d. d., Borongajska cesta 71, Zagreb, Hrvatska, filip.pavelic@zzf.hr

[4] Zavod za fotogrametriju d. d., Borongajska cesta 71, Zagreb, Hrvatska, stjepan.miletic@zzf.hr

Sažetak

Popis stanovništva najveće je i najopsežnije statističko istraživanje u Republici Hrvatskoj koje se provodi svakih deset godina. Cilj provođenja Popisa stanovništva je prikupljanje osnovnih podataka o broju, prostornom rasporedu i sastavu stanovništva prema njegovim demografskim, ekonomskim, obrazovnim, migracijskim i ostalim obilježjima, podataka o kućanstvima i stanovima te o njihovim obilježjima. Kako bi se Popis stanovništva što uspješnije proveo potrebno je popisivačima, koji su različitih obrazovanja i struka, što kvalitetnije pripremiti tehničku dokumentaciju koja je neophodna za izlazak popisivača na teren u svaku popisnu jedinicu. Pripremanje tehničke dokumentacije obuhvaćalo je niz geodetskih poslova koji su, kao i sve faze izrade, opisani u ovom radu.

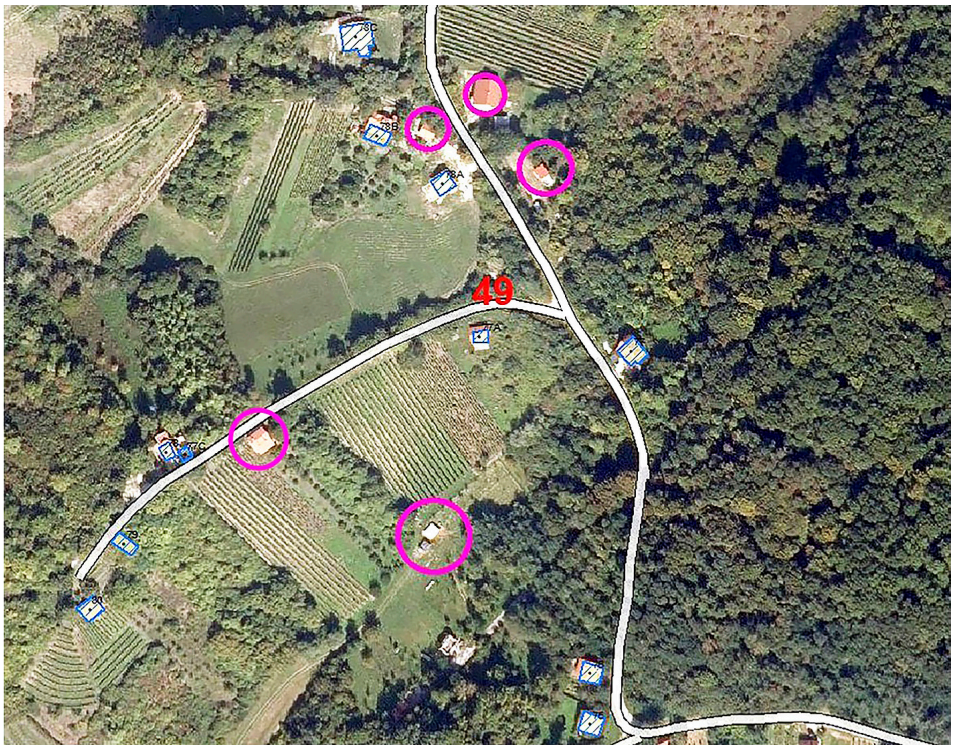
Ključne riječi: *geodetski poslovi, popis stanovništva, popisivači, tehnička dokumentacija*

1. Uvod

Popis stanovništva (dalje: Popis) se, kao najveće, najopsežnije i najsloženije statističko istraživanje kako u svijetu tako i u Republici Hrvatskoj (dalje: RH), provodi svakih deset godina. Osnovni dokument koji definira osnovne aspekte Popisa i njegova provođenja je Zakon o popisu stanovništva, kućanstava i stanova u Republici Hrvatskoj 2021. godine (Narodne novine 2020a) koji je na snazi od 14. ožujka 2020. godine i Zakon o izmjenama i dopunama zakona o popisu stanovništva, kućanstava i stanova u Republici Hrvatskoj 2021. godine (Narodne novine 2021a), koji je na snazi od 10. travnja 2021. godine. Osnovni cilj provođenja Popisa je prikupljanje osnovnih podataka o broju, prostornom rasporedu i sastavu stanovništva prema njegovim demografskim, ekonomskim, obrazovnim, migracijskim i ostalim obilježjima, podataka o kućanstvima i stanovima te o njihovim obilježjima. Nakon prikupljanja, podaci se statistički obrađuju te se provode razne analize u odnosu na prethodne Popise.

Popis 2021. godine odvijao se u dvije faze. Prva faza počela je 13. rujna 2021. i trajala je do 26. rujna 2021. godine. U tom razdoblju građani su imali priliku za sebe i članove svog kućanstva izvršiti samopopisivanje putem elektroničkog sustava e-Građani. Druga faza je obuhvaćala terensko popisivanje stanovništva koja je Odlukom o produženju roka za provedbu popisa stanovništva, kućanstava i stanova u Republici Hrvatskoj 2021. godine (Narodne novine 2021b) trajala od 27. rujna 2021. godine do 14. studenoga 2021. godine. Popisivači su obilazili svako kućanstvo te su koristeći prijenosna računala prikupljali osnovne podatke na svakoj adresi u svakoj popisnoj jedinici koja nije bila prikupljena prvom fazom. Ovakvim načinom prikupljanja podataka uvelike se ubrzalo vrijeme obrade prikupljenih podataka u odnosu na prethodni popis iz 2011. godine. Valja naglasiti da su prilikom provođenja druge faze popisivači obilazili i ona kućanstva u kojima su se osobe samostalno popisale s ciljem prikupljanja jedinstvenih šifri koje su građani dobili nakon uspješno završenog samopopisivanja.

S obzirom da se Popis provodi na temelju službenih podataka Registra prostornih jedinica (dalje: RPJ), koji vodi i održava Državna geodetska uprava (dalje: DGU), tehničku dokumentaciju za provedbu Popisa izrađuje DGU. Glavni ravnatelj DGU-a donosi naputak za izradu tehničke dokumentacije (Narodne novine 2021a). Stanje podataka o prostornim jedinicama, ulicama i kućnim brojevima zgrada u tehničkoj dokumentaciji mora se odražavati s datumom 1. prosinca 2020. Iz tog razloga, bilo je nužno u određenim područjima RH provesti terensku reviziju. Za uspješno provođenje Popisa, trebalo je što kvalitetnije pripremiti tehničku dokumentaciju na temelju koje su se popisivači mogli orijentirati u prostoru i pronaći svaki popisni krug (dalje: PK), ulicu i kućni broj. U ovom radu opisani su geodetski poslovi u postupku izrade tehničke dokumentacije.



Slika 1: Lokacije za terensku reviziju.

2. Preuzimanje podataka i ustrojavanje baze podataka

S predstavnicima DGU-a je organizirano i održano niz radnih sastanaka na kojima su detaljno dogovoreni načini isporuke i preuzimanja podataka, formati isporuke, niz pojedinosti oko terenske revizije, rokovi te su definirane uloge u samom procesu izrade tehničke dokumentacije. Za potrebe terenske revizije i izrade tehničke dokumentacije preuzeti su sljedeći podaci od DGU-a:

- podaci digitalnog katastarskog plana (DKP),
- topografske karte mjerila 1:25 000,
- podaci temeljne topografske baze (TTB),
- digitalna ortofoto karta (DOF5 iz 2011. godine i zadnje izrađeni DOF5),
- podaci Registra prostornih jedinica (RPJ).

Podaci RPJ-a (URL 1) su strukturirani grafički podaci o granicama, imenima i identifikatorima prostornih jedinica u SHP formatu i alfanumerički podaci popisa prostornih jedinica u formatu XML određenom Pravilniku o registru prostornih jedinica (Narodne novine 2020b). Od preuzetih podataka DGU-a bilo je potrebno, u svrhu provođenja terenske revizije, uspostaviti bazu podataka prostornih jedinica koja odgovara stanju na dan preuzetih podataka. To je zahtijevalo kreiranje privremenih klasa strukturiranih sukladno RPJ-u, a koje su bile potrebne za ucrtavanje/upisivanje podataka prikupljenih terenskom revizijom:

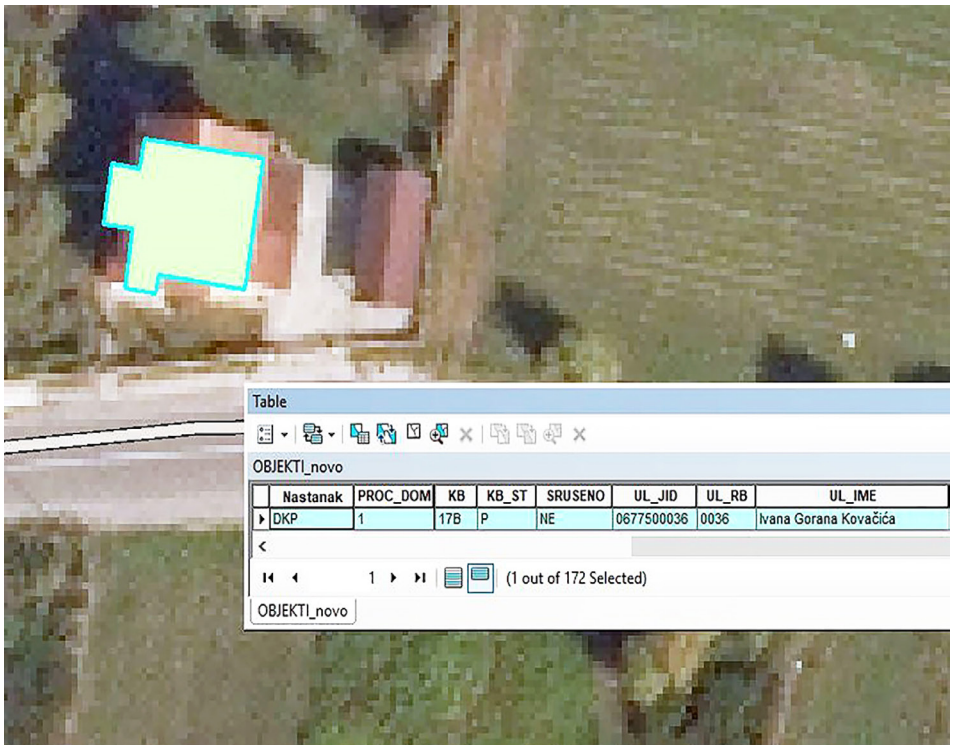
- KUCNI_BROJEVI_novo
- OBJEKTI_novo
- PK_prijedlog
- UL_novo.

Nakon uspostavljanja baze i kreiranja privremenih klasa, moglo se pristupiti pripremi za terensku reviziju.

3. Priprema za terensku reviziju

Kao osnova za pripremu podataka za terensku reviziju korišteni su podaci RPJ-a, podaci DKP-a i DOF-a. Na osnovu pregleda DOF5 i zgrada iz RPJ-a na cjelokupnoj površini RH, ciljano su locirana područja koja signaliziraju potrebu za terenskom revizijom. Kako su poslovi terenske revizije obuhvaćali područje cijele RH, zbog velikog obuhvata, terensku reviziju je obavljalo deset geodetskih tvrtki. Za svaku od njih su odabrana područja za reviziju, izrađen je dinamički plan terenske revizije i napisane upute. U njima je detaljno opisan proces rada u QGIS-u, od kreiranja projekta, učitavanja podataka, uređivanja učitanih slojeva, dodavanje fotografija, ucrtavanja objekata, novih ulica, dijeljenja PK do ispunjavanja svih atributa sukladno strukturiranim podacima RPJ-a.

Kao završni rezultat priprema izrađen je plan provođenja terenske revizije koji je u sebi sadržavao prikaz područja i vremensko razdoblje provođenja. Prije početka provođenja terenskih revizija, svi planovi su potvrđeni od nadležnih katastarskih ureda. Radni pregledni kartografski prikazi koji služe za terensku reviziju nisu rađeni u analognom obliku, već se uspostavila baza podataka i ciljane lokacije za terensku reviziju su se označavale krugovima (Slika 1).



Slika 2: Nova evidentirana zgrada.

3.1. Provođenje terenske revizije i obrada podataka

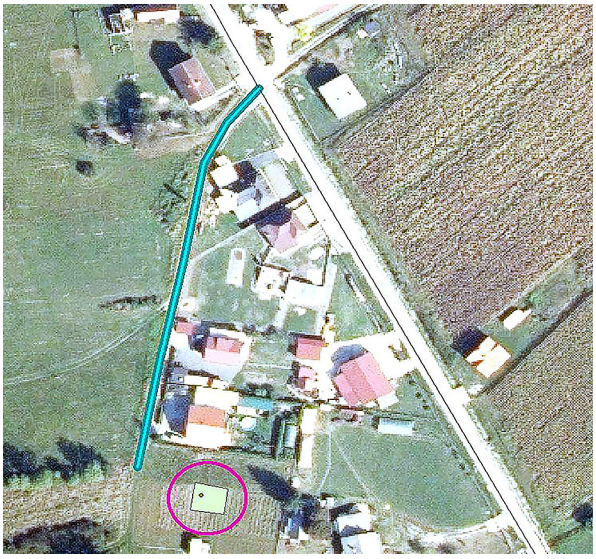
Terenska revizija je bila jedna od zahtjevnijih faza cijelog projekta, jer je u kratkom roku trebalo obići sve ciljane lokacije na području cijele RH, uz napomenu da se ista provodila u uvjetima globalne pandemije COVID-19. Ako se ciljanom terenskom revizijom utvrdilo da je zgradu potrebno evidentirati, tada su se podaci za takvu zgradu preuzimali iz podataka DKP-a. Ako zgrada nije evidentirana na DKP-u, podaci za nju bi se preuzimali iz podataka TTB-a. U slučaju da ni u jednoj od prethodno spomenutih službenih evidencija zgrada nije evidentirana, tada se na osnovu podataka DOF5 izradio strukturirani shematski prikaz te zgrade. Podatak o nastanku zgrade je upisan u atributnu tablicu (Slika 2). Ako se terenskom revizijom utvrdilo da objekt nije potrebno evidentirati, za takav objekt se upisivala napomena u atributnu tablicu (npr. poljoprivredni objekti, garaže i sl.). Obilaskom terena prikupljeni su podaci i o novosagrađenim objektima koji nisu vidljivi na posljednjem snimljenom DOF-u što je jedna od velikih prednosti terenske revizije.

Osim geometrije zgrada, bilo je potrebno dodijeliti privremene kućne brojeve. Plan dodjeljivanja kućnih brojeva mora biti odobren od strane nadležnog područnog ureda za katastar ili njegove ispostave, a radi se prema Pravilniku o RPJ-u. Svaka zgrada obuhvaćena terenskom revizijom fotografirana je mobilnim uređajem s uključenom lokacijom te su u postupku obrade podataka sve fotografije pridružene objektima na koje se odnose. Na taj način, u atributnoj tablici svakog objekta, bila je dostupna poveznica preko koje se mogla ostvariti vizualizacija fotografija (Slika 3).



Slika 3: Fotografija nove evidentirane zgrade.

U pojedinim područjima u kojima je predviđena terenska revizija bilo je potrebno obuhvatiti i dopuniti podatke o protezanju ulica i trgova, također u strukturiranom zapisu. Slika 4 jasno prikazuje protezanje ulice koja je evidentirana u RPJ-u (crna linija). Terenskom revizijom uočeno je da na terenu postoji slijepa ulica koja nije evidentirana u RPJ-u. U tom slučaju, takva ulica bi se evidentirala u privremenoj strukturnoj klasi UL_novo (svijetloplava linija) sa svim potrebnim atributnim podacima.



Slika 4: Dopuna podataka o ulici.

Pravilnik o RPJ-u (Narodne novine 2020b) propisuje broj kućanstava u jednom PK-u do 130. Ako je od strane geodetskog izvoditelja procijenjen prevelik broj kućanstava u PK-u, tada je izrađen prijedlog dijeljenja istog s upisanim podacima o procijenjenom broju kućanstava. Kod dijeljenja PK-a bilo je važno ne mijenjati vanjske granice, a trebalo ga je podijeliti tako da svaki dio sadrži približan broj kućanstava i da granica dijeljenja ide smisleno po nekoj prometnici ili nekom trajnijem obilježju na terenu (Slika 5).

Nakon prikupljanja svih podataka na terenu i topološke obrade, obavljala se kontrola kvalitete dostavljenih terenskih podataka. Prilikom provođenja iste, bilo je potrebno pridržavati se određenih uvjeta:

- da ne dolazi do preklapanja prikupljenih geometrija zgrada s postojećim,
- da dodijeljen privremeni kućni broj već ne postoji u jednoj ulici,
- da su upisani svi atributi u tablice,
- da se prilikom prijedloga dijeljenja PK-a poštuju vanjske granice istog.

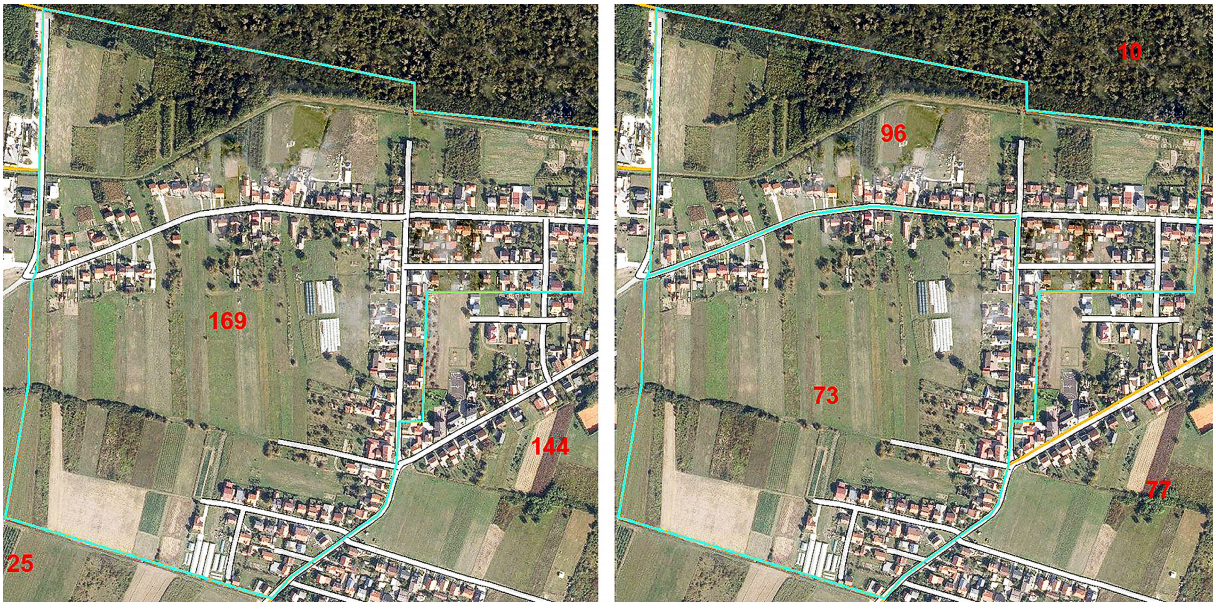
Po provedbi kontrola i eventualnih ispravaka, podaci su predani DGU te ažurirani u bazu RPJ-a.

4. Izrada digitalnih i analognih primjeraka tehničke dokumentacije

Nakon svih obavljenih poslova, dobivanja konačnih podataka od strane DGU-a, pristupilo se izradi digitalnih i analognih primjeraka tehničke dokumentacije. Tehnička dokumentacija sastoji se od:

1. popisa prostornih jedinica,
2. preglednih kartografskih prikaza,
3. skica statističkog krug (dalje: SK) i PK,
4. obrazaca PK.

U okviru izrade tehničke dokumentacije izrađeno je ukupno 2.742 popisa prostornih jedinica u analognom i isto toliko u digitalnom obliku, po dva primjerka.



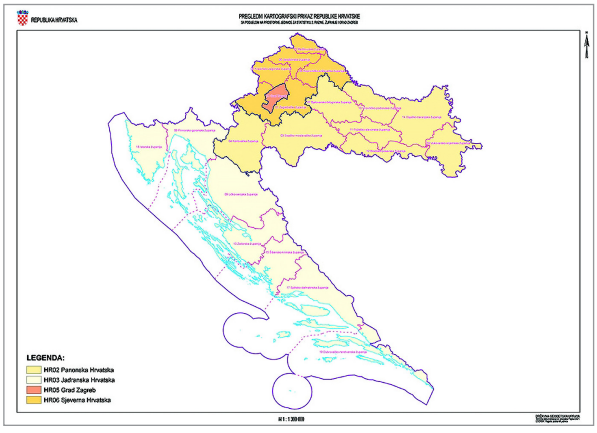
Slika 5: Dijeljenje popisnog kruga.

4.1. Pregledni kartografski prikazi

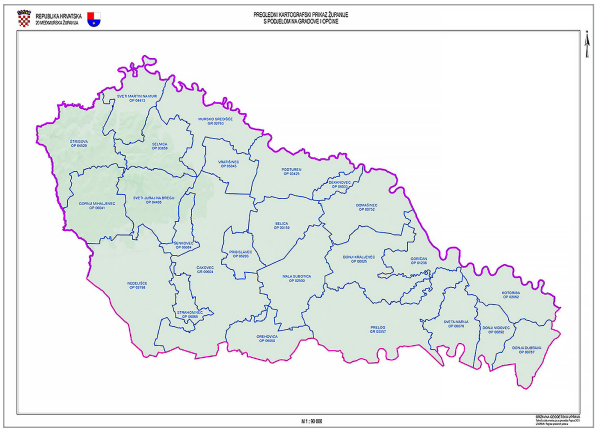
Izrađeno je 961 preglednih kartografskih prikaza u analognom i digitalnom obliku, po dva primjerka:

- Pregledni kartografski prikaz Republike Hrvatske s podjelom na prostorne jedinice za statistiku 2. razine te županije i Grad Zagreb kao prostorne jedinice 3. razine (Slika 6).
- Pregledni kartografski prikazi županija s podjelom na gradove i općine (Slika 7).
- Pregledni kartografski prikaz Grada Zagreba s podjelom na gradske četvrti i mjesne odbore (Slika 8).
- Pregledni kartografski prikazi gradova i općina s podjelom na jedinice mjesne samouprave (za one gradove i općine za koje su jedinice mjesne samouprave ustrojene) (Slika 9).
- Pregledni kartografski prikaz gradova i općina s podjelom na jedinice mjesne samouprave, naselja, katastarske općine i statističke krugove (Slika 10).

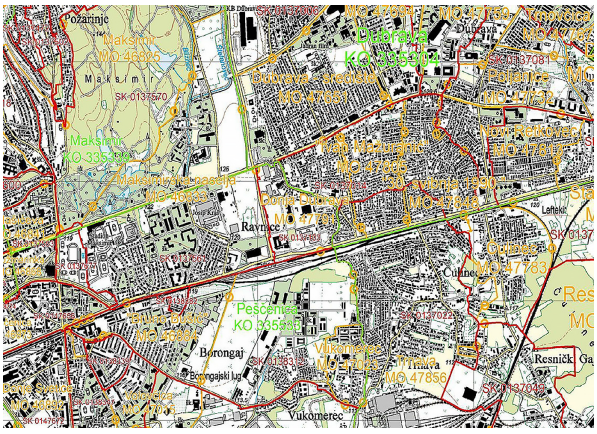
Pregledni kartografski prikaz gradskih četvrti Grada Zagreba s podjelom na jedinice mjesne samouprave, naselja, katastarske općine i statističke krugove (Slika 8).



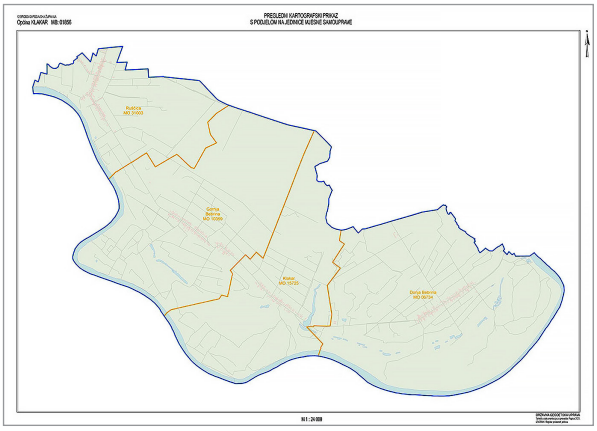
Slika 6: Prikaz podjele RH.



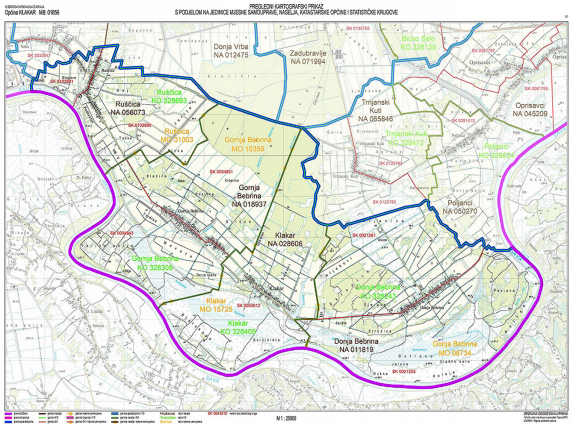
Slika 7: Prikaz podjele na GR/OP.



Slika 8: Prikaz podjele Grada Zagreba.



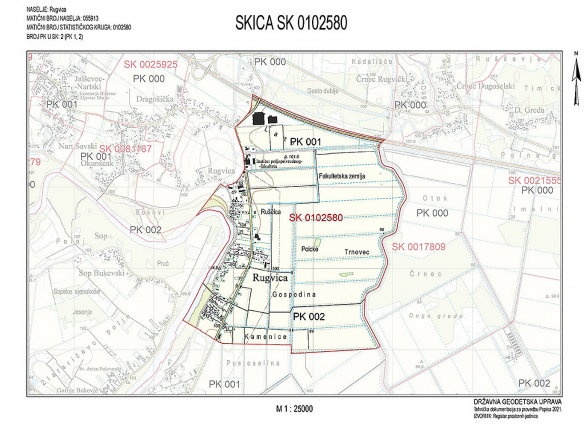
Slika 9: Prikaz podjele na JMS.



Slika 10: Prikaz podjele na JMS, NA, KO i SK.

4.2. Skice statističkih i popisnih krugova

Skice SK izrađene su pomoću podloga TK25 ili DOF5 u mjerilima 1:25 000 ili 1:5000, ovisno o njegovoj veličini. Bez obzira na podlogu, prikazane su njihove granice kao i granice PK s identifikatorima ukoliko postoji takva podjela (Slika 11). Osim navedenog, ako je na skici podloga DOF5, prikazane su i ulice sa svojim nazivima.



Slika 11: Skica statističkog kruga.

PK skice, također ovisno o veličini, izrađuju se u mjerilima 1:2500 ili 1:5000 s podlogom DOF5. Za gusto izgrađena područja skice se mogu izraditi i u krupnijem mjerilu radi što bolje orijentacije popisivača. Na skicama PK prikazane su njihove granice te ulice i kućni brojevi (Slika 12). Izrazito veliki PK-ovi ne moraju biti prikazani u cijelosti, nego samo ona područja sa zgradama i ulicama koje popisivač mora obići. Njih je moguće prikazati u dijelovima s time da se na skici označi broj dijelova (npr. 2/1 i 2/2).

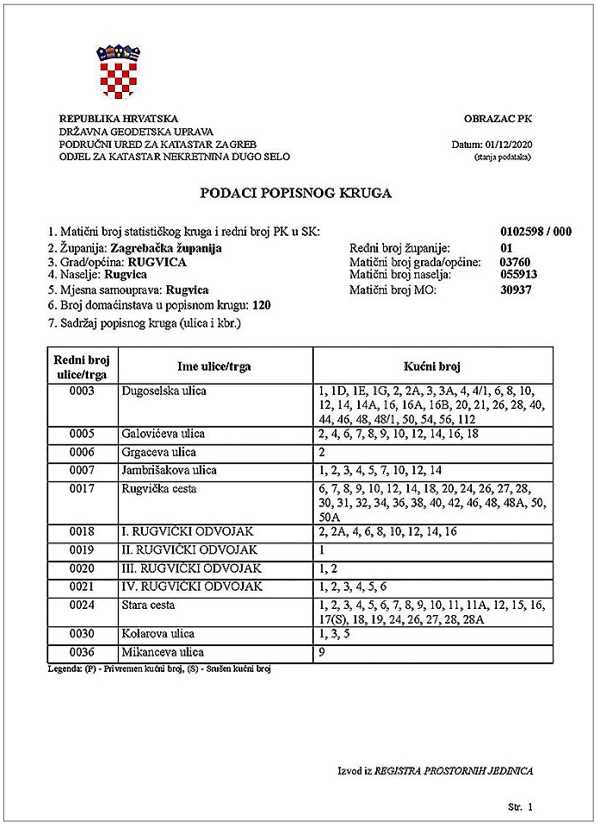
U Tablici 1 prikazan je ukupan broj PK i SK u RH te broj izrađenih skica koje je bilo potrebno izraditi u analognom i digitalnom obliku.

Tablica 1: Ukupan broj izrađenih skica.

Skice	Ukupno u RH	Izrađeno
SK	13.552	13.620
PK	29.192	30.829

4.3. PK obrasci

Oblik i sadržaj PK obrasca je propisan Pravilnikom o registru prostornih jedinica (Narodne novine 2020b). Ukupno je izrađeno po 29.192 PK obrasca u analognom i digitalnom obliku (Slika 13).



REPUBLIKA HRVATSKA
DRŽAVNA GEODETSKA UPRAVA
PODRUČNI URED ZA KATASTAR ZAGREB
ODJEL ZA KATASTAR NEKRETNINA DUGO SELO

OBRAZAC PK

Datum: 01/12/2020
(stanja podataka)

PODACI POPISNOG KRUGA

1. Matični broj statističkog kruga i redni broj PK u SK: **0102598 / 000**
2. Županija: **Zagrebačka županija** — Redni broj županije: **01**
3. Grad/općina: **RUGVICA** — Matični broj grada/općine: **03760**
4. Naselje: **Rugvica** — Matični broj naselja: **055913**
5. Mjesna samouprava: **Rugvica** — Matični broj MO: **30937**
6. Broj domaćinstava u popisnom krugu: **120**
7. Sadržaj popisnog kruga (ulica i kbr.)

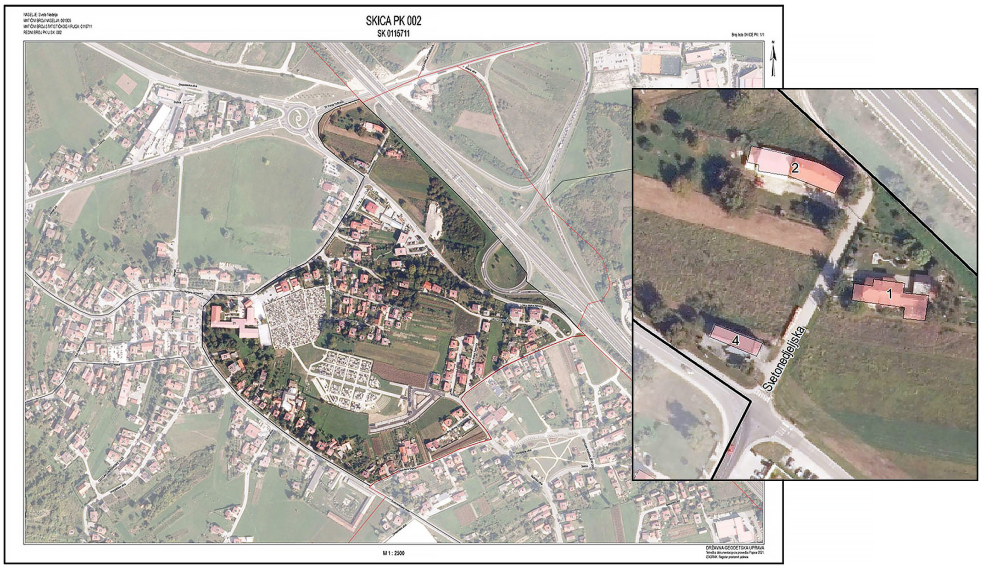
Redni broj ulice/trga	Ime ulice/trga	Kućni broj
0003	Dugoselska ulica	1, 1D, 1E, 1G, 2, 2A, 3, 3A, 4, 4/1, 6, 8, 10, 12, 14, 14A, 16, 16A, 16B, 20, 21, 26, 28, 40, 44, 46, 48, 48/1, 50, 54, 56, 112
0005	Galovićeva ulica	2, 4, 6, 7, 8, 9, 10, 12, 14, 16, 18
0006	Grgaceva ulica	2
0007	Jambrišakova ulica	1, 2, 3, 4, 5, 7, 10, 12, 14
0017	Rugvička cesta	6, 7, 8, 9, 10, 12, 14, 18, 20, 24, 26, 27, 28, 30, 31, 32, 34, 36, 38, 40, 42, 46, 48, 48A, 50, 50A
0018	I. RUGVIČKI ODVOJAK	2, 2A, 4, 6, 8, 10, 12, 14, 16
0019	II. RUGVIČKI ODVOJAK	1
0020	III. RUGVIČKI ODVOJAK	1, 2
0021	IV. RUGVIČKI ODVOJAK	1, 2, 3, 4, 5, 6
0024	Stara cesta	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 11A, 12, 15, 16, 17(S), 18, 19, 24, 26, 27, 28, 28A
0030	Kolarova ulica	1, 3, 5
0036	Mikanceva ulica	9

Legenda: (P) - Privremen kućni broj, (S) - Srušen kućni broj

Izvod iz *REGISTRA PROSTORNIH JEDINICA*

Str. 1

Slika 13: PK obrazac.



Slika 12: Skica popisnog kruga.



Slika 14: Sortiranje tehničke dokumentacije.

5. Predaja tehničke dokumentacije

Kontrola ukupnosti tehničke dokumentacije i sortiranje popisa prostornih jedinica i preglednih kartografskih prikaza radilo se po županijama i gradovima/općinama. Skice SK i PK te PK obrasci sortirani su unutar grada/općine po naseljima. U naselju je za svaki SK napravljena košuljica unutar koje su umetnute skice SK, PK i PK obrazaca. Podaci svakog naselja su umetnuti u posebne mape, a sva naselja unutar grada/općine u posebne korice (Slika 14).

Digitalni zapisi sortirani su prema pravilima za tehničku dokumentaciju u analognom obliku. Kontrola ukupnosti digitalnih datoteka obavljala se automatskim kontrolama razvijenim u FME-u od geodetskih stručnjaka. Ti su podaci za svaki grad/općinu zapisani na zasebne DVD-ove, ukupno 556. Središnji ured DGU obavio je poslove kontrole kvalitete i kontrole sortiranja tehničke dokumentacije. Kompletna tehnička dokumentacija predana je DGU u dvije faze prema propisanim zakonskim rokovima. Prva faza predana je Državnom zavodu za statistiku do 15. prosinca 2020., a druga faza županijskim popisnim povjerenstvima i Popisnom povjerenstvu Grada Zagreba do 1. veljače 2021. Primjerak za Državni zavod za statistiku sadržavao je analogni i digitalni oblik:

- Popisa prostornih jedinica,
- Preglednih kartografskih prikaza.

Županijskim popisnim povjerenstvima i Popisnom povjerenstvu Grada Zagreba su u analognom i digitalnom obliku dostavljeni:

- Popisi prostornih jedinica,
- Pregledni kartografski prikazi,
- Skice statističkih krugova,
- Skice popisnih krugova,
- PK obrasci.

6. Ažuriranje tehničke dokumentacije nakon potresa u prosincu 2020. godine

Na sisačkom, petrinjskom i zagrebačkom području dogodio se potres u prosincu 2020. godine kada su

radovi terenske revizije već bili gotovi i prva faza podataka isporučena. Velik broj objekata je tim potresom uništen i prostorni raspored stanovništva je značajno promijenjen. Zbog toga je bilo potrebno izvršiti ažuriranje na tom području kako popisivači ne bi nepotrebno gubili vrijeme obilazeći lokacije. Lokalnom stanovništvu su postavljene privremene smještajne jedinice (pojedinačni kontejneri i kontejnerska naselja). Ažuriranje je obuhvaćalo obilazak zgrada koja su imala evidentiranu crvenu ili narančastu naljepnicu na područjima Gvozda, Topuskog, Gline, Siska, Lekenika, Martinske Vesi, Petrinje, Majura, Sunje, Donjih Kukuruzara, Hrvatske Dubice, Hrvatske Kostajnice, Jasenovca, Pokupskog i Kravarskog. Lokacije tih objekata dostavljene su od strane Hrvatskog centra za potresno inženjerstvo kao i lokacije privremenih smještajnih jedinica kojima su dodjeljivani kućni brojevi. Po završetku terenskog prikupljanja izvršena je obrada tih podataka, postupak kontrole kvalitete te nova izrada i isporuka ažuriranih dijelova tehničke dokumentacije. Rok za izvršenje ažuriranja je bio 1. srpanj 2021. godine s time da je ažurirana dokumentacija pratila stanje podataka na dan 1. lipnja 2021. godine.

7. Zaključak

Za izradu kvalitetne tehničke dokumentacije za Popis 2021. bili su nužni geodetski poslovi na ažuriranju i interpretaciji podataka RPJ-a. Geodetski poslovi u ovom projektu obuhvaćali su terenske radove, geoinformatičku obradu i razvoj raznih aplikativnih rješenja za automatsku kontrolu. Također je bilo potrebno i znanje kartografskog uređivanja prikaza i izrada podloga za te prikaze. Valja naglasiti da su u sklopu ovog projekta prikupljene i dodatne informacije o stanju podataka u RPJ-u. Usprkos opsežnosti radova i dodatnim posebnim okolnostima (COVID-19 i potres) ovaj projekt je bio veliki izazov za struku te je izvršen sukladno svim zakonskim rokovima.

Literatura

Narodne novine (2020a): Zakon o popisu stanovništva, kućanstava i stanova u Republici Hrvatskoj 2021. godine, br. 25/20, Zagreb.

Narodne novine (2020b): Pravilnik o registru prostornih jedinica, br. 37/20, Zagreb.

Narodne novine (2021a): Zakon o izmjenama i dopunama zakona o popisu stanovništva, kućanstava i stanova u Republici Hrvatskoj 2021. godine, br. 34/21, Zagreb.

Narodne novine (2021b): Odluka o produženju roka za provedbu popisa stanovništva, kućanstava i stanova u Republici Hrvatskoj 2021. godine, br. 117/21, Zagreb.

URL 1: Registar prostornih jedinica,

https://dgu.gov.hr/registar-prostornih-jedinica-172/172, (24.6.2022.).

Geodetic Works in Production of Technical Documentation for the 2021 Population Census

Abstract

The population census takes place every ten years and is the largest and most comprehensive statistical survey in the Republic of Croatia. The objective of the Census is collecting data on the numbers, spatial distribution and structure of the population based on its demographic, economic, educational, migrational and other features, data on households and apartments and their characteristics. The technical documentation is necessary for enumerators field work and needs to be prepared in the highest quality so the enumerators, of various education and professions, can successfully carry out the Census. The preparation of technical documentation, including a series of geodetic works, and all the production stages are described in this paper.

Keywords: *enumerators, geodetic works, population census, technical documentation*

Primjena metoda umjetne inteligencije i strojnog učenja u sređivanju zemljišnih podataka

Petar Delać[1], Mario Pranjić[2], Marinko Požega[3], Josip Šimić[4]

[1] Ericsson Nikola Tesla d.d., Krapinska 45, Zagreb, Hrvatska, petar.delac@ericsson.com

[2] Ericsson Nikola Tesla d.d., Krapinska 45, Zagreb, Hrvatska, mario.pranjic@ericsson.com

[3] Ericsson Nikola Tesla d.d., Krapinska 45, Zagreb, Hrvatska, marinko.pozega@ericsson.com

[4] Ericsson Nikola Tesla d.d., Krapinska 45, Zagreb, Hrvatska, josip.simic@ericsson.com

Sažetak

Podacima katastra i zemljišnih knjiga svakodnevno pristupa veliki broj zainteresiranih građana i poslovnih subjekata, ali ih isto tako u svojim poslovnim procesima koriste brojne institucije i tijela javne vlasti. To je prepoznala i Vlada Republike Hrvatske te je u svojoj odluci katastar nekretnina i zemljišnu knjigu proglasila temeljnim registrima za prostor. U proteklih nekoliko desetljeća provedeni su mnogi projekti digitalizacije katastra i zemljišne knjige, ali i dalje je otežano pretraživanje registara prema jednostavnim analitičkim upitima. Glavni uzrok za to su nedovoljno dobro strukturirani i kategorizirani podaci koji su u većoj mjeri prepisani u nestrukturiranom obliku iz ručno vođenih knjiga. Tehnološki razvoj na području umjetne inteligencija i strojnog učenja u proteklih nekoliko godina omogućio je širu primjenu navedenih tehnologija u različitim područjima. To je prepoznato i u sklopu projekta „Upravljanje zemljišnim podacima", gdje su navedene tehnologije iskorištene za strukturiranje i kategorizaciju podataka katastra i zemljišnih knjiga. Koristile su se metode strojnog učenja za procesiranje teksta kako bi se pronašle sličnosti između riječi, predvidjelo značenje kratica i vrsta riječi. Navedeno je omogućilo prepoznavanje i kategorizaciju načina uporabe zemljišta i zgrada, upisa posebnih pravnih režima, koncesija i služnosti te strukturiranje podataka fizičkih osoba koje su upisane u katastru i zemljišnim knjigama. U sklopu rada prikazat će se dobiveni rezultati, analizirati mogućnost primjene navedenih tehnologija i na drugim zemljišnim podacima te razmotriti potrebne prilagodbe pravnog okvira kako bi se navedeni podaci stavili u primjenu.

Ključne riječi: *katastar, sređivanje podataka, strojno učenje, umjetna inteligencija, zemljišna knjiga*

1. Uvod

Trenutni podaci u službenim evidencijama zemljišnih knjiga i katastra u najvećoj mjeri nastali su postupkom prijepisa zadnjeg stanja podataka iz ručno vođene evidencije. Pod elektroničkom evidencijom podrazumijevaju se baze podataka nad kojima su izrađena programska rješenja za vođenje i čuvanje podataka. U trenutku prijepisa u elektroničku evidenciju, katastarski i zemljišnoknjižni uredi koristili su različita programska rješenja koja su se naslanjala na baze podataka s različitim modelima podataka. Složenost modela podataka ovisila je o dobavljaču pojedine aplikacije, ali i specifičnim zahtjevima pojedinog katastarskog ili zemljišnoknjižnog ureda koji su koristili pojedino programsko rješenje. Treba uzeti u obzir činjenicu da su ova programska rješenja nastala prije 20 i više godina i da je u tom trenutku glavni benefit bio podatke prebaciti u elektronički oblik. Nije napravljeno detaljno strukturiranje i šifriranje podataka pa se iz današnje perspektive takvi modeli podataka smatraju manjkavim.

Način vođenja službenih evidencija katastra i zemljišnih knjiga često se razlikovao od ureda do ureda. Različito održavanje podataka često je uzrokovano povijesnim nasljeđem pojedinih regija u Republici Hrvatskoj, ali i načina kako su pojedini uredi ustaljenom praksom održavali podatke. Također, potrebno je naglasiti činjenicu da su se kroz vrijeme mijenjali zakonski propisi koji uređuju način vođenja i sadržaj službenih evidencija (Narodne novine 2019, Narodne novine 2018b). Radi ubrzanja postupaka prijepisa, prijepis se dijelom odrađivao od strane djelatnika koji nisu izvorno radili u katastarskim i zemljišnoknjižnim uredima te su se prilikom prijepisa događale različite neujednačenosti, a ponekad i pogreške. Prilikom projektiranja Zajedničkog informacijskog sustava zemljišnih knjiga i katastra (ZIS) definiran je model podataka koji je usklađen sa zakonskim propisima koji određuju način održavanja službenih evidencija katastra i zemljišnih knjiga. Glavni prioritet prilikom migracije podataka bio je prebaciti podatke iz drugih baza podataka u ZIS bazu u izvornom obliku. Gdje je bilo moguće, prilikom migracije podataka odrađeno je programsko strukturiranje i šifriranje podataka. Prilikom migracije podataka iz različitih programskih rješenja u ZIS često su pojedini uredi, u želji da migri-

raju i pojedine specifične podatke, zahtijevali nadogradnju ili prilagodbu definiranog modela podataka. U konačnici su svi podaci, bez obzira u kojem uredu i u koje vrijeme nastali te bez obzira u kojem programskom rješenju održavani, završili u jedinstvenoj bazi podataka.

Prilikom migracije podataka postojala je želja da se što više podataka strukturira, šifrira i generalno podigne razina kvalitete podataka, ali je zbog vremenskog okvira i unaprijed definiranog opsega migracije ta aktivnost odgođena za naknadne projekte uređivanja zemljišnih podataka. Svi podaci koji danas nastaju kroz održavanje u ZIS-u imaju očekivanu razinu složenosti strukture podataka, dok su migrirani podaci ograničene strukture i često ih se može smatrati jednostavnom preslikom ručno vođene evidencije. Iz perspektive ljudskog promatranja podataka, podaci su razumljivi i točni, međutim iz računalne perspektive podaci su nedovoljno definirani i neprilagođeni današnjim potrebama za održavanje i uporabu podataka. Podaci službenih evidencija katastra i zemljišnih knjiga spadaju u grupu podataka za kojima postoji izniman interes različitih državnih tijela. U području poljoprivrede, graditeljstva, turizma, gospodarstva i ostalih sektora, podaci katastra i zemljišne knjige često su temeljni podaci za obavljanje osnovnih djelatnosti pojedinog sektora ili podaci koji su potrebni za planiranje i provođenje različitih aktivnosti. Također, unutar institucija Državne geodetske uprave i Ministarstva pravosuđa i uprave koje su nadležne za zemljišne podatke, provode se različite analize stanja podataka u svrhu planiranja reformi, predlaganja zakonskih promjena i unaprjeđenja postupka održavanja podataka.

Ukoliko je zahtjev analize npr. izrada popisa pravnih osoba koje su upisane kao vlasnici poljoprivrednog zemljišta, potrebno je razlučiti što je poljoprivredno zemljište, tko su osobe koje su vlasnici i jesu li upisani vlasnici pravne osobe. Za svaku od ovih dimenzija potrebna je pouzdana informacija u podacima za dobivanje željenog rezultata analize. Propisi točno određuju što spada u poljoprivredno zemljište, gdje su upisani vlasnici i tko su pravne osobe. Međutim, upoznati smo s činjenicom da su se načini uporabe zemljišta, što su izvori informacije za kategorizaciju poljoprivrednog zemljišta, kroz vrijeme upisivali na različite načine. Za dobivanje podatka o upisanom vlasniku potrebno je preko identifikacije iz zemljišne knjige dohvatiti upisane osobe, razlučiti vlasnike i podatak je li upisana osoba kategorizirana kao pravna osoba. Ovisno o strukturi, kvaliteti ili postojanju ovih podataka ovisit će i rezultati dobiveni analizom. Strukturiranje i kategorizacija postojećih podataka postupak je koji bi se najtočnije obavio od strane osoba upoznatih s upravljanjem zemljišnih podataka. Takav pristup ne može se opravdati zbog vremena i resursa koji bi se uložili u tu aktivnost te je bilo potrebno pronaći neka prihvatljivija rješenja.

Tehnološki razvoj na području umjetne inteligencija i strojnog učenja u proteklih nekoliko godina omogućio je širu primjenu ovih tehnologija u različitim područjima, pa tako i u području zemljišne administracije. To je prepoznato i u sklopu projekta „Upravljanje zemljišnim podacima“, gdje su navedene tehnologije iskorištene za strukturiranje i kategorizaciju podataka katastra i zemljišnih knjiga. Koristile su se metode strojnog učenja za procesiranje teksta kako bi se pronašle sličnosti između riječi, predvidjelo značenje kratica i vrsta riječi. Navedeno je omogućilo prepoznavanje i kategorizaciju načina uporabe zemljišta i zgrada, upisa posebnih pravnih režima, koncesija i služnosti te strukturiranje podataka fizičkih osoba koje su upisane u katastru i zemljišnim knjigama.

2. Metodologija

2.1. Kategorizacija vrsti uporaba

Usuglašeno je da će se kategorizacija vrsti uporaba raditi sukladno Tehničkoj specifikaciji za izradu DKP-a i DGE-a, koja je prilog Pravilniku o geodetskim elaboratima (Narodne novine 2018a). Kategorizacija je rađena sukladno utvrđenim šifrarnicima na razini vrste uporabe zemljišta i vrste uporabe zgrada te pripadajućih grupa vrsti uporabe zemljišta i zgrada. U ZIS bazi podataka postoje dva šifrarnika u kojima se čuvaju podaci o vrstama uporaba zgrada i vrstama uporaba zemljišta. Šifrarnici sadrže aktivne zapise koji su usklađeni s trenutno važećim pravilnikom (Narodne novine 2018a), ali se u njima nalazi i veliki broj neaktivnih zapisa koji su migrirani iz prethodnih sustava, odnosno baza podataka i koji su u najvećoj nestrukturirani (Tablica 1).

Tablica 1: Neaktivne vrste uporabe.

Vrsta uporabe	Grupa vrste uporabe
IGRALIŠTE	NEDEFINIRANO
KUĆA BR.28,ZG,DVOR	NEDEFINIRANO

Uvidom u postojeće podatke u ZIS bazi, utvrđeno je kako se neaktivni zapisi koji se nalaze u šifrarniku vrsti uporabe zemljišta ne moraju nužno odnositi na zemljište nego se zapravo radi o zgradi. Isto vrijedi i za postojeće vrste uporabe zgrada. Stoga je odlučeno da će se kategorizacija svih neaktivnih zapisa raditi uspoređujući svaki od zapisa sa svim aktivnim vrstama uporaba zemljišta i zgrada. Također, neaktivni zapisi u većini slučajeva ne mogu se kategorizirati na samo jednu vrstu uporabe zemljišta ili zgrada iz aktivnog šifrarnika. Rezultat takve kategorizacije jest 7 razina kategorizacije:

1. Naziv vrste uporabe opisuje samo jednu vrstu uporabe zemljišta
2. Naziv vrste uporabe opisuje samo jednu vrstu uporabe zgrade
3. Naziv vrste uporabe opisuje više vrsti uporabe zemljišta i one se nalaze unutar iste grupe
4. Naziv vrste uporabe opisuje više vrsti uporabe zgrada i one se nalaze unutar iste grupe
5. Naziv vrste uporabe opisuje više vrsti uporabe zemljišta i one se nalaze unutar različitih grupa
6. Naziv vrste uporabe opisuje više vrsti uporabe zgrada i one se nalaze unutar različitih grupa

Tablica 2: Primjer postojećih nestrukturiranih podataka.

Naziv	Ime	Prezime	Ime oca	Djevojačko prezime
BOŽIĆEV DARKO MLDB. POK. DINKA	–	–	–	–

Tablica 3: Primjer nekategoriziranog upisa u ZIS bazi.

OPIS UPISA	VRSTA PRAVA	VRSTA ČINJENICE	VRSTA VLASNIŠTVA
Zaprimljeno 15.11.2013. broj Z-2643/13 Na temelju pravomoćnog rješenja Ministarstva kulture, Uprava za zaštitu kulturne baštine Klasa:UP-I-612-08/07-06/0147 ur.broj:532-04-01-04/16-13-3 od 09. listopada 2013.g.zabilježuje se da je čest. zem. 429/1, 438 ima svojstvo kulturnog dobra	–	–	–

7. Naziv vrste uporabe opisuje više vrsti uporabe zemljišta i zgrada i one se nalaze unutar različitih grupa.

Vrste uporabe čiji naziv nije moguće mapirati na aktivni šifrarnik metodama strojnog učenja i umjetne inteligencije, izdvojeni su kako bi se pokušali manualno kategorizirati. Zapisi koje ni na taj način nije bilo moguće kategorizirati, kategorizirani su kao NEPOZNATO.

2.2. Strukturiranje podataka fizičkih osoba upisanih u katastru i zemljišnim knjigama

Podaci o upisanim osobama u većoj mjeri su migrirani iz prethodnih aplikacija i nisu dobro strukturirani, a to se posebno odnosi na podatke o fizičkim osobama (Tablica 2). Često je slučaj da se i ime i prezime nalazi spojeno u jednom polju koje može biti ime ili prezime ili naziv. Ostala polja u tom slučaju su prazna. Osim imena i prezimena, postoje i primjeri gdje je u istom polju spojeno i ime oca ili djevojačko prezime, a također se u nazivu mogao naći i tekst koji predstavlja datum rođenja, OIB ili JMBG osobe te razni drugi podaci.

Strukturiranje osoba provedeno je za osobe upisane u katastru (posjednici) i zemljišnim knjigama (vlasnici) za koje se utvrdilo da nemaju strukturirani zapis. Za svaku upisanu osobu podaci su strukturirati prema sljedećem algoritmu:

1. Za sve osobe procedura provjerava nestrukturirano polje NAZIV i određuje radi li se fizičkoj osobi ili ne. Za osobe za koje se utvrdi da nisu fizičke, eliminiraju se iz daljnjeg procesa.
2. Za osobe za koje se utvrdi da su fizičke, procedura provjerava imaju li upisano ime i prezime u odvojena polja. Ako imaju, preskaču se i smatraju se strukturiranim.
3. Ako se radi o fizičkoj osobi procedura iz nestrukturiranog polja NAZIV prepoznaje ime, prezime, ime oca i djevojačko prezime te sprema u predviđena polja.

2.3. Kategorizacija upisa posebnih pravnih režima, koncesija i služnosti

U ZIS bazi podataka svi novi upisi u zemljišnim knjigama šifriraju se prema vrsti prava, vrsti činjenica i vrsti vlasništva. Međutim većina upisa u zemljišnim knjigama je migrirana i nije strukturirana, odnosno jedina informacija o vrsti upisa nalazi se u tekstualnom polju OPIS UPISA (Tablica 3).

Kategorizacijom je za svaki upis za koji se nedvojbeno utvrdilo kako se radi o posebnom pravnom režimu, koncesiji ili služnosti dodijeljena odgovarajuća kategorija. Također, ukoliko je bilo moguće odrediti o kojem pravnom režimu se radi (pomorsko dobro, vodno dobro itd.) ili koja je vrsta služnosti u pitanju (stvarna služnost, osobna služnost – pravo plodouživanja itd.) dodana je i odgovarajuća potkategorija.

3. Metode umjetne inteligencije i strojnog učenja

Kategorizacija i strukturiranje podataka odrađeni su u programskom jeziku Python koji je trenutno najpopularniji jezik za procesiranje podataka i kreiranje modela strojnog učenja. Python programski jezik sadrži mnoštvo paketa otvorenog koda za različite svrhe, a oni koji su se koristili u ovom projektu su:

- Scikit learn – kreiranje modela strojnog učenja
- Pandas – rad s „dataframe“ (okvir podataka) tipovima podataka
- Nltk, spacy – obrada prirodnog jezika (natural language processing)
- Stanza, spacy_udpipe – hrvatski rječnik i atributi riječi
- Cx_oracle – operacije nad bazom
- Hmni, fuzzywuzzy – korišteni za sličnosti riječi.

Tablica 4: Početna obrada naziva vrsti uporaba.

NAZIV	OBRADA	KRATICE	TOKENI
3 POSL. ZGRADE	POSL. ZGRADE	POSL	ZGRADE
CRKVA + ZVONIK + POS.ST.	CRKVA ZVONIK POS.ST.	POS, ST	CRKVA ZVONIK
SKLADIŠTE I GARAŽA	SKLADIŠTE I GARAŽA	-	SKLADIŠTE, GARAŽA

3.1. Kategorizacija vrsti uporabe

Kategorizacija vrsti uporabe zemljišta i vrsti uporabe zgrada zahtijevala je procesiranje teksta te se sukladno tome koristila metoda obrade prirodnog jezika (engl. natural language processing), koja je jedna od grana strojnog učenja. Postojeći podaci preuzeti su iz baze podataka te su procesirani na način da je naziv svake vrste podijeljen (tokeniziran) u zasebne riječi, očišćen od numeričkih podataka te transformiran u mala slova. Pronađene su sve kratice u nazivima i spremljene u novi stupac koji će biti potreban za analizu (Tablica 4).

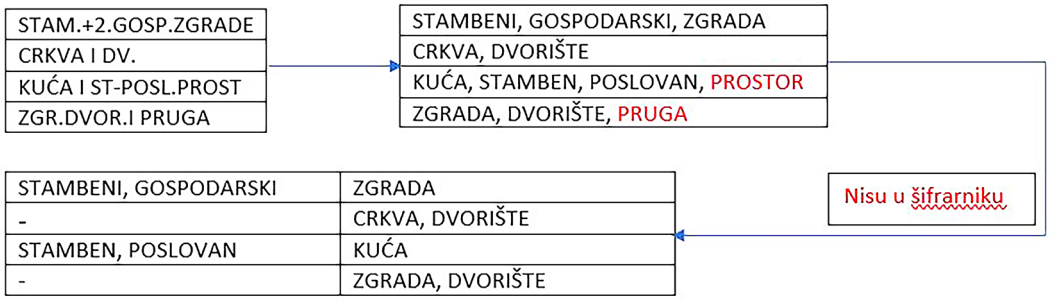
Kako bi se što bolje kategorizirali podaci, bilo je potrebno kreirati pomoćne stupce u tzv. okviru podataka (engl. dataframe) koji je opći tip podataka za rad s tabličnim podacima u Pythonu. Nakon što je naziv tokeniziran i izdvojene kratice, sve dobivene riječi (tokeni) svedeni su na opći oblik riječi. Slijedi proces pronalaženja sličnosti riječi neaktivnih vrsti s vrstama iz šifrarnika pomoću paketa koji vraća postotak sličnosti dvaju riječi, nakon čega se u stupac našeg okvira podataka spremaju sve „ključne riječi" koje su pronađene u šifrarniku preko filtera visoke sličnosti (Slika 1). Identičan proces obavljen je nad kraticama u tekstu koje su izdvojene u obradi podataka.

Sljedeći korak bio je pronalazak vrste riječi koje su pronađene prethodnim procesom, što je izvršeno paketom koji ima razvijen API (engl. application program interface) za hrvatski jezik te rječnik hrvatskih riječi i njihova vrstu, kao i opći oblik. U primjeru kategorizacije vrsti uporabe radilo se samo s imenicama i pridjevima jer su svi ostali nepotrebni tipovi eliminirani. Važno je napomenuti da su sve metode obrade podataka i prirodnog jezika izvršene i na aktivnim (šifrarnik) i neaktivnim vrstama uporabe zemljišta i zgrada. Završni korak kategorizacije vrsti uporaba zemljišta i zgrada je usporedba dobivenih ključnih imenica i pridjeva neaktivnog dijela podataka sa šifrarnikom. Ovdje je ključna „hijerarhijska" kategorizacija podataka – podaci se najprije kategoriziraju prema tome da li se za određenu vrstu iz šifrarnika nalaze sve imenice i pridjevi iz ključnih riječi u neaktivnom zapisu te strogost funkcije polako otpada kako bi svaki zapis mogao biti kategoriziran ako ima bilo kakvu ključnu riječ koja pripada šifrarniku.

3.2. Strukturiranje podataka fizičkih osoba upisanih u katastru i zemljišnim knjigama

Dio podataka u bazi je prethodno bio strukturiran na ime i prezime te su se isti koristili za kreiranje nadziranog modela strojnog učenja koji klasificira tekst u jednu od dvije kategorije. Model je treniran na strukturiranim podacima, a predikcije su odrađene na način da pouzdanim rezultatima smatramo samo one koji imaju sigurnost predikcije veću od 85%. Razlog tome je što sve riječi u tekstu koji predviđamo „moraju" spasti pod ime i prezime, tako da ovim postupkom kreiramo filter koji će među predikcijama naći riječi koje zaista predstavljaju jednu od dvije kategorije potrebne za strukturiranje.

Svi nazivi su prethodno obrađeni na isti način kao i vrste uporabe zemljišta i zgrada uz dodatni korak eliminacije tzv. regex patterna i njihovih ekstenzija koji su manualno pronađeni u uzorcima podataka a uvelike pomažu čišćenju teksta za daljnji proces. Nakon što su podaci obrađeni, provedena je kategorizacija podataka na fizičke i pravne osobe na način da se fizičkom osobom smatra onaj naziv koji sadrži barem jedan par imena i prezimena koji su pronađeni preko kreiranog modela strojnog učenja. Iz teksta se ponovo regex uzorcima pronalaze zapisi koji ukazuju na pojavu djevojačkog prezimena ili imena oca koji su nam potrebni za strukturu podataka. Na uzorcima (npr. rod., kćer, sin itd.) uz ekstenziju provedena je



Slika 1: Primjeri izdvajanja i pronalaska ključnih riječi koje povezuju vrste sa šifrarnikom.

predikcija pomoću kreiranog modela strojnog učenja kako bi se potvrdilo da je uz uzorak zaista pridruženo ime ili prezime. Ukoliko je pronađeno ime oca ili djevojačko prezime u nazivu, spremaju se u novi stupac okvira podataka te se pronađeni uzorak i ekstenzija brišu iz početnog naziva kako bi pročistili tekst za daljnju strukturu.

Zadnji korak strukturiranja naziva je pronalazak imena i prezimena. Ukoliko je u pročišćenom nazivu ostalo samo dva tokena, provodi se jednostavno strukturiranje naziva u kojemu je uvijek jedan token predviđen kao ime, a jedan kao prezime. Svi ostali zapisi, koji imaju više od dva tokena, prolaze kroz napredniju metodu strukturiranja u kojoj veliku ulogu igra i pozicija svakog tokena, ukoliko je on ime ili prezime. Ukoliko se radilo o nedostatku strukturiranih podataka, provedena je druga iteracija pronalaska imena i prezimena.

3.3. Kategorizacija upisa posebnih pravnih režima, koncesija i služnosti

Kategorizacija upisa provedena je jednostavnim filterima pomoću upita na bazi podataka. Kako bi se kategorizirali ti upisi, uzeta je u obzir prisutnost ključnih riječi u polju OPIS UPISA (npr. kulturno dobro, koncesija, plodouživanje itd.). Strukturirani podaci u bazi sadržavali su i oznake kojima je omogućen pronalazak određene kategorije upisa (vrsta činjenice, vrsta prava i vrsta vlasništva).

4. Rezultati

Kada su u pitanju rezultati kategorizacije vrsti uporabe zemljišta i zgrada (Tablica 5), od ukupno 176 390 neaktivnih upisa, kroz proces strojnog učenja je

Tablica 5: Rezultat kategorizacije vrsti uporaba.

Vrsta uporabe	Vrsta uporabe – kategorizirana	Grupa vrste uporabe	Razina kategorizacije
IGRALIŠTE	DJEČJE IGRALIŠTE	ZEMLJIŠTE PRIVEDENO SVRSI	1. Naziv vrste uporabe opisuje samo jednu vrstu uporabe zemljišta
KUĆA BR.28,ZG,DVOR	KUĆA	ZGRADE KOJE SE UPOTREBLJAVAJU ZA STANOVANJE	7. Naziv vrste uporabe opisuje više vrsti uporabe zemljišta i zgrada i one se nalaze unutar različitih grupa
	ZGRADA (OPĆE)	ZGRADE KOJE SE UPOTREBLJAVAJU ZA STANOVANJE	
	DVORIŠTE	ZEMLJIŠTE PRIVEDENO SVRSI	

Tablica 6: Rezultat strukturiranja posjednika/vlasnika.

Naziv	Ime	Prezime	Ime oca	Djevojačko prezime
BOŽIĆEV DARKO MLDB. POK. DINKA	DARKO	BOŽIĆEV	DINKA	–

Tablica 7: Rezultati kategorizacije upisa.

OPIS UPISA	KATEGORIJA	POTKATEGORIJA
Zaprimljeno 15.11.2013. broj Z-2643/13 Na temelju pravomoćnog rješenja Ministarstva kulture, Uprava za zaštitu kulturne baštine Klasa:UP-I-612-08/07-06/0147 ur.broj:532-04-01-04/16-13-3 od 09. listopada 2013.g. zabilježuje se da je čest. zem. 429/1, 438 ima svojstvo kulturnog dobra	POSEBNI PRAVNI REŽIMI	KULTURNO DOBRO

kategorizirano 170 034 upisa, što predstavlja uspješnost od 96,4%. Naknadnim manualnom iteracijom, od nekategoriziranih 6356 zapisa, kategorizirano je dodatnih 1650 zapisa te je ukupan postotak kategorizacije 97,3%.

Kada su u pitanju rezultati strukturiranja vlasnika i posjednika (Tablica 6), od 26 631 837 zapisa koji su prepoznati kao fizičke osobe, a koje nisu bile strukturirane, primjenom modela strukturirano ih je 26 082 522, što predstavlja uspješnost od 97,9%.

Kada su u pitanju rezultati kategorizacije upisa, 85 389 upisa je kategorizirano kao posebni pravni režim, 1549 kao koncesija te 759 006 kao upis služnosti. Posebnim pravnim režimima i služnostima su pridružene odgovarajuće potkategorije (Tablica 7).

5. Zaključak

Preduvjet za izradu kvalitetnih analiza je kvaliteta i struktura podataka nad kojima se analiza provodi. Ako se podaci žele filtrirati ili grupirati po pojedinoj dimenziji, bitno je da postoji strukturirana informacija u modelu podataka koja se želi iskoristiti u tu svrhu. Nadalje, bitno je da je sadržana informacija točna. Bez ispunjenja ovih preduvjeta, rezultati analize neće sadržavati potpune podatke ili će dijelom sadržavati podatke koji nisu ispravni. Rezultati prikazani u ovom radu pokazali su da je primjenom novih tehnologija poput umjetne inteligencija i strojnog učenja moguće vrlo brzo i s visokom točnošću podići kvalitetu postojećih podataka u katastru i zemljišnim knjigama. Navedene podatke moguće je koristiti za složene analize i izvještaje i na taj način omogućiti nadležnim institucijama, ali i drugim zainteresiranom korisnicima što bolje informacije o stanju u prostoru.

Iako su kategorizirani i strukturirani podaci visoke točnosti, trenutno se zbog zakonske regulative podaci dobiveni na ovaj način ne mogu koristiti za održavanje službenih evidencijama. Stoga bi u budućnosti trebalo raditi na prilagodbi zakonskih okvira kako bi se ovi podaci mogli u manjoj ili većoj mjeri iskoristiti u postupcima održavanja katastarskog operata i zemljišnih knjiga. Također, u budućnosti je potrebno nastaviti koristiti ove i slične moderne tehnologije kako bi se kontinuirano podizala kvaliteta zemljišnih podataka, jer će to rezultirati i podizanjem kvalitete poslovnih procesa i javnih usluga koje koriste zemljišne podatke, a što će dugoročno donijeti korist svim građanima Republike Hrvatske.

Literatura

Narodne novine (2018a): Pravilnik o geodetskim elaboratima, br. 59/18, Zagreb.

Narodne novine (2018b): Zakon o državnoj izmjeri i katastru nekretnina, br. 112/18, Zagreb.

Narodne novine (2019): Zakon o zemljišnim knjigama, br. 63/19, Zagreb.

Application of Artificial Intelligence and Machine Learning Methods in Land Data Management

Abstract

Cadastre and land registry data are accessed daily by many citizens and business subjects, and they are also used in business processes by numerous institutions and public authorities. This was recognized by the Government of the Republic of Croatia, which led to declaring real estate cadastre and land register as the key registers for spatial data. Many cadastre and land registry digitization projects have been implemented in the past few decades, but browsing data using simple analytical queries still remains challenging. The main reasons for this are inadequately structured and categorized data, which were mostly copied from written books in unstructured form. Technological developments in the field of artificial intelligence and machine learning in the past few years have enabled the wider implementation of these technologies in various fields. Subsequently, this was recognized in the project "Land Data Management" which used these technologies for the improvement in organizing and categorizing cadastral and land registry data. Machine learning methods for word processing were used to find similarities between words, predict the meaning of abbreviations and word types. This enabled the identification and categorization of land use, buildings, special legal regimes, concessions, easements and structuring the data of physical persons that are registered in the cadastre and land books. Those results are presented in this study. Furthermore, we analysed the possibility of applying these technologies to other data types and necessary adjustments to the legal framework to put these data into official records.

Keywords: *artificial intelligence, cadastre, land data management, land registry, machine learning*

Korištenje umjetne inteligencije u raspoznavanju podzemne infrastrukture te primjena pri kreiranju sustava inteligentne infrastrukture

Sanja Vaclavek[1], Martin Šutalo[2], Bojan Blažona[3]

[1] Ericsson Nikola Tesla, Zagreb, Hrvatska, sanja.vaclavek@ericsson.com

[2] Ericsson Nikola Tesla, Zagreb, Hrvatska, martin.sutalo@ericsson.com

[3] Ericsson Nikola Tesla, Zagreb, Hrvatska, bojan.blazona@ericsson.com

Sažetak

U radu se predstavlja novi informacijski sustav katastra infrastrukture (SKI) i jedinstvene informacijske točke (JIT) pušten u produkcijski rad 2020. godine za područje Sisačko-moslavačke i Bjelovarsko-bilogorske županije. Širenje sustava nastavilo se za područja Međimurske, Vukovarsko-srijemske, Virovitičko-podravske, Požeško-slavonske i Brodsko-posavske županije. Trenutno se u bazi sustava nalaze podaci za navedene županije, no baza će se kontinuirano puniti dok sva infrastruktura u Hrvatskoj ne bude dio sustava. Početkom godine, u rad se pustio digitalni geodetski elaborat infrastrukture (DGEI). Puštanjem u rad, proces predaje digitalnog geodetskog elaborata infrastrukture, elaborati katastra infrastrukture dobili su unificiran izgled i strukturu, a digitalizacija i automatizacija procesa „od predaje do ovjere" jamči transparentnost. Nadalje, u radu se analizira inovativnost pristupa sustava 4D Inteligentna Infrastruktura (4DII) pri razvoju katastra infrastrukture u Republici Hrvatskoj. U tu svrhu provedena je analiza odabrane dostupne literature i podataka koji se odnose na katastar infrastrukture te do sada završenog materijala sustava 4DII, koji se razvija u sklopu inovativno-znanstveno-istraživačkog projekta „Centar kompetencija za pametne gradove" (CEKOM). Rezultati analize pokazali su da se inovativan pristup projekta 4DII sastoji od: uvođenja novih načina obrade, evidencije, inventarizacije, nadzora i analize infrastrukture u prostorno-vremenskoj dimenziji (4D); integracije različitih informacija o infrastrukturi s drugim socio-ekonomskim informacijama i utjecaj koji infrastruktura ima na odvijanje poslovnih procesa pametnog grada (investicije, održavanje, kritična infrastruktura); inovativne metode vizualizacije i prezentacije (pojačana stvarnost) podataka i primjena georadara u detekciji infrastrukture uz primjenu umjetne inteligencije.

Ključne riječi: *3D, 4D, AI, georadar, infrastruktura*

1. Uvod

Sustav katastra infrastrukture (SKI) sustav, omogućuje vođenje, pohranu i distribuciju podataka katastra infrastrukture i na taj način doprinosi dostupnosti i mogućnosti preuzimanja podataka katastra infrastrukture tijelima državne uprave, jedinicama lokalne samouprave, javnim poduzećima i vlasnicima, odnosno upraviteljima infrastrukture.

Sustav 4D Inteligentne infrastrukture (4DII) istražuje mogućnosti poboljšanja upravljanja infrastrukturom, načina prikupljanja i snimanja podataka pomoću 3D koordinatnog zapisa, kao osnove za prikaz objekata u prostoru. Korištenjem vremenskih karakteristika infrastrukturnih objekata (godina izgradnje, predviđeni rok trajanja i sl.) objektima se dodaje vremenska komponenta čime se stvaraju preduvjeti za izradu 4D katastra infrastrukture. Uz klasični 2D grafički preglednik, 4DII sustav ima mogućnost pregleda infrastrukture u 3D prostoru s mogućnošću pregleda nastanka objekata, kao i njihovih karakteristika, kroz vrijeme.

SKI sustav veliki je napredak u pogledu standardizacije i digitalizacije gdje se predstavlja osnova za sustavno vođenje informacija o objektima vlasnika, odnosno upravitelja infrastrukture na nacionalnoj razini na jednom mjestu. 4DII sustav u svojoj istraživačkoj komponenti istražuje potrebu za podrškom svakodnevnom operativnom radu vlasnika tj. upravitelja infrastrukture uz mogućnost razmjene podataka sa SKI/JIT sustavom.

2. Novi informacijski sustav katastra infrastrukture (SKI) i jedinstvene informacijske točke (JIT)

U katastru infrastrukture evidentiraju se vodovi (i drugi objekti) elektroenergetske, elektroničko komunikacijske, toplovodne, plinovodne, naftovodne, vodovodne i odvodne infrastrukture, što je približno 330.000 km vodova. Budući da se radi o velikom broju podataka različitih vrsta vodova koji su se vodili kod većeg broja subjekata u različitim oblicima, osnivanje i vođenje jedinstvene baze katastra infrastrukture na državnoj razini bilo je prioritetno za uspostaviti.

Zakon o državnoj izmjeri i katastru nekretnina (Narodne novine 2018), članak 123. propisuje da je Državna geodetska uprava nadležna za osnivanje, vođenje i održavanje infrastrukture, a iznimno od članka 123. istog Zakona, poslove iz članka 123. mogu obavljati jedinice lokalne samouprave te za područja mora tijelo nadležno za hidrografsku izmjeru na moru. Shodno navedenom, 2018. godine započeo je razvoj aplikativnog rješenja i implementacije sustava katastra infrastrukture i jedinstvene informacijske točke. Na razvoju, uz stručnjake iz Ericsson Nikola Tesle, sudjelovao je i tim iz tvrtke IGEA d.o.o.

SKI sustav sastoji se od javnog i privatnog dijela. Javni dio (Jedinstvena informacijska točka) namijenjen je svim građanima RH (registrirani i neregistrirani korisnici), dok je privatni dio sustava katastra infrastrukture namijenjen prvenstveno zaposlenicima DGU koji unutar sustava rade prema definiranim poslovnim procesima katastra infrastrukture. Za područje Sisačko-moslavačke i Bjelovarsko-bilogorske županije Sustav je pušten u produkcijski rad 2020. godine. Širenje Sustava nastavilo se za područja Međimurske, Vukovarsko-srijemske, Virovitičko-podravske, Požeško-slavonske i Brodsko-posavske županije. Trenutno se u bazi sustava nalaze podaci za navedene županije, no baza će se kontinuirano puniti dok sva infrastruktura u Hrvatskoj ne bude dio sustava.

SKI sustav omogućuje vođenje, pohranu i distribuciju podataka katastra infrastrukture za cijelo područje Republike Hrvatske i na taj način poboljšava se dostupnost i preuzimanje podataka katastra infrastrukture ostalim tijelima državne uprave, jedinicama lokalne samouprave, javnim poduzećima i vlasnicima, odnosno upraviteljima infrastrukture.

Implementacijom jedinstvene informacijske točke osigurala se dostupnost podataka i raspolaganje podacima o postojećoj fizičkoj infrastrukturi upravitelja te obavijestima o tekućim ili planiranim građevinskim radovima, što za posljedicu ima smanjenje troškova uzorkovanih izravnim i neizravnim štetama prilikom izvođenja radova na fizičkoj infrastrukturi, te smanjenje troškova i zapreka prilikom izvođenja novih građevinskih radova.

2.1. Komponente SKI sustava

SKI privatni dio Sustava uključuje jedinstvenu bazu podataka o infrastrukturi kao temeljni dio Sustava. Također, razvijeno je aplikativno rješenje za preuzimanje, kontrolu i zapisa postojećih podataka o infrastrukturi upravitelja i vlasnika infrastrukture, odnosno jedinica lokalne samouprave iz katastra infrastrukture (inicijalni uvoz), zatim za zaprimanje, pregled i potvrđivanje geodetskog elaborata infrastrukture (D(GEI)), te za unos podataka pregledanih i potvrđenih geodetskih elaborata infrastrukture (unos arhiviranih elaborata). U SKI sustavu omogućeno je izdavanje podataka i javnih isprava, statističko izvještavanje, te administriranje sustava. Uspostavom SKI sustava uspostavio se i jedinstveni registar korisnika sustava, odnosno, popis vlasnika/upravitelja infrastrukture na državnoj razini.

JIT javni dio Sustava uključuje jedinstvenu bazu podataka o infrastrukturi te prezentacija baze kao temeljni dio Sustava. Također, razvijeno je aplikativno rješenje za atributno i prostorno pretraživanje podataka katastra infrastrukture, izdavanje podataka i javnih isprava, statističko izvještavanje i administriranje sustava. Implementirana je javna dostupnost setova podataka infrastrukture u skladu sa Zakonom o Nacionalnoj infrastrukturi prostornih podataka za registrirane korisnike, te distribucija podataka web servisima. Omogućen je zapis, prikaz i preuzimanje obavijesti o tekućim ili planiranim građevinskim radovima na infrastrukturi, te atributno i prostorno pretraživanje planiranih i završenih građevinskih radova. Trenutno se objekti SKI sustava prikazuju u 2D pregledniku, a intencija je u budućnosti kreirati 3D preglednik.

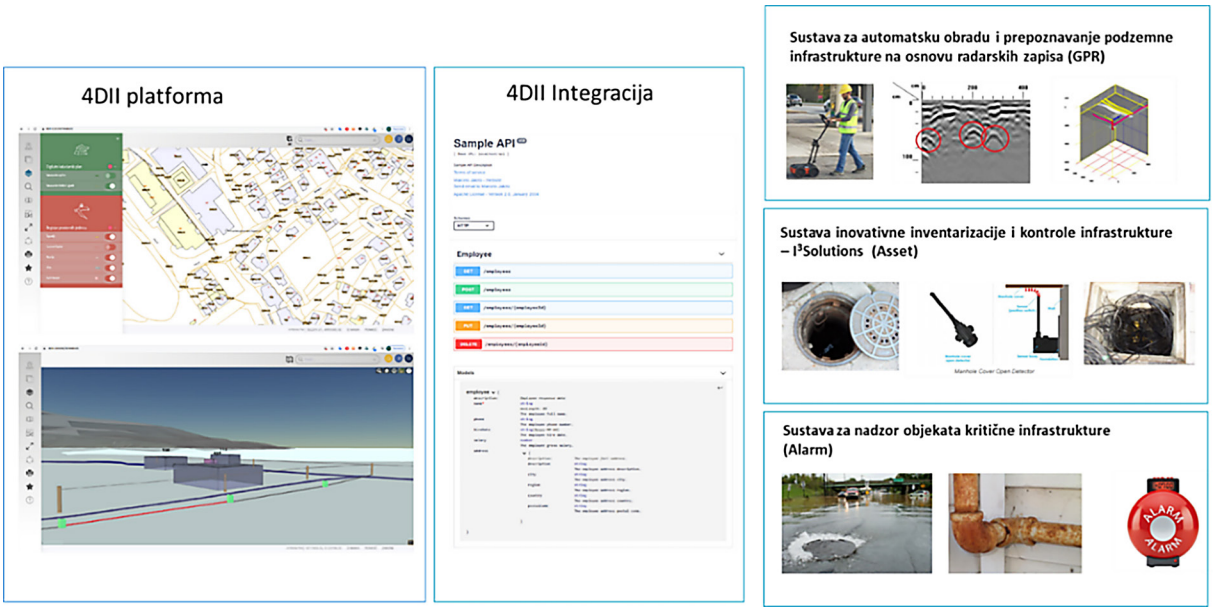
2.2. Razmjenski format

U sklopu projekta definirana su dva razmjenska formata: razmjenski format zapisa za inicijalni uvoz i razmjenski format zapisa za potrebe izrade digitalnog geodetskog elaborata infrastrukture (DGEI). Razmjenski formati predstavljaju dokumente čija je namjena opisati razmjensku strukturu i format podataka koji se koristi za unos podataka u SKI sustav putem inicijalnog uvoza i digitalnog geodetskog elaborata infrastrukture. Svrha je bila propisati razmjenski model koji će unificirati i pojednostaviti proces uvoza podataka, s obzirom na različitost upravitelja, količine podataka, te strukture podataka o kojima upravitelji odnosno vlasnici infrastrukture raspolažu.

Početkom 2022. godine, u rad se pustio digitalni geodetski elaborat infrastrukture (DGEI). Puštanjem u rad proces predaje digitalnog geodetskog elaborata infrastrukture, elaborati katastra infrastrukture dobili su unificiran izgled i strukturu, a digitalizacija i automatizacija procesa „od predaje do ovjere“ jamči transparentnost.

2.3. Povezanost s ostalim informacijskim sustavima

Integracija SKI sustava uspostavljena je s temeljnim informacijskim sustavom ZIS (Zajednički informacijski sustav zemljišnih knjiga i katastra) koji se koristi za pisarnički dio i za otpremu dokumenata, a između ostalog implementirane su i integracije s OSS sustavom,



Slika 1: Poslovna arhitektura sustava 4DII

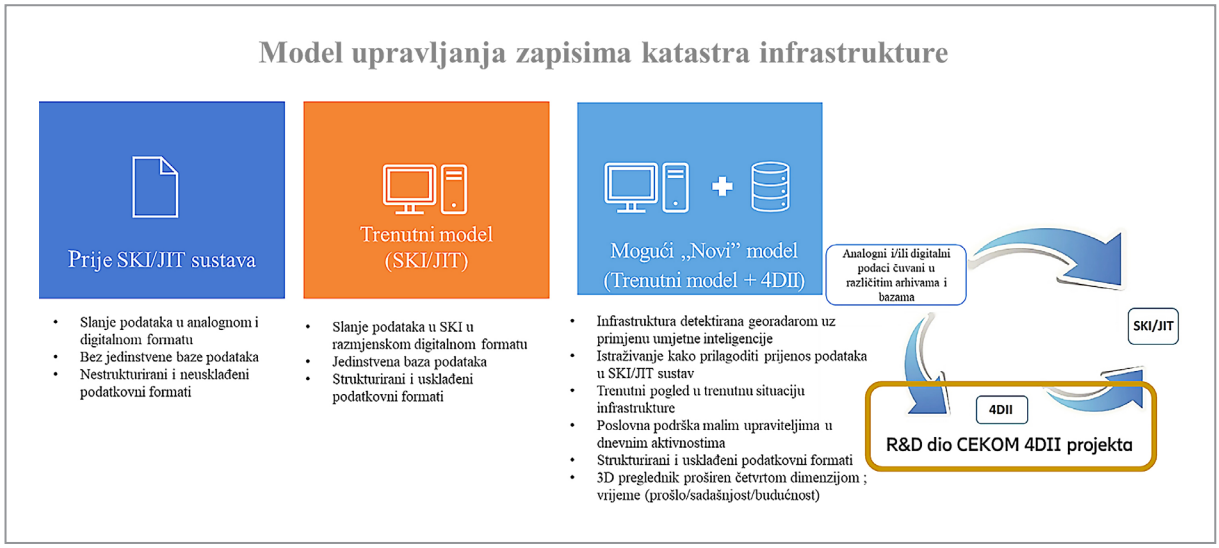
Geoportalom, SDA sustavom, OIB sustavom, NIAS sustavom, OKP/PKP, ePoslovanje i RPJ sustavom.

3. Sustav 4D inteligentne infrastrukture

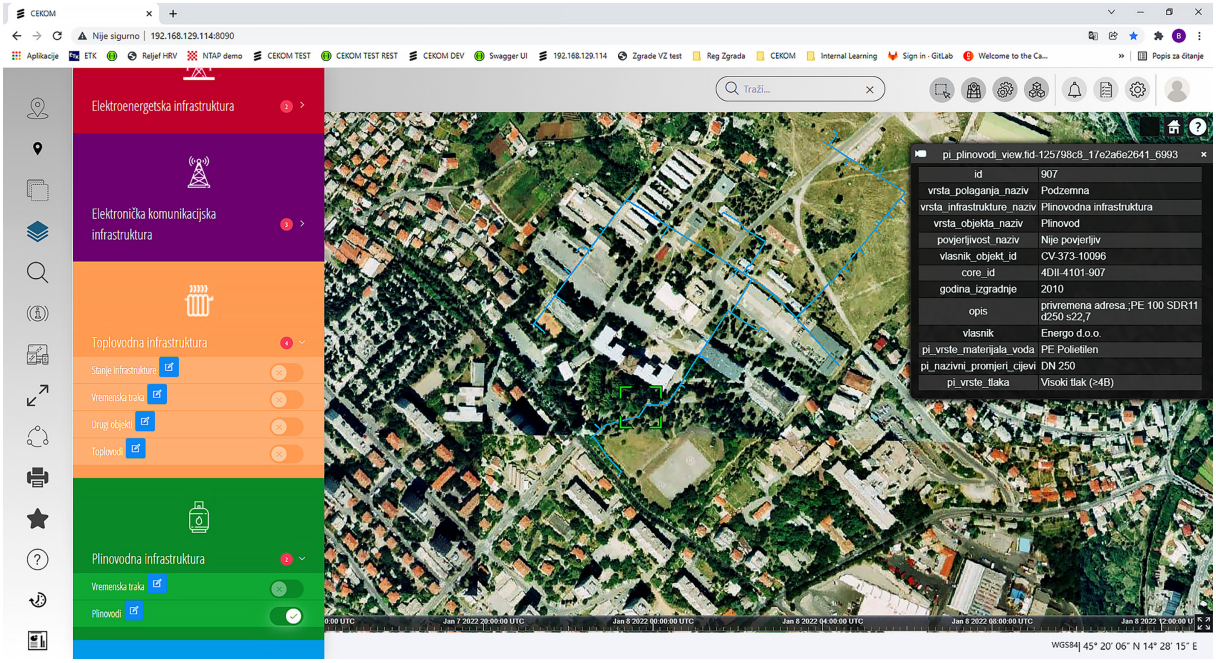
Sustav 4D Inteligentne infrastrukture (4DII) razvija se u sklopu projekta CEKOM Rijeka. Projekt 4DII istražuje mogućnosti poboljšanja upravljanja infrastrukturom, načina prikupljanja i snimanja podataka pomoću 3D koordinatnog zapisa, kao osnove za prikaz objekata u prostoru.

Korištenjem vremenskih karakteristika infrastrukturnih objekata (godina izgradnje, predviđeni rok trajanja i sl.) objektima se dodaje vremenska komponenta čime se stvaraju preduvjeti za izradu 4D katastra infrastrukture. Uz klasični 2D grafički preglednik, 4DII sustav ima mogućnost pregleda infrastrukture u 3D prostoru s mogućnošću pregleda nastanka objekata, kao i njihovih karakteristika, kroz vrijeme.

4DII razvija nekoliko partnera na projektu, uz Ericsson Nikola Teslu na projektu sudjeluju Vodovod i kanalizacija (Rijeka), Energo (Rijeka), Energetski institut Hrvoje Požar, Sveučilište u Rijeci, 3t Cable (Rijeka), Alarma Automatika (Rijeka) te Smart RI (Rijeka). Osnovna poslovna arhitektura sustava uključuje 4DII platformu koja čuva sve podatke o infrastrukturi te je može prikazivati u 2D i 3D režimu pregleda, 4DII integracijski dio koji uključuje REST API kao i standardne OGC servise za potrebe integracija, modul za prepoznavanje infrastrukture na temelju georadarskih zapisa uz korištenje umjetne inteligencije, sustava za inventarizaciju infrastrukture u puno više detalja posebice za elektroničko komunikacijsku infrastruk-



Slika 2: Prikaz korelacije sustava SKI i 4DII



Slika 3: Prikaz 4DII objekata u 3D pregledniku

turu kao i sustava za nadzor kritične infrastrukture koji uključuje integraciju u postojeći nadzorni sustav operatera infrastrukture (Slika 1).

3.1. Korelacija sustava SKI i 4DII koncepta

S gledišta potreba 4DII projekta koji uključuju bolje upravljanje infrastrukturom, povećanja efikasnosti infrastrukture, bolja usluga korisnicima komunalnih usluga, smanjenje troškova upravljanja infrastrukturom što kao rezultat treba polučiti privlačenje investicija i bržu realizaciju infrastrukturnih potreba napravljena je korelacija s novim sustavom SKI i realnim potrebama operatera infrastrukture u njihovoj specifičnosti ovisno o infrastrukturi te dnevnim operativnim potrebama.

Sustav SKI veliki je napredak u pogledu standardizacije i digitalizacije gdje se predstavlja osnova za sustavno vođenje informacija u statičkom/neoperativnom režimu rada u domeni operatera i vlasnike infrastrukture gdje se na nacionalnoj razini na jednom mjestu prikupljaju informacije o infrastrukturi. 4DII projekt u svojoj istraživačkoj komponenti istražuje potrebu za podrškom svakodnevnom operativnom radu vlasnika tj. upravitelja infrastrukture uz mogućnost razmjene podataka sa SKI/JIT sustavom. Sažeti vizualni prikaz korelacije s detaljima dan je na Slici 2.

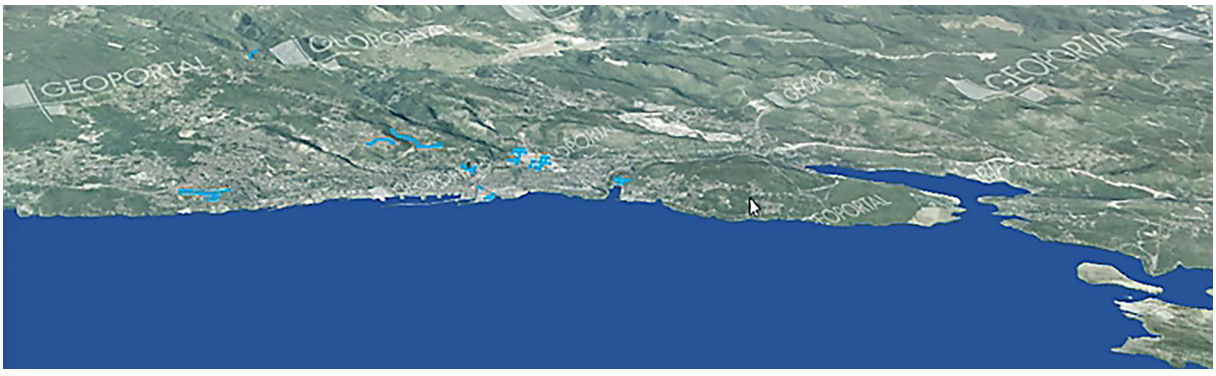
3.2. Funkcionalnosti sustava 4DII

Temeljni dio sustava 4DII je baza podataka koja omogućuje zapis geografskih informacija u sistematično podijeljene slojeve pri čemu svi objekti dobivaju jedinstveni 4DII identifikator u smislu jednoznačnog označavanja objekta tj. razmjene strukturiranih podataka unutar sustava kao i s drugim sustavima putem dostupnih integracijskih sučelja.

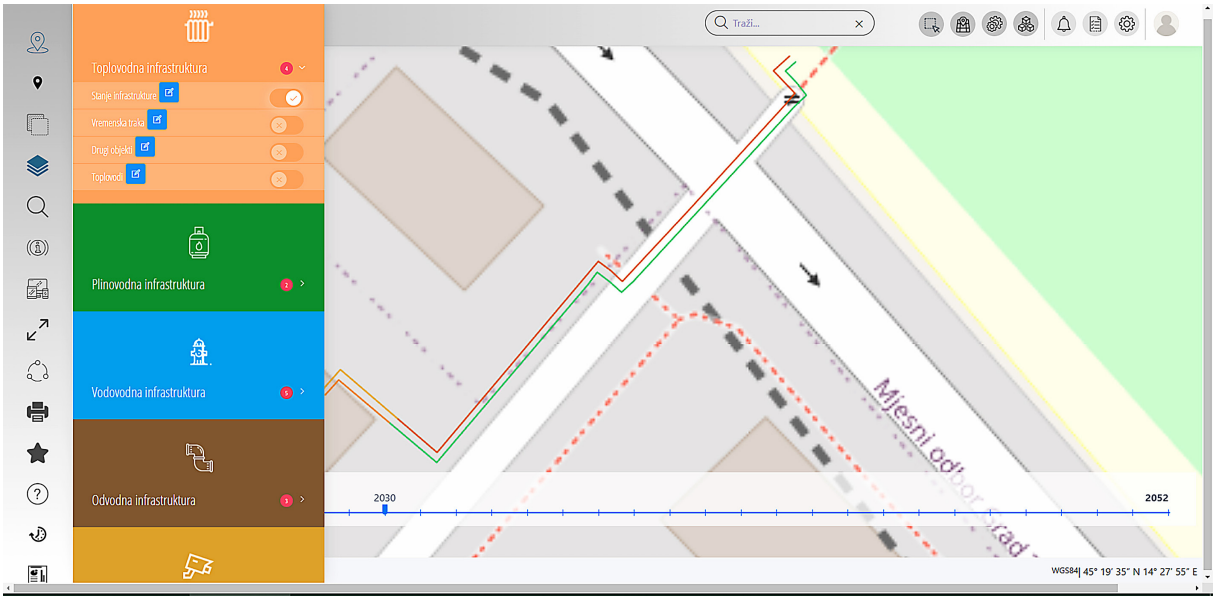
Infrastruktura unesena u 4DII sustav podrazumijeva unos sve 3 koordinate (E, N, h) objekata (linijskih i točkastih) što omogućuje višestruke mogućnosti u smislu prikaza i vizualizacije podataka kao i mogućnosti nadogradnje u budućnosti za korištenje u drugim specijaliziranim alatima u smislu sustava hidraulike i drugo. Moguća je vizualizacija u 3D pregledniku što podrazumijeva dostupnost preciznog 3D model reljefa kao i točne koordinate objekata infrastrukture koji se nalaze ispod površine zemlje (Slika 3). S tehnološkog aspekta, preglednik omogućuje prikaz detaljnog 3D reljefa i linijske infrastrukture kao i točkastih objekata uz različite mogućnosti razine transparentnosti podloge kao i selekciju objekata (Slika 4).

Operativni rad upravitelja tj. vlasnika podrazumijeva zahtjeve za izmjenom ili popravkom dijela infrastrukture te bilježenjem stanja infrastrukturnih objekata. U svrhu podrške, s gledišta IT sustava, u svakodnevnom radu tom zahtjevu, sustav 4DII ima ugrađenu integraciju s BPM – sustavom za upravljanje poslovnim procesima (engl. BPM Business Process Management) te ugrađeno 10-ak poslovnih procesa koji su detektirani u sklopu inicijalnih faza 4DII projekta kao potreba vlasnika i upravitelja infrastrukture i jedinice lokalne samouprave kao konačnog vlasnika infrastrukture na nekom području.

Stanje infrastrukture predstavlja četvrtu vremensku komponentu 4DIIsustava uz 3D. Na temelju izrađene studije EIHP-a koja definira algoritam procjene stanja infrastrukture na temelju ulaznih parametara (godina izgradnje, vrsta infrastrukture, senzorska očitanja,…) sustav računa faktor stanja i faktor kritičnosti infrastrukture u sadašnjosti te daje predviđanje stanja u budućnosti. Rezultati se vizualiziraju na web pregledniku na način da se bojom identificira i filterima omogućuje selekcija i identifikacija infrastrukture koja zahtjeva pozornost u danom trenutku. Aplikacija omogućuje izračun faktora koji ukazuju na stanje infrastrukture i kritičnost segmenata na način da se može odabrati vrijeme u budućnosti te selektirati faktor kritičnosti C1-C4. Stanje infra-



Slika 4: 3D prikaz infrastrukture u 4DII sustavu (uneseni vodovodi, Rijeka)



Slika 5: Prikaz stanja infrastrukture u vremenskoj domeni.

strukture prikazuje se bojom (zeleno -> crveno) prema definiranoj studiji za ocjenu stanja infrastrukture (Slika 5).

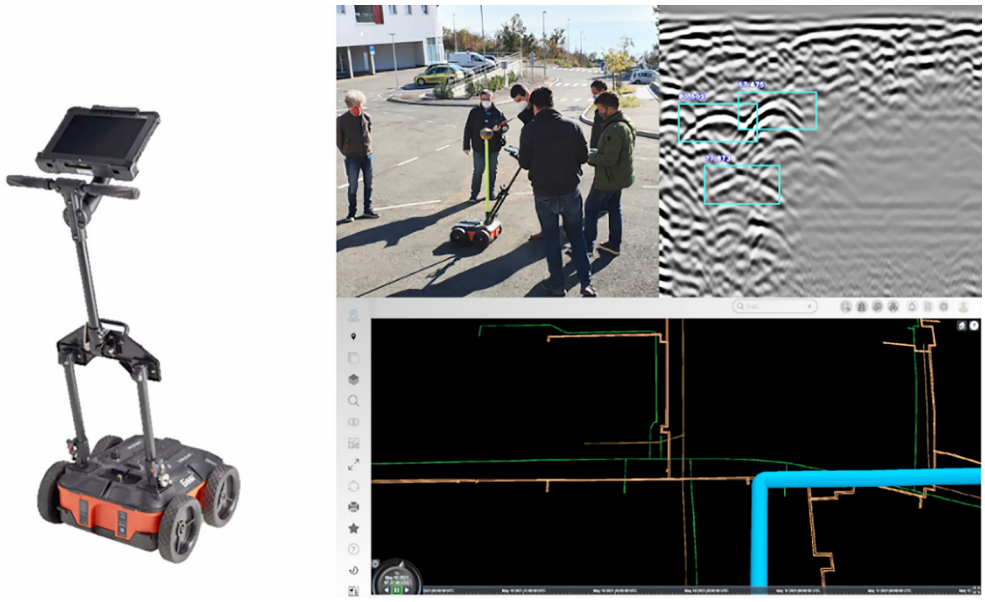
3.3. Umjetna inteligencija u raspoznavanju podzemne infrastrukture

Upravitelj i vlasnici, uz veliki napredak u novije vrijeme prilikom bilježenja postavljenje infrastrukture uz primjenu geodetskih metoda i dalje na obuhvatima djelovanja nailaze na vlastitu ili tuđu neobilježenu infrastrukturu. Ista može biti u statusu korištenja, ali je u pravilu izvan funkcije. Bitna istraživačka komponenta 4DII sustava je razvoj podsustava za prepoznavanje podzemne infrastrukture primjenom georadara i primjenom umjetne inteligencije u smislu ubrzanja procesa identifikacije infrastrukture.

U svrhu razvoja podsustava napravljeno je 8500 reprezentativnih anotacija (označenih sličica za učenje), uz svaku sličicu napravljena je augmentacija (uparivanje i proširenje) alfanumeričkim podacima domenskih partnera koji imaju točne zapise infrastrukture (kut, vrsta materijala, širina elementa), radilo se na preciznosti anotacija ručnim korekcijama i dodatno razvijenim kodom, nabavljeni su GPR i GNSS uređaji s pripadajućim softverima, naučeno domensko znanje u tumačenju radarskih snimki te osmišljen proces pripreme i vođenje procesa snimanja i obrade na lokacijama koje su reprezentativne za stvarne situacije na terenu.

Za potrebe umjetne inteligencije kao osnovica odabran je YOLO (engl. „You only look once“) koji je treniran na temelju reprezentativnih uzoraka. Treniranje mreže je zahtjevan proces koji se odrađuje na grafičkim radnim stanicama dok korištenje naučene mreže ne zahtjeva značajne grafičke resurse. Rezultati dosadašnjeg istraživanja pokazuju na pozitivne pomake u smislu vjerojatnosti koje se pridjeljuju detektiranim segmentima infrastrukture što će se do kraja projekta kvantitativno sumirati kroz TRL5/TRL6 fazu projekta.

Proces snimanja kao i slika korištenog georadara dani su u nastavku, kao i segment stvarne radarske snimke s vjerojatnostima detekcije primjenom naučene neuronske mreže. Nakon procesa prepoznavanja točaka infrastrukture radi se 3D rekonstrukcija



Slika 6: Prikaz georadara, snimanje na terenu, obrađene slike AI algoritmom te rekonstrukcija u 4DII platformi.

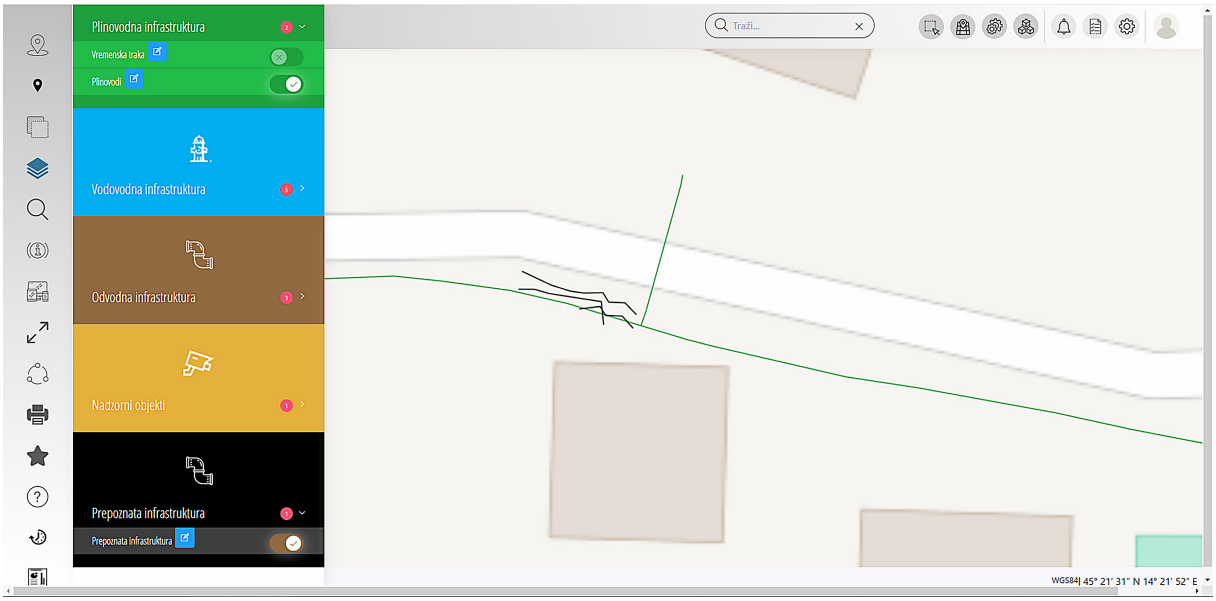
kako bi se za točke kreirali linijski prikazi što odgovara cijevima koje su i predmet identifikacije (Slika 6).

Prepoznata infrastruktura sprema se u posebni privremeni sloj sustava 4DII te je vidljiv na pregledniku pri čemu se prikazuju vjerojatnosti koji su dodijeljene prilikom prepoznavanja. S obzirom da se radi o nepoznatoj infrastrukturi, čak i informacija da se nešto nalazi ispod površine, uvelike utječe na način pristupa invazivnom raskopu područja radi različitih potreba građenja, sanacije ili ugradnje nove infrastrukture. Kroz sustav je dana mogućnost upraviteljima i vlasnicima za preuzimanjem linijske prepoznate infrastrukture u operativne slojeve infrastrukture (stvarni zapisi) ovisno o potrebama (Slika 7).

4. Zaključak

Sustav SKI postigao je ključni korak potreban za sustavno upravljanje infrastrukturom i podršku poslovnim procesima u Republici Hrvatskoj. Razvoj sustava kao što je 4DII uvelike može unaprijediti svakodnevne poslovne potrebe vlasnika tj. upravitelja infrastrukture.

Sustav 4DII, uz postojeći SKI sustav, predstavlja dobar primjer modernizacije i digitalizacije poslovanja, te omogućuje bolje planiranje i niže troškove poslovanja. Uz 4DII sustav vlasnici/upravitelji će imati priliku bolje upravljati javnim sredstvima u interesu građana Republike Hrvatske, a investicija koja se odrađuje kroz uspostavu SKI sustava može se dodatno ople-



Slika 7: Prikaz prepoznate infrastrukture (crne linije) na sloju prepoznate infrastrukture.

meniti mogućnošću operativnog rada nad unesenim podacima.

Rad na sustavu 4DII u aktivnoj je fazi TRL5/TRL6 do sredine trećeg mjeseca 2023. godine te će konačni rezultati istraživačkog rada biti poznati tada, no već sada se nazire stvarna potreba za ovakvim sustavom i konceptom uz potrebne promjene upravljačkih procesa u JLS-ovima u smislu dijeljenja tj. korištenja podataka različitih upravitelja/vlasnika infrastrukture.

Literatura

Narodne novine (2018): Zakon o državnoj izmjeri i katastru nekretnina, br. 112/18, Zagreb.

The Use of Artificial Intelligence in the Recognition of Underground Infrastructure and its Application in the Creation of an Intelligent Infrastructure System

Abstract

The paper presents the new information system of utility cadastre (SKI) and single information point (JIT) put into production in 2020 for the area of Sisak-Moslavina and Bjelovar-Bilogora counties. Further development of the System continued for the areas of Međimurje, Vukovar-Srijem, Virovitica-Podravina, Požega-Slavonia and Brod-Posavina counties. Currently, the system database contains data for the mentioned counties, but the database will be continuously filled until all the infrastructure in Croatia is part of the system. At the beginning of the year, the Digital Geodetic Elaborate of Infrastructure (DGEI) was put into operation. With the launch of the process of submission of the digital geodetic elaborate of infrastructure, the utility cadastre studies received a unified layout and structure, and the digitization and automation of the process "from submission to certification" guarantees transparency. Furthermore, the paper analyses the innovative approach of the 4D Intelligent Infrastructure (4DII) system in the development of the utility cadastre in the Republic of Croatia. For this purpose, an analysis of selected available literature and data related to the utility cadastre, as well as the material of the 4DII system completed so far, which is being developed as part of the innovative-scientific-research project "Competence Center for Smart Cities" (CEKOM), was carried out. The results of the analysis showed that the innovative approach of the 4DII project consists of: introducing new ways of processing, recording, inventorying, monitoring and analysis of infrastructure in the space-time dimension (4D); integration of different information about infrastructure with other socio-economic information and the impact that infrastructure has on the development of smart city business processes (investments, maintenance, critical infrastructure); innovative methods of visualization and presentation (augmented reality) of data and application of georadar in infrastructure detection with the use of artificial intelligence.

Keywords: *3D, 4D, AI, georadar, infrastructure*

Virtualni asistenti u zemljišnoj administraciji – mit ili nezaobilazna budućnost?

Jelena Jurišić[1], Ilija Ćaćić[2]

[1] Ericsson Nikola Tesla, Krapinska 45, Zagreb, Hrvatska, jelena.jurisic@ericsson.com

[2] Ericsson Nikola Tesla, Krapinska 45, Zagreb, Hrvatska, ilija.cacic@ericsson.com

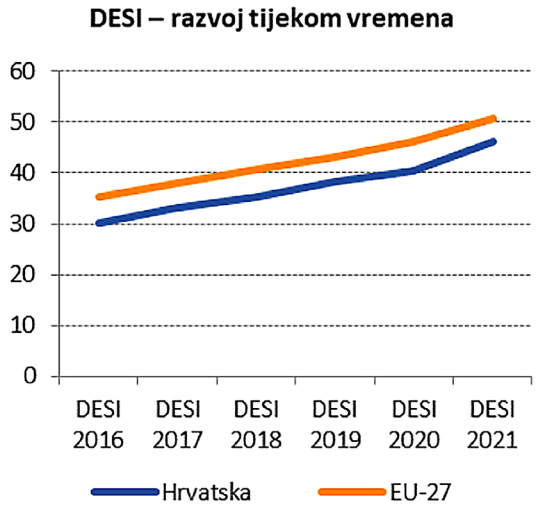
Sažetak

Vlada Republike Hrvatske prepoznala je da je za daljnji napredak hrvatskog društva i gospodarstva nužno izgraditi digitalne kapacitete kroz razvoj digitalnih usluga i digitalnu transformaciju. Usluge katastra i zemljišnih knjiga svakodnevno koristi veliki broj građana i poslovnih subjekata te se zadnjih 10 godina intenzivno radi na tome da se, što je moguće više usluga, ponudi u elektroničkom obliku, odnosno kao e-usluge. Prema Europskoj komisiji svaka e-usluga može biti razine od 1 do 5, pri čemu razina 5 podrazumijeva da je obavljanje usluge proaktivno na način da se od korisnika traži samo suglasnost. Većina e-usluga implementiranih u RH kao digitalni kanal koriste web stranicu te su razine 4. Virtualni asistenti omogućavaju da usluga bude istovremeno dostupna kroz različite digitalne kanale i proaktivna te da bude prilagođena pojedinom korisniku. Pandemija korona virusa dovela je do značajnog porasta korištenja virtualnih asistenata za poslovnu komunikaciju i automatizaciju. Očekuje se da će globalno tržište virtualnih asistenata dostići 10,5 milijardi dolara do 2026. godine. Prvi tipovi virtualnih asistenata bili su bazirani na pravilima i jednostavni, a razvojem tehnologije danas su dostupni virtualni asistenti koji koriste metode obrade prirodnog jezika i strojno učenje i kao takvi postižu zavidne rezultate u svim granama industrije. U budućnosti, virtualni asistenti postat će još zreliji i sposobniji predvidjeti potrebe korisnika. Kao rezultat toga, povećat će svoju učinkovitost i raditi na još personaliziraniji način. U sklopu ovog rada prikazat će se mogućnost primjene konverzacijskog virtualnog asistenta u zemljišnoj knjizi i katastru te razmotriti potrebne prilagodbe pravnog okvira kako bi se navedeno podržalo.

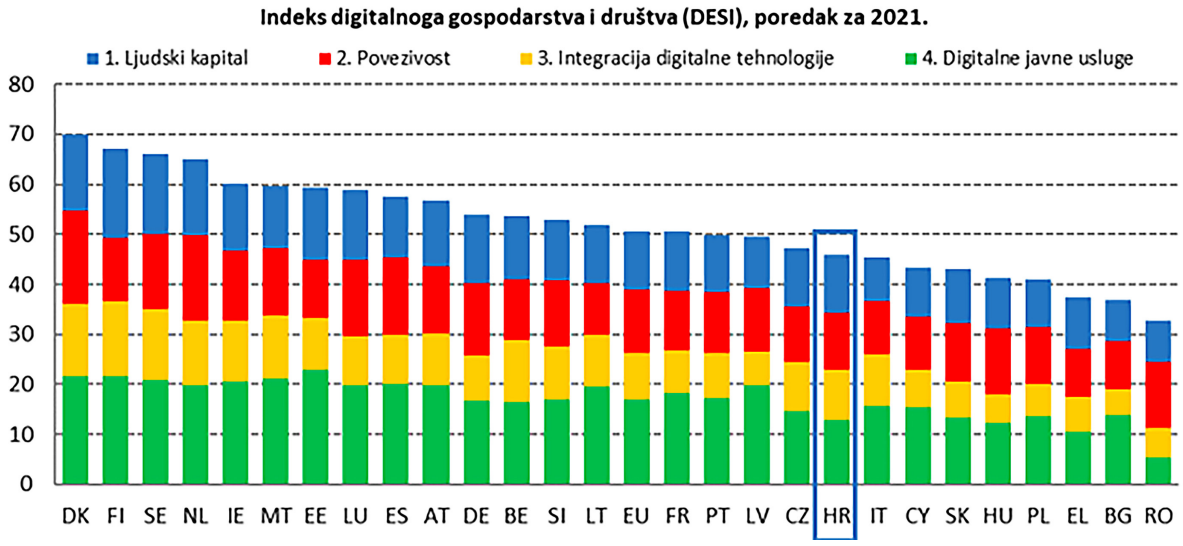
Ključne riječi: *katastar, konverzacijski dizajn, obrada prirodnog jezika, virtualni asistent, zemljišna knjiga*

1. Razvoj elektroničkih usluga u Republici Hrvatskoj

Standard razvoja javnih e-usluga u Republici Hrvatskoj (URL 1) definira e-uslugu kao uslugu koju pruža javno tijelo/institucija putem digitalnih kanala. Javne e-usluge ubrzavaju učinkovitost administrativnih sustava, optimiziraju administrativne poslovne procese, podižu razinu transparentnosti i time poboljšavaju kvalitetu javne uprave koja u navedenom slučaju postaje e-uprava. Za korisnike e-usluga to znači brži način dobivanja informacija i rješavanja životnih situacija/problema iz vlastitog doma ili ureda bez fizičkih odlazaka na šalter državne institucije. U Lindgren i Jansson (2013) je navedeno da e-uprava ima tri cilja: 1) poboljšati mogućnosti građana za interakciju s državnim tijelima, 2) povećati učinkovitost državnih tijela smanjenjem broja manualnih procedura i 3) povećati demokraciju kroz veću transparentnost vlade. Posljednjih 10-ak godina RH napreduje u ovim ciljevima, premještajući svoj fokus s internih procedura na scenarije u kojima građani koriste javne e-usluge za obavljanje složenih transakcija s državnim tijelima, tj. vladinim uslugama korištenjem informacijske tehnologije. Taj napredak je vidljiv i kroz indeks gospodarske i društvene digitalizacije (DESI), koji prati napredak zemalja Europske unije u pogledu njihove digitalne konkurentnosti (Slika 1).



Slika 1: DESI Hrvatska – razvoj tijekom vremena (URL 2).



Slika 2: Indeks gospodarske i društvene digitalizacije (DESI) (URL 2).

1.1. Indeks gospodarske i društvene digitalizacije (DESI)

Europska komisija od 2014. prati napredak država članica u digitalnom području i objavljuje godišnja izvješća o indeksu gospodarske i društvene digitalizacije (Slika 2). Svake godine izvješća uključuju profile država, pomoću kojih države članice mogu utvrditi područja za prioritetno djelovanje i tematska poglavlja s analizom ključnih područja digitalne politike na razini EU-a (URL 2). Među 27 država članica EU-a, Hrvatska je na 19. mjestu prema indeksu gospodarske i društvene digitalizacije (DESI), odnosno, ispod prosjeka EU. Kada je riječ o digitalnim javnim uslugama, Hrvatska je na 24. mjestu među zemljama EU i tu ujedno bilježimo i najlošiji rezultat. Stoga je u narednom periodu, preporuka EU dodatno promicanje i poboljšanje digitalizacije javne uprave i javnih usluga s fokusom na pojednostavnjenje istih te interoperabilnost državnih usluga i podataka.

1.2. Elektroničke usluge u zemljišnoj administraciji

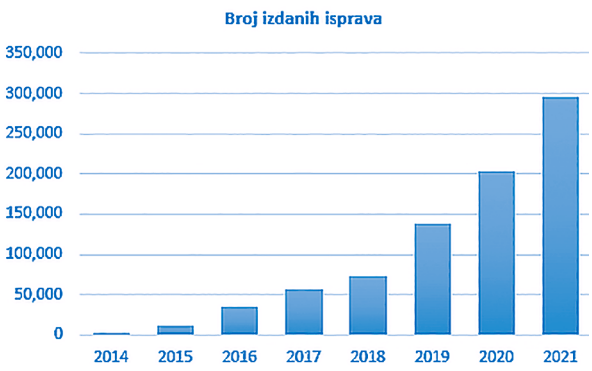
U području digitalizacije zemljišne administracije, uvođenjem Zajedničkog informacijskog sustava za zemljišne knjige i katastar (ZIS) i pripadajućeg javnog portala OSS omogućen je jednostavniji i brži pristup informacijama i stvoren je preduvjet za uvođenje elektroničkih usluga.

Prva usluga koja je omogućena 2015. godine bilo je izdavanje Zemljišnoknjižnog izvatka, Izvatka iz knjige položenih ugovora i BZP izvatka elektroničkim putem. Podatke je tada prvi puta bilo moguće izdati na jednom mjestu za cijelu Republiku Hrvatsku, bez potrebe za odlaskom u nadležni zemljišnoknjižni odjel, a plaćanje sudskih pristojbi omogućeno je putem sustava online naplate (engl. Payment Gateway). To je bila prva javna isprava izdana u RH za koju se pristojba mogla platiti kartičnim putem. Kako bi se pojednostavio i ubrzao pristup svim građanima, OSS je integriran sa sustavom e-Građani te je omogućena prijava putem Nacionalnog identifikacijskog i autentifikacijskog sustava (NIAS), a javne isprave automatski se šalju u Osobni korisnički pretinac (OKP) građanina koji je zatražio javnu ispravu (URL 3). Od tada do kraja 2021. godine na OSS-u su omogućene sljedeće usluge:

- izdavanje prijepisa/izvatka posjedovnog lista,
- izdavanje digitalnog katastarskog plana,
- izdavanje potvrde i rješenja o kućnom broju,
- izdavanje identifikacije čestice i
- izdavanje suglasnosti za obavljanje stručnih geodetskih poslova.

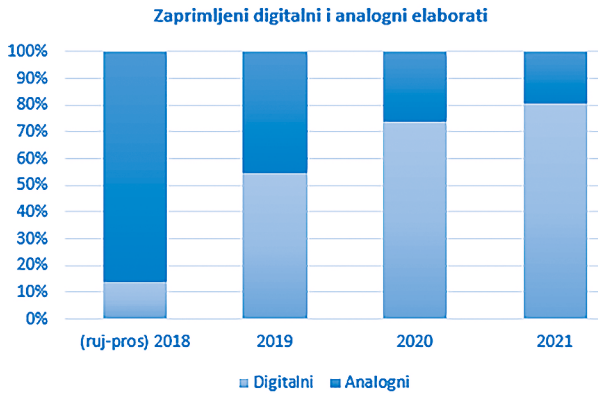
Dio usluga dostupan je samo ključnim korisnicima (geodetski izvoditelji, javni bilježnici, odvjetnici):

- izvoz podataka za potrebe izrade geodetskih elaborata,
- servisno predavanje zahtjeva za pregled i potvrđivanje elaborata i provedbu elaborata,
- servisna rezervacija čestica,
- izdavanje potvrde o suglasnosti za obavljanje stručnih geodetskih poslova,
- prijedlog za upis u zemljišnu knjigu.



Slika 3: Broj izdanih javnih isprava putem OSS-a.

Implementirane elektroničke usluge značajno su ubrzale postupke, smanjile potrebu za fizičkom odlaskom u urede i povećale transparentnost te su vrlo dobro prihvaćene od strane građana i ključnih korisnika. U prilog tome govori više od 975 milijuna upita u OSS sustav od njegova početka i kontinuirano povećanje broja izdanih isprava tijekom godina (Slika 3).



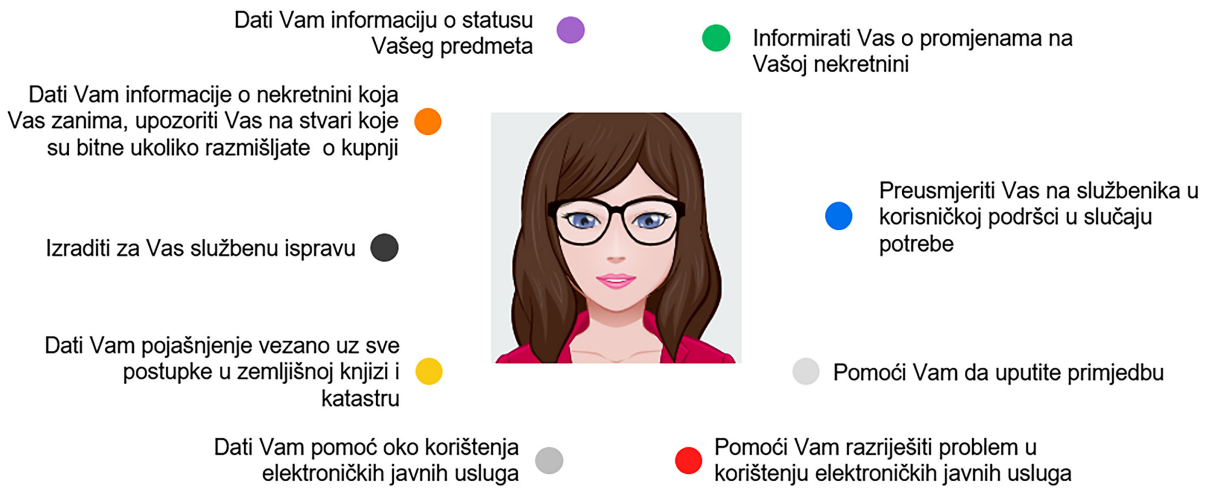
Slika 4: Odnos broja zaprimljenih digitalnih i analognih geodetskih elaborata nakon implementacije DGE.

Produkcijski rad Digitalnog geodetskog elaborata (DGE) započeo je u rujnu 2018. godine. O važnosti uvođenja DGE najbolje govori brzina s kojom su ga geodetski izvoditelji prihvatili i počeli koristiti. Već 2019. godine broj digitalno predanih geodetskih elaborata premašio je broj analognih, a kontinuirani rast nastavljen je i narednih godina (Slika 4). Uvođenje DGE značajno je ubrzalo i olakšalo postupak pregleda i potvrđivanja elaborata.

Sve ovo pokazuje da je interes za korištenje elektroničkih usluga u zemljišnoj administraciji velik pa je sukladno smjernicama Europske komisije potrebno poraditi na promociji i pristupačnosti navedenih usluga kroz dodatne komunikacijske kanale. Također, veliki prostor za poboljšanje postoji u dijelu da se postigne razina 5 elektroničkih usluga odnosno da usluge postanu proaktivne za što je upravo virtualni asistent (chatbot) odličan alat.

2. Daljnji razvoj elektroničkih usluga kroz implementaciju virtualnih asistenata

Chatbot je računalni program (bot) koji automatizira određene zadatke, obično razgovorom s korisnikom putem konverzacijskog sučelja. Očekuje se da će globalno tržište chatbotova dostići 10,5 milijardi dolara do 2026. godine (URL 4). Chatbotovi još uvijek nemaju veliku primjenu u javnoj upravi, međutim, i to se mijenja pa je tako vlada Singapura (URL 5) pokrenula chatbot koji građanima pomaže da lako pronađu informacije o vladinim agencijama, vijestima, priopćenjima za javnost, radnoj snazi i politikama. Isto tako, građani mogu podnijeti i pratiti status pritužbi u vezi s propustima u bilo kojoj od javnih usluga. Prvi chatbot implementiran u javnu upravu Republike Hrvatske je bio Andrija koji je pomagao u borbi protiv korona virusa i bio dostupan kroz Whatsapp komunikacijski kanal (URL 6). Najveća primjena chatbota u javnoj upravi je upravo u dijelu rješavanja ponavljajućih i često rutinskih zadataka i upita, a upravo takvi procesi stvaraju nezadovoljstvo u poslovnoj okolini. Kada su usmjereni na izazovnije zadatke, djelatnicima raste motivacija te produktivnost. Zadovoljan radnik radit će bolje, a zadovoljan korisnik ponovno će se vraćati i htjeti još. Također, velika prednost chatbota je brz pristup informacijama. Naime, često se dogodi da korisnik dođe na web stranicu i izgubi se u količini dostupnih informacija te naposljetku odustane. S druge strane, o chatbotu možemo razmišljati kao o personaliziranoj tražilici preko koje, kroz automatizirane tijekove komunikacije, korisnik dobiva jednostavna rješenja za njegove probleme, željene preporuke i točne odgovore na postavljena pitanja. Na Slici 5 pri-



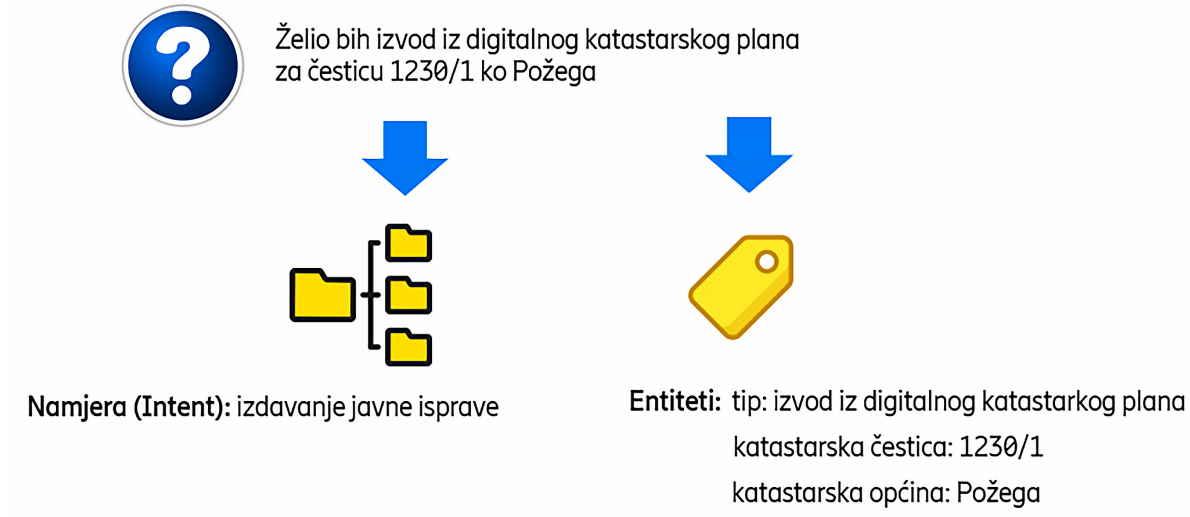
Slika 5: Moguća primjena chatbota u području zemljišne administracije.

kazana su moguća područja primjene chatbotova u zemljišnoj administraciji, a ona se odnose na:

1. Davanje informacije o statusu predmeta
2. Proaktivno obavještavanje o promjenama na nekretnini
3. Izradu službenih isprava, predaju zahtjeva i slično
4. Davanje pojašnjenja vezani uz različite postupke (gdje, kada, kako i što je pritom potrebno?)
5. Pomoć pri upućivanja primjedbe odnosno ostvarivanja određenih prava
6. Pomoć prilikom općenitog korištenja elektroničkih usluga.

2.1. Povijest razvoja virtualnih asistenata

Alan Turing 1950. godine zapitao se može li računalni program razgovarati s grupom ljudi, a da ne shvati da je njihov sugovornik "robot". Ovo pitanje, nazvano Turingov test, mnogi smatraju izvornom idejom chatbota. Prvi chatbot s imenom ELIZA razvijen je 1966. godine. ELIZA je koristila podudaranje uzoraka i metodu supstitucije za simulaciju razgovora, te je simulirala rad psihoterapeuta vraćajući korisnikove rečenice u upitnom obliku. PARRY koji je imitirao pacijenta sa shizofrenijom s ciljem simuliranja bolesti pojavio se 1972. godine. PARRY se smatra naprednijim od ELIZE jer je imao "osobnost" i bolju strukturu kontrole. Unatoč navedenom, PARRY se i dalje temeljio na pravilima, što znači da je slijedio krutu (iako zamršenu) formulu ako X (uvjet) onda Y (akcija). Umjetna inteligencija prvi se put koristi u domeni chatbota s izgradnjom Jabberwackyja 1988. godine. Jabberwacky je napisan na CleverScriptu, jeziku temeljenom na proračunskim tablicama koje su olakšale razvoj chatbota, a koristio je kontekstualno podudaranje uzoraka kako bi odgovorio na temelju prethodnih rasprava. Pojam Chatterbot prvi se put spominje 1991. Bio je to TINYMUD (multiplayer real-time virtual world) umjetni igrač, čija je primarna funkcija bila razgovor. Sbaitso (Sound Blaster Artificial Intelligent Text to Speech Operator) chatbot kreiran 1992. godine, dizajniran je za prikaz digitaliziranih glasova koje su zvučne kartice mogle proizvesti. Igrao je ulogu psihologa bez ikakve kompliciranе interakcije. A.L.I.C.E. je nastala 1995. godine, univerzalni chatbot za obradu jezika koji koristi podudaranje uzoraka za obavljanje razgovora. A.L.I.C.E. koristi XML shemu zvanu artificial intelligence markup language (AIML), koja pomaže odrediti pravila razgovora. A.L.I.C.E. simulira razgovor sa stvarnom osobom putem interneta. Alice predstavlja mladu ženu koja korisniku govori o svojoj dobi, hobijima, fascinantnim činjenicama, te odgovara na korisnikov dijalog. Do prave evolucije u tehnologiji chatbot došlo je 2001. godine s razvojem SmarterChild, koji je bio dostupan na Messengerima kao što su America Online (AOL) i Microsoft (MSN). To je ujedno bio prvi put da je chatbot mogao pomoći ljudima u praktičnim svakodnevnim zadacima jer je mogao dohvatiti informacije iz baza podataka o terminima filmova, sportskim rezultatima, cijenama dionica, vijestima i vremenu. Ova sposobnost označila je značajan razvoj kako u strojnoj inteligenciji, tako i u putanjama interakcije čovjeka i računala jer se informacijskim sustavima moglo pristupiti kroz raspravu s chatbotom. Apple je stvorio inteligentnog osobnog asistenta Siri 2010. godine. Siri daje preporuke i odgovara na zahtjeve korisnika koristeći različite internetske usluge, a uz stalnu upotrebu prilagođava se jezičnoj upotrebi, pretraživanjima i željama korisnika. IBM je 2011. godine kreirao chatbot pod nazivom Watson. Watson je mogao razumjeti prirodni ljudski jezik dovoljno dobro da pobijedi dva prijašnja prvaka u natjecanju kviza "Jeopardy", u kojem su sudionici dobili neke informacije u obliku odgovora i trebali pogoditi odgovarajuća pitanja. Google Now, razvijen 2012., u početku se koristio za davanje informacija korisniku uzimajući u obzir doba dana, lokaciju i preferencije. Google Assistant, koji je razvijen 2016. godine, predstavlja sljedeću generaciju Google Nowa. Ima dublju umjetnu inteligenciju s prijateljskim sučeljem za razgovor i pruža informacije korisnicima predviđajući njihove zahtjeve. Amazon je 2014. godine predstavio Alexu koja je ugrađena u uređaje za



Slika 6: Primjer analize zahtjeva korisnika u području zemljišne administracije.

kućnu automatizaciju i zabavu, te na taj način čini internet stvari (IoT) pristupačnije ljudima.

2.2. Kako radi chatbot

Chatbot izvršava dva glavna zadatka – analizu zahtjeva korisnika i vraćanje odgovora korisniku. Pri analizi zahtjeva korisnika, chatbot prepoznaje namjeru korisnika te izdvaja relevantne podatke (namjere i entitete) iz samog zahtjeva (Slika 6).

Prepoznavanje namjere korisnika te izdvajanje relevantnih podataka iz zahtjeva od izuzetne je važnosti za chatbota, jer ako ne možemo točno prepoznati zahtjev korisnika, ne možemo korisniku dati dobar odgovor. Slika 6 prikazuje primjer u kojem chatbot „razumije" da korisnik želi dobiti Izvod iz digitalnog katastarskog plana. Nakon što sazna namjeru korisnika, chatbot mora odabrati najbolji odgovor na temelju zahtjeva. Zahtjev može biti:

- generički i unaprijed definirani tekst,
- tekst dohvaćen iz baze znanja koja sadrži različite odgovore,
- kontekstualizirani podatak na temelju podataka koje je dao korisnik,
- podatak pohranjen u poslovnom sustavu,
- rezultat interakcije chatbota s jednom ili više backend aplikacija,
- pitanje koje pomaže chatbotu da ispravno razumije zahtjev korisnika.

Chatbot analizira zahtjeve korisnika i vraća odgovor na način koristeći tri metode klasifikacije (URL 7):

- Podudaranje uzoraka (engl. pattern matching) – chatbot koristi podudaranje uzoraka kako bi grupirao tekst te stvorio odgovarajući odgovor. Pri tome koristi Artificial Intelligence Markup Language (AIML) kao standardni strukturni model uzoraka. Chatbot reagira na sve podatke koji su povezani s relevantnim uzorcima kako bi dobio najbolji mogući odgovor,
- Razumijevanje prirodnog jezika (engl. natural language understanding – NLU) NLU je sposobnost chatbota da razumije čovjeka. To je proces pretvaranja teksta u strukturirane podatke koje stroj može razumjeti. NLU koristi tri koncepta: entitete, kontekst i očekivanja.
  - Entiteti – predstavljaju ideju chatbotu, primjerice, sustav povrata novca u komercijalnom chatbotu.
  - Kontekst – kad algoritam razumijevanja prirodnog jezika prepozna zahtjev i nema povijest razgovora, neće se moći prisjetiti zahtjeva kako bi dao odgovor.
  - Očekivanja – chatbot mora biti u stanju ispuniti očekivanja korisnika prilikom podnošenja zahtjeva ili slanja upita.
- Obrada prirodnog jezika (engl. natural language processing – NLP) – chatbot pretvara tekst ili govor korisnika u strukturirane podatke. Ti se podaci nadalje koriste za odabir relevantnog odgovora. Obrada prirodnog jezika sastoji se od pet koraka:

1. Tokenizacija – chatbot filtrira skup riječi u obliku tokena
2. Analiza osjećaja – chatbot interpretira korisničke odgovore kako bi se uskladio s njihovim osjećajima
3. Normalizacija – chatbot provjerava tiskarske greške koje mogu promijeniti značenje korisničkog upita
4. Prepoznavanje entiteta – chatbot traži različite kategorije potrebnih podataka
5. Analiza ovisnosti – chatbot traži uobičajene izraze koje korisnici korist.

2.3. Različiti tipovi chatbotova

S obzirom na način implementacije i primijenjenu tehnologiju, razlikujemo nekoliko tipova chatbotova (URL 8):

Tip 1: Chatbotovi bazirani na pravilima („rule-based")

Ovaj tip chatbotova slijedi unaprijed definirane puteve tijekom razgovora. Tijekom svakog koraka razgovora, korisnik mora odabrati neku od opcija koje određuju sljedeći korak u razgovoru. Ovakvi se chatbotovi koriste za jednostavnije scenarije. Interakcije s „rule-based" chatbotovima su visoko strukturirane te se najviše koriste za funkcije korisničke podrške. Idealni su za odgovaranje na uobičajene upite poput upita o radnom vremenu, statusu predmeta ili pojedinostima postupka.

Tip 2: Razgovorni chatbotovi

Razgovorni se chatbotovi često nazivaju virtualni ili digitalni asistenti. Puno su interaktivniji i personaliziraniji od „rule-based" chatbota. Razgovaraju s korisnicima na način na koji ljudi razgovaraju u stvarnim situacijama. Mogu razumjeti kontekst i namjeru složenih razgovora i pokušati dati relevantnije odgovore. Vještina komunikacije chatbota omogućuje tvrtkama da kupcima isporuče ono što traže.

Tip 3: A.I. chatbotovi

A.I. chatbotovi su dizajnirani da samostalno rade i uče korištenjem obrade prirodnog jezika zajedno s umjetnom inteligencijom. Oni postaju pametniji tijekom vremena. Primjenjuju prediktivnu analizu inteligencije i raspoloženja kako bi bolje razumjeli emocije korisnika. Strojnim učenjem uče od ponašanja korisnika te tako pružaju prilagođenije razgovore.

2.4. Etički problemi u primjeni chatbotova

Kada sagledamo specifično područje razvoja chatbotova, postoje četiri osnovna izazova, koja je potrebno sagledati kod razvoja:

1. Transparentnost podataka – sve informacije koje korisnici podijele s botom tijekom svog razgovora potencijalno bi se mogle prikupiti, koristiti ili prodati bez njihovog pristanka. Stoga je nužno osigurati da su korisnici svjesni

svih aspekata koji uključuju chatbot i posljedica interakcije s njim. Jedan od načina da se poveća transparentnost uključuje implementaciju sustava regulacije podataka poput GDPR-a Europske unije (URL 9), koji pojedincima daje veću kontrolu nad njihovim osobnim podacima.

2. Osobnost chatbota – potrebno je osigurati priopćavanje korisniku da doista razgovara s botom. Kako chatboti postaju napredniji i realističniji, nije uvijek vidljivo razgovara li korisnik s botom ili drugim čovjekom. Primjer je Google Duplex (URL 10).

3. Umjetnost komunikacije – chatbot bi mogao biti u opasnosti od ispoljavanja rasizma, seksizma ili upotrebe uvredljivog jezika. Upravo se to dogodilo Microsoftovom Tayu (URL 11), koji je generirao svoje odgovore na temelju načina na koji su korisnici s njim komunicirali. Kada su razni korisnici počeli objavljivati uvredljive poruke prema botu, Tay je uzvratio oponašajući taj isti jezik u svojim odgovorima.

4. Pokazivanje osjećaja – neki korisnici posežu za chatbotovima kao izvorom društva i utjehe kada se osjećaju usamljeno ili depresivno. U tim situacijama korisnici mogu postati emocionalno vezani, a chatbot bi trebao biti posebno pažljiv prema njihovim osjećajima. Ovdje se postavlja pitanje može li i kako chatbot pokazati suosjećanje i empatiju prema korisniku, a da istovremeno i sam ne razvije osjećaje. O ovom području će se još jako puno razgovarati u budućnosti, a o kompleksnosti problema dovoljno govori nedavni primjer Goggle LaMDE (URL 12), gdje je Googleov inženjer suspendiran nakon što je ustvrdio da je računalni chatbot na kojem je radio postao razuman te da je počeo razmišljati i rasuđivati poput ljudskog bića.

2.5. Pravna regulacija primjene umjetne inteligencije

Dok Amerika i Kina predvode u razvoju novih tehnologija, EU je od 2014. donijela niz mjera za reguliranje razvoja gospodarstva vođenog razvojem umjetne inteligencije. Komisija je 2018. predstavila strategiju za umjetnu inteligenciju i s državama članicama dogovorila koordinirani plan. U travnju 2019. Stručna skupina na visokoj razini za umjetnu inteligenciju predstavila je Etičke smjernice za pouzdanu umjetnu inteligenciju. Na temelju toga izrađen je okvir za umjetnu inteligenciju, predstavljen 19. veljače 2020. Europska komisija je 21. travnja 2021. predložila, u okviru svoje digitalne strategije, novu uredbu o umjetnoj inteligenciji s ciljem da EU postane svjetski predvodnik u pouzdanoj umjetnoj inteligenciji. Uredba definira koji sustavi se smatraju visokorizičnim za primjenu tehnologije umjetne inteligencije pa se tako neprihvatljivim rizikom smatraju sustavi koji mogu predstavljati jasnu prijetnju za sigurnost, život i temeljna ljudska prava. Između ostalog, sustavi u pravosuđu i demokratskim procesima (npr. primjena zakona na konkretan skup činjenica) smatraju se visokorizičnim što znači da će proći još puno vremena prije nego što chatbotovi zamijene referente u postupku odlučivanja i donošenja rješenja unatoč ubrzanom razvoju tehnologije.

3. Zaključak

U 56 godina dugoj povijesti virtualnih asistenata tehnologija je napredovala do razine da se danas pitamo imaju li neki asistenti svjesnost? S obzirom da smo prevalili daleki put, jasno je da virtualni asistenti nisu budućnost nego sadašnjost. Uz mudro upravljanje i uzimanjem u obzir etičkih problema kao što su transparentnost podataka, osobnost, osjećaji i umjetnost komunikacije, jasno je da će virtualni asistenti biti sve pametniji i korisniji čovječanstvu. Geodetska struka do sada je bila jedna od struka koja je najbrže prihvaćala tehnološke inovacije, mudro koristila tehnologiju u svrhu boljitka svih građana i ubrzanja poslovnih procesa. Na putu daljnjeg tehnološkog napretka, umjetna inteligencija i virtualni asistenti sigurno su jedno od područja od kojeg se može puno očekivati. Najveću vrijednost od virtualnih asistenata dobit će građani, kroz funkcionalnosti kao što su pomoć u korištenju aplikacija, izdavanje službenih isprava, pregleda podataka o katastarskim česticama, posjedovnim listovima, zemljišnoknjižni uloškima i slično.

Literatura

Lindgren, I., Jansson, G. (2013): Electronic services in the public sector: A conceptual framework, Government Information Quarterly, 30, 2, 163–172.

URL 1: Standard razvoja javnih e-usluga u RH Smjernice, https://rdd.gov.hr/UserDocsImages/e-Standardi/Standard%20razvoja%20javnih%20e_usluga%20u%20RH_Smjernice.pdf, (26.6.2022.).

URL 2: Indeks DESI, https://ec.europa.eu/newsroom/dae/redirection/document/80579, (25.6.2022.).

URL 3: Strategija eHrvatska 2020, https://rdd.gov.hr/UserDocsImages/dokumenti/Strategija_e-Hrvatska_2020.pdf, (25.6.2022.).

URL 4: Chatbot market, https://www.marketsandmarkets.com/Market-Reports/smart-advisor-market-72302363.html, (25.6.2022.).

URL 5: Chatbot vlade Singapura, https://www.facebook.com/gov.sg/, (26.6.2022.).

URL 6: Andrija chatbot, https://vlada.gov.hr/vijesti/predstavljen-andrija-prvi-digitalni-asistent-u-borbi-protiv-koronavirusa/29226, (26.6.2022.).

URL 7: What is Chatbot? Why are Chatbots Important?, https://www.revechat.com/blog/what-is-a-chatbot/, (26.6.2022.).

URL 8: How Does A Chatbot Work?,

https://www.drift.com/learn/chatbot/how-does-a-chatbot-work/, (26.6.2022.).

URL 9: GDPR Uredba, https://eur-lex.europa.eu/legal-content/HR/TXT/HTML/?uri=LEGISSUM:310401_2, (26.6.2022.).

URL 10: Google Duplex, https://ai.googleblog.com/2018/05/duplex-ai-system-for-natural-conversation.html, (26.6.2022.).

URL 11: Microsoft Tay chatbot,

https://en.wikipedia.org/wiki/Tay_%28bot%29, (26.6.2022.).

URL 12: Google LaMDA, https://cajundiscordian.medium.com/is-lamda-sentient-an-interview-ea64d916d917, (26.6.2022.).

Virtual Assistant in Land Administration, Myth or Unavoidable Future?

Abstract

The Government of the Republic of Croatia recognized that for the further progress of Croatian society and economy, it is necessary to build digital capacities through the development of digital services and digital transformation. Cadastre and land registry services are used daily by a large number of citizens and business entities, and for the last 10 years intensive work has been done to offer as many services as possible in electronic form, i.e., as e-services. According to the European Commission, every e-service can be of level 1 to 5, where level 5 implies that the provision of the service is proactive in such a way that only consent is requested from the user. Most of the e-services implemented in the Republic of Croatia use a website as a digital channel and are level 4. Virtual assistants enable the service to be simultaneously available through different digital channels and proactive, and to be adapted to the individual user. The corona virus pandemic has led to a significant increase in the use of virtual assistants for business communication and automation. The global virtual assistant market is expected to reach $10.5 billion by 2026. The first types of virtual assistants were rule-based and simple, and with the development of technology, virtual assistants are available today that use natural language processing methods and machine learning and as such achieve enviable results in all branches of industry. In the future, virtual assistants will become even more mature and able to anticipate the needs of users. As a result, they will increase their efficiency and work in an even more personalized way. As part of the work, the possibility of using a conversational virtual assistant in the land register and cadastre will be presented, and the necessary adjustments to the legal framework will be considered to support this.

Keywords: *cadastre, conversational design, land registry, natural language processing, virtual assistant*

Prostorno-vremensko grupiranje tokova kretanja – detekcija promjene korištenja sustava javnih bicikala zbog COVID-19 zatvaranja u Londonu

Sebastijan Sekulić[1,2], Jed Long[3], Urška Demšar[2]

[1] Geoprostor d.o.o., Kurilovac 10, Ozalj, Hrvatska, sebastijan@geoprostor.hr

[2] School of Geography and Sustainable Development, University of St Andrews, St Andrews, Scotland, UK, urska.demsar@st-andrews.ac.uk

[3] Department of Geography & Environment, Western University, London, Ontario, Canada, jed.long@uwo.ca

Sažetak

Tokovi kretanja podaci su koji se mogu koristiti za istraživanje prostornih interakcija te odnosa među lokacijama. Napredci u prikupljanju podataka omogućuju da se informacije o kretanju prikupljaju lakše, brže i detaljnije nego ikad prije. Ta dodatna količina podataka i informacija omogućuje nam da kreiramo i koristimo nove metode za analizu kretanja. Jedna od glavnih prednosti detaljnijeg prikupljanja podataka, uz prostorne informacije, je prikupljanje podataka o vremenu u kojem se kretnja odvija. U ovom radu, koristeći novu metodu za grupiranje tokova koja koristi 4D podatke (prostor i vrijeme) analiziramo promjenu ponašanja i kretanja korisnika sustava javnih bicikala u Londonu za vrijeme zatvaranja (lockdown). Metoda grupiranja tokova zasniva se na izračunu prostorno vremenske sličnosti tokova te omogućuje pojednostavljivanje velikog skupa podataka i prikaz promjena na karti. Kao primjer mreže korišten je sustav javnih bicikala Santander London, koji se sastoji od 700 stanica rasprostranjenih Londonom te sustav bilježi preko 800 tisuća tokova kretanja mjesečno. Kako bi pokazali postojanje promjena, odrađena je detekcija grupa sličnih kretanja u travnju 2019. godine te u travnju 2020. godine. Za svaku grupu su potom izračunati karakteristični parametri pomoću kojih je bilo moguće odrediti veličinu grupe, ukupan broj kretanja unutar grupe te njenu površinu. Usporedbom rezultata pokazali smo kako je zatvaranje u Londonu značajno utjecao na promjenu ponašanja biciklista. Promijenjene su lokacije na kojima se bicikli najviše koriste, detektirane su promjene u vremenu u kojem se bicikli koriste te razlozi korištenja. Također, pokazali smo kako se dobivene promjene podudaraju s očekivanjima zbog smjernica i ograničenjima kretanja tokom zatvaranja.

Ključne riječi: *prostorno-vremenska analiza, sustav javnih bicikala, tokovi kretanja, zatvaranje*

1. Uvod

Tok je jedan od načina na koji se može prikazat kretnja u geoinformatičkim sustavima u slučajevima kad je poznato ishodište i odredište kretanja. Ishodište i odredište se još mogu zvati i čvorovi. Često se, uz sam tok, zapisuje i informacija o težini (važnosti) toka. Ta važnost može predstavljati broj putnika ili broj poslanih paketa. Više tokova koji predstavljaju isti fenomen na istom području (ili tematsku cjelinu) čine mrežu tokova.

Podaci iz kojih se kreiraju mreže tokova, mogu biti iz različitih domena i izvora, te mogu biti povezani uz kriminal, društvene mreže, klimatske promjene, širenje virusa ili prijevozne sustave (Newman, 2004; Javed i dr., 2018). Često mreže sadrže informaciju gdje i kad se događaji (kretnje) odvijaju te takve mreže se mogu i trebaju drugačije tretirati (Atluri i dr., 2018) i treba se pokušati iskoristiti te dodatne podatke.

Mreže koje sadrže informaciju o vremenu i prostoru, nazivaju se prostorno-vremenske mreže tokova te u posljednje vrijeme znanstvenici istražuju na koji način se ta dodatna prostorna i vremenska komponenta mogu iskoristiti kako bi se bolje opisali i istražili procesi koji dovode do formiranja takvih mreža (Dubin, 1998). Chen i dr. (2014) modeliraju metropolitanski sustav željeznica koristeći prostorno-vremensku mrežu tokova s ciljem istraživanja pristupačnosti željeznice, Cheng i dr. (2019) izrađuju prostorno-vremensku mrežu koristeći sustav prometnica kako bi predvidio promet te prometne gužve, dok Yang i dr. (2019) grupiraju kretanja u mreži nastaloj koristeći podatke sustava za javno korištenje bicikala. Nedostatak kod njihovih analiza je to što vrijeme koriste kao diskretni parametar prekide, tj. koriste takozvane vremenske prozore, a ne kao kontinuirani parametar (Chen i dr, 2014). Korištenjem diskretnih prekida ili vremenskih prozora, ograničeni smo predefinirani parametrom te se gubi informaciju o događajima koji se odvijaju preko dva vremenska prozora ili preko više njih. Gadd i dr. (2022) u nedavnoj studiji, potvrđuju utjecaj pre-

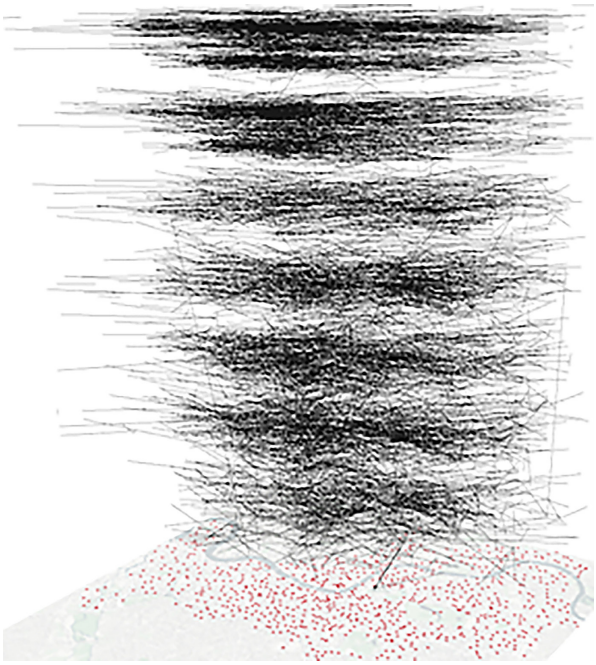
kida i važnost preciznog i pažljivog izbora vremenskih prozora.

Jedna od čestih metoda za analizu mreža tokova je detekcija zajednica (community detection, CD). CD metode grupiraju tokove na način da grupe (zajednice) unutar mreže imaju više veza unutar grupe, nego što imaju veza s čvorištima izvan grupe (Newman, 2004).

CD se može koristiti na više načina, metoda je korištena za detekciju grupa unutar mreže nogometnih klubova (Newman, 2004; Wu i dr., 2012), pronalazak skupina povezanih tema na internetu (Blondel i dr., 2008) ili identifikaciju najistaknutijih pojedinaca unutar društvene mreže (Ahajjam i dr, 2018). Izvorno, CD metode potječu iz područja fizike (Newman, 2004) te su popularnost stekle zbog analiza unutar društvenih znanosti. Ono što je često bilo ignorirano je prostorna, a kasnije i vremenska komponenta sadržana unutar mreža (O'Sullivan i Manson, 2015). U kontekstu prostornih mreža tokova, prostorna komponenta je često ignorirana u samoj analizi (Pavlopoulos i dr., 2011) ili namjerno uklonjena (Expert i dr., 2011). Uključivanje prostorne komponente u analizu mreža kretanja izuzetno je važno, prostorna udaljenost snažno je povezna s vremenom kretanja, te snažno utječe na procese koji definiraju razloge kretanja i samu strukturu mreže (Cerina i dr., 2012).

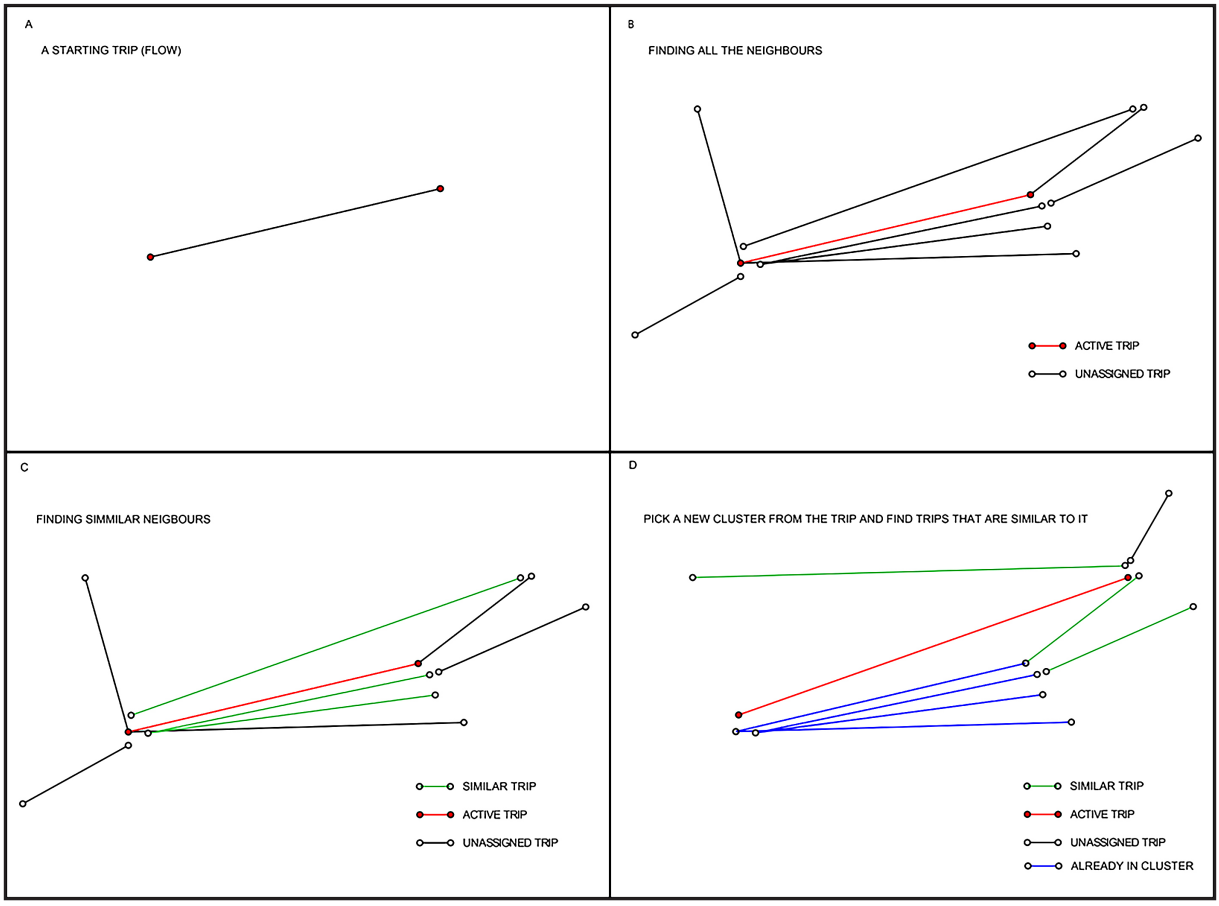
U ovom članku predstavljena je metoda za grupiranje tokova unutar prostorno-vremenskih mreža koja koristi udaljenost i vrijeme kao kontinuirane varijable. Cilj metode je da u grupiranju tokova iskoristimo i vremensku komponentu kako bi obuhvatili i detektirali procese koji se odvijaju na istom području, ali u različitim vremenskim periodima, a ne da grupiramo tokove samo prema njihovim prostornim karakteristikama. Metodu je prikazana na primjeru detekcije promjena unutar korištenja sustava javnih bicikala u dva različita perioda. Sustavi javnih bicikala jedan su od najbrže rastućih načina prijevoza Todd i dr., 2021). Od 2013 do 2019, broj takovih sustava u svijetu porastao je s 13 na više od 2000 (URL 1). Sustavi javnih bicikala generiraju dvije vrste podataka: informaciju o broju bicikala na stanici te podatke o odredištu i ishodištu (origin-destination, OD). OD podaci uz odredište i ishodište, sadrže i informaciju o vremenu preuzimanja i vraćanja bicikla. Oni su naš primarni interes, jer pomoću njih možemo kreirati prostorno-vremensku mrežu kretanja.

Za demonstraciju metode odabrana su dva perioda između kojih znamo da postoji razlika, te su te razlike opisane kroz različite analize i znanstvena područja. Specifično, zanima nas promjena kretanja u Londonu zbog uvođenja prvog zatvaranja 2020. godine. U ožujku 2020. WHO (World Health Organisation, Svjetska zdravstvena organizacija) je proglasio pandemiju te započinje uvođenje zatvaranja u mnoge države (Lau i dr. 2020). Collivignarelli i dr. (2021) istražuju promjenu kretanja kroz praćenje stakleničkih plinova i zagađivača. U svom istraživanju prikazuju 80%-tni pad u kretanjima prema kinima, muzejima i restoranima, 70%-tni pad pri odlasku na posao te 76%-tni pad u korištenju javnog prijevoza. Također, uspoređuju vremenske prilike u travnju 2019. godine te travnju 2020. godine. U tim mjesecima, prosječna temperatura, vjetar i padaline su bile slične. Zaključuju da je jedini efekt zbog kojeg bi se vidjela takva značajna promjena u kretanjima zatvaranje, što je i razlog našeg odabira tog perioda. Razlog odabira sustava javnih bicikala za istraživanje je dostupnost podataka (besplatno preuzimanje), postojanje podataka u oba vremenska perioda, te kako je bicikliranje bio jedan od rijetkih razloga zbog koje su ljudi smjeli napuštati domove (Baker i dr., 2021). Iz svega postavljamo sljedeću hipotezu; očekuje se značajno manje kretanja biciklista u travnju 2020. godine nego u travnju 2019, očekujemo puno manje kretanja na posao i s posla, te povećanje kretanja za vježbu/slobodno vrijeme. Očekuje se povećanje kretanja oko zelenih područja i parkova, i smanjenje kretanja u centru grada. Također, ne očekuje se jutarnje i popodnevne maksimume (commuting, put na/s posla), nego se očekuje spori porast kretanja prema popodnevu te lagano opadanje kako vrijeme ide bliže noći.



Slika 1: Prikaz prostorno-vremenske mreže tokova Santander Cycles London (space-time cube). Prikaz sadrži tjedan dana tokova, Z os predstavlja vrijeme, a točke su lokacije stanica u sustavu (vlastiti podaci)

Ostatak članka strukturiran je na sljedeći način. U idućem poglavlju objašnjeno je više o metodi za grupiranje prostorno-vremenskih mreža tokova i načinu na koji se uključuje vrijeme kao kontinuirani parametar u analizu. Potom piše se više o podacima, daje se detalje o strukturi i količini podataka te obrade koje su potrebne prije primjene algoritma za grupiranje. U trećem poglavlju prikazani su rezultati prostorno vremenskog grupiranja. U posljednjem poglavlju diskutira se o rezultatima, uspoređuju se s hipotezom i dolazi se do konačnih zaključaka o radu algoritma te promjenama kretanja u Londonu zbog zatvaranja.



Slika 2: Grafički prikaz algoritma za grupiranje tokova prema sličnosti (vlastiti podaci)

2. Metoda za prostorno-vremensko grupiranje tokova

Za grupiranje prostorno-vremenskih tokova, izrađen je algoritam koji koristi vremensku i prostornu komponentu toka, te grupira tokove koji imaju slične prostorne i vremenske značajke. U ovoj metodi, računa se prostornu sličnost koristeći udaljenosti između dva odredišta i dva ishodišta, te prostornu duljinu toka. Vremenska sličnost računa se uspoređujući vremena početka kretnje i vremena dolaska.

Prvi korak u algoritmu je sortiranje podataka prema vremenu početka, razlog sortiranja je izbjegavanje slučajnosti u biranju tokova u idućem koraku, te mogućnost ponavljanja rezultata ukoliko se postupak ponavlja više puta. Proces grupiranja započinje biranjem prvog toka u listi. Taj tok potom nazivamo „glavni tok" – koji predstavlja prvu grupu. Potom se pronalaze svi tokovi koji su prostorno blizu glavnom toku, tj. sve tokove čija odredišta i ishodišta su u blizini odredišta i ishodišta glavnog toka. Taj set je nazvan „set za testiranje – testni set". U testnom setu traži se kandidate za priključivanje u našu grupu. Za svaki tok u testnom setu računa se prostorna i vremenska sličnost s našim glavnim tokom. Ukoliko sličnost prelazi graničnu vrijednost, taj tok se pridodaje u grupu. Ukoliko je tok dodan u grupu, on se uklanja iz popisa kandidata i popisa tokova koji mogu postati kandidati, tj. taj tok je „potrošen". Granična vrijednost sličnosti je u ovom slučaju broj između 1 i 0 koji sami postavljamo, gdje 1 znači da su dva toka identična, a 0 da su potpuno različiti. Odabir granične vrijednosti određuje veličinu grupa i njihovu homogenost, te za njegovu definiciju treba imati znanje o procesima i samom skupu podataka. Nakon što se svi slični tokovi iz testnog seta dodaju u grupu, iz grupe se bira idući tok. Za njega se potom kreira novi testni set i postupak se ponavlja. Postupak dodavanja tokova i kreiranja novog testnog seta se ponavlja dok god se u testnom setu ne pronađe niti jedan sličan tok i nema više novih tokova koji se mogu dodati u našu grupu. Potom se bira novi tok iz originalne liste tokova, kreira se nova grupa te se postupak ponavlja dok ne iskoristi sve tokove. Ilustracija grupiranja prikazana je na Slici 2.

2.1 Podaci

Prostorno-vremenska mreža tokova izrađena je koristeći podatke iz sustava javnih bicikala u Londonu (Santander Cycles) te je isječak iz mreže prikazan na Slici 1. Glavna prednost tog skupa podataka je to da je svaki individualni put zabilježen s lokacijom početka, vremenom početka, lokacijom kraja i vremenom dolaska. Daljnja prednost je veliko korištenje sustava, njegova dobra prostorna pokrivenost i veličina. U Londonu su nalazi preko 700 stanica s biciklima.

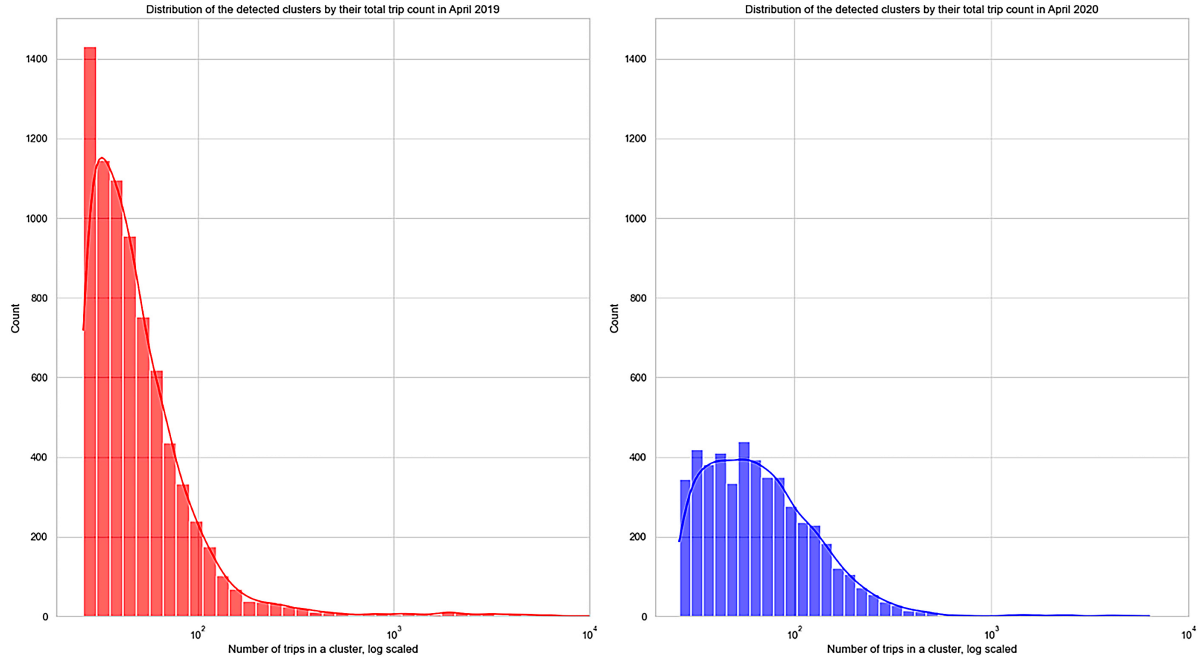
Skup podataka iz travnja 2019. godine sadrži 824,630 pojedinačnih zapisa koji predstavljaju jednog putni-

ka na jednom biciklu. Period promatranja 3.4.2019 i 30.4.2019.

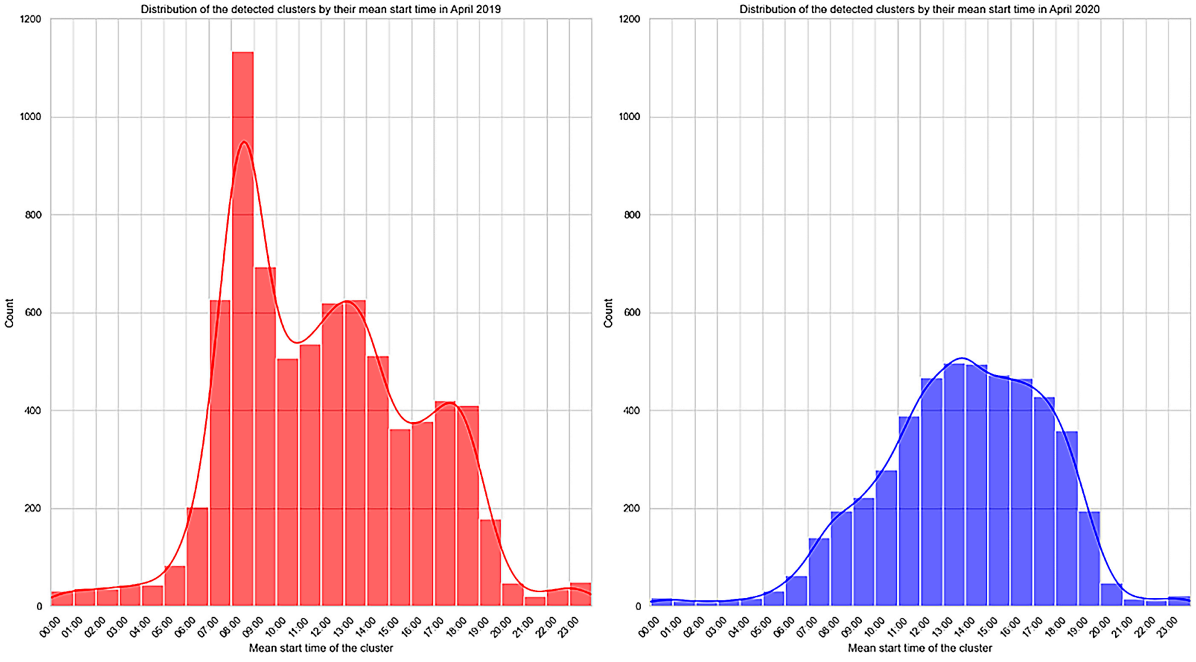
Skup podataka iz travnja 2020. sadrži 562,501 zapis u periodu od 1.4.2020 do 28.4.2020. Zbog načina prikupljanja i pohrane podataka, najdulji put je 24 sata.

3. Rezultati

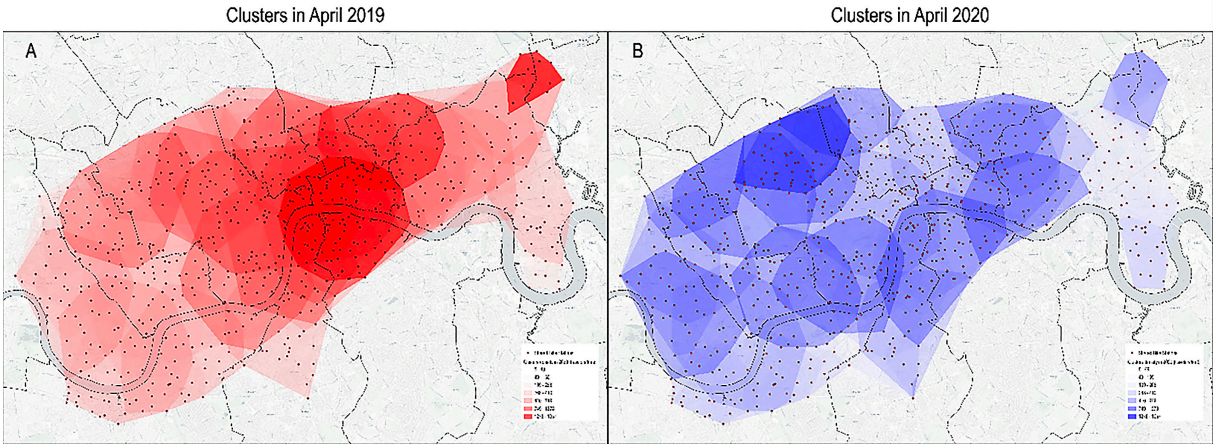
Za travanj 2019. od 824,630 zapisa uspješno je grupirano 694,606 tokova u 7,652 grupe. Uspješnost klasifikacije je 84,23%. U 2020. godini uspješno je grupirano 511,092 tokova u 4,874 grupe uz uspješnost klasifikacije od 90,86%.



Slika 3: Prikaz distribucije detektiranih grupa s obzirom na ukupan broj tokova. Velika većina tokova je u prvoj kvartili, što znači da većina grupa ima manji broj tokova. U lijevo je prikazana distribucija za 2019. godina, a desno distribucija za 2020. godinu. (vlastiti podaci)



Slika 4: Prikaz distribucije detektiranih grupa s obzirom na prosječno vrijeme kretanja unutar grupe. U 2019. godini (lijevo) može se primijetiti vremena pojačanog korištenja, dok u 2020. godini (desno) imamo kontinuirani i ujednačeni rast prema kasnom popodnevu te sporije opadanje korištenja. (vlastiti podaci)



Slika 5: Prostorna distribucija detektiranih grupa te prikaz gustoća tokova s obzirom na površinu grupe. (vlastiti podaci)

Vidljiva je razlika u distribuciji i ukupnom broju grupa između dvije uspoređivane godine. U 2019. godini je bilo više manjih grupa nego u 2020. godini (Slika 3). Koristeći K-S (Kolmogorov–Smirnov) test, pokazano je kako su distribucije statistički signifikantno drugačije ($p<0.0005$)

Idući rezultat je distribucija grupa kroz vrijeme gdje se uspoređuje prosječno početno vrijeme tokova unutar grupe. Na Slici 4, prikazano je kako u 2020. godini ima manje biciklista ujutro nego u 2019. godini, te nedostaju pojačana korištenja koja odgovaraju putu na posao i s posla (8, 13 i 18 sati). Također pomoću K-S testa, potvrđuje se kako su distribucije statistički signifikantno drugačije ($p<0.0005$).

Uspoređujući površine grupa, zaključuje se kako su grupe ostale sličnih površina, ali u 2020. godini postoji manji broj tokova unutar pojedine grupe.

Najzanimljiviji prikaz je prikaz grupa na karti (Slika 5), gdje vidimo kako su u 2019. godini grupe gušće smještene u centru grada, dok u 2020. centar grada nema toliku pozornost i korištenje je većinom prebačeno na parkove i vanjske dijelove grada.

4. Diskusija i zaključak

U ovom članku prikazana je nova metoda za prostorno-vremensko grupiranje tokova koristeći prostorno-vremenske mreže. Cilj je bio demonstrirati metodu i pokazati rezultate korištenja vremena kao kontinuiranog parametra i kako koristiti metodu za bolje detektiranje grupa unutar mreža tokova. Metoda nam omogućuje pojednostavljivanje velike količine podataka radi lakše analize i prikaza. Algoritam smo je demonstriran na detekciji promjena korištenja jedne mreže javnih bicikala zbog restrikcija kretanja (zatvaranja). Uspoređujući rezultate prije i poslije zatvaranja, promjena korištenja je očita. Pokazano je kako su postavljene hipoteze bile valjane. Algoritam je uspio detektirati različite načine korištenja na istom prostoru u različitim vremenskim okvirima na primjeru detekcije puta na posao u 2019. godini, te nedostatka takve vrste kretanja u 2020. godini (rad od kuće). Također je uspješno pokazano kako je uistinu bilo manje kretanja u 2020. godini, s tim da se korištenje javnih bicikala nije smanjilo u istoj mjeri. Korištenje prostora prebacilo se iz centra grada na rubove i zelena područja. Prikazana analiza pokazuje na koji način se mogu iskoristiti prostorno-vremenski podatci i nove metode da bi bolje razumjeli i opisali procese koji utječu na kretanje ljudi.

Literatura

Ahajjam, Sara, Mohamed El Haddad, and Hassan Badir (2018): A New Scalable Leader-Community Detection Approach for Community Detection in Social Networks, Social Networks

Atluri, Gowtham, Anuj Karpatne, and Vipin Kumar (2018): Spatio-Temporal Data Mining: A Survey of Problems and Methods, ACM Computing Surveys (CSUR) 51(4):1–41.

Baker, Carl, Esme Kirk-Wade, Jennifer Brown, and Sarah Barber (2021): Coronavirus: A History of English Lockdown Laws.

Blondel, Vincent D., Jean-Loup Guillaume, Renaud Lambiotte, and Etienne Lefebvre (2008): Fast Unfolding of Communities in Large Networks, Journal of Statistical Mechanics: Theory and Experiment

Cerina, Federica, Vincenzo De Leo, Marc Barthelemy, and Alessandro Chessa (2012): Spatial Correlations in Attribute Communities, PLoS ONE 7(5):e37507.

Chen, Shaopei, Christophe Claramunt, and Cyril Ray (2014): A Spatio-Temporal Modelling Approach for the Study of the Connectivity and Accessibility of the Guangzhou Metropolitan Network, Journal of Transport Geography 36:12–23.

Cheng, Jiujun, Xiao Wu, Mengchu Zhou, Shangce Gao, Zhenhua Huang, and Cong Liu (2019): A Novel Method for Detecting New Overlapping Community in Complex Evolving Networks, IEEE Transactions on Systems, Man, and Cybernetics: Systems 49(9):1832–44.

Collivignarelli, Maria Cristina, Claudio De Rose, Alessandro Abbà, Marco Baldi, Giorgio Bertanza, Roberta Pedrazzani, Sabrina Sorlini, and Marco Carnevale Miino (2021): Analysis of Lockdown for CoViD-19 Impact on NO2 in London, Milan and Paris: What Lesson Can Be Learnt?, Process Safety and Environmental Protection 146:952–60.

Dubin, Robin A. (1998): Spatial Autocorrelation: A Primer, Journal of Housing Economics 7(4):304–27.

Expert, P., T. S. Evans, V. D. Blondel, and R. Lambiotte (2011): Uncovering Space-Independent Communities in Spatial Networks, Proceedings of the National Academy of Sciences 108(19):7663–68.

Gadd, Sarah C., Alexis Comber, Peter Tennant, Mark S. Gilthorpe, and Alison J. Heppenstall (2022): 'The Utility of Multilevel Models for Continuous-Time Feature Selection of Spatio-Temporal Networks', Computers, Environment and Urban Systems 91:101728.

Javed, Muhammad Aqib, Muhammad Shahzad Younis, Siddique Latif, Junaid Qadir, and Adeel Baig (2018): Community Detection in Networks: A Multidisciplinary Review. Journal of Network and Computer Applications 108:87–111.

Lau, Hien, Veria Khosrawipour, Piotr Kocbach, Agata Mikolajczyk, Justyna Schubert, Jacek Bania, and Tanja Khosrawipour (2020): The Positive Impact of Lockdown in Wuhan on Containing the COVID-19 Outbreak in China, Journal of Travel Medicine.

Newman, M. E. J. (2004): Detecting Community Structure in Networks, The European Physical Journal B - Condensed Matter 38(2):321–30.

O'Sullivan, David, and Steven M. Manson (2015): Do Physicists Have Geography Envy? And What Can Geographers Learn from It?, Annals of the Association of American Geographers 105(4):704–22.

Pavlopoulos, Georgios A., Maria Secrier, Charalampos N. Moschopoulos, Theodoros G. Soldatos, Sophia Kossida, Jan Aerts, Reinhard Schneider, and Pantelis G. Bagos (2011): Using Graph Theory to Analyze Biological Networks, BioData Mining 4(1):10.

Todd, James, Oliver O'Brien, and James Cheshire (2021): A Global Comparison of Bicycle Sharing Systems, Journal of Transport Geography 94:103119.

Wu, Ying-Jun, Han Huang, Zhi-Feng Hao, and Feng Chen (2012): 'Local Community Detection Using Link Similarity'. Journal of Computer Science and Technology 27(6):1261–68.

Yang, Yuanxuan, Alison Heppenstall, Andy Turner, and Alexis Comber (2019): A Spatiotemporal and Graph-Based Analysis of Dockless Bike Sharing Patterns to Understand Urban Flows over the Last Mile', Computers, Environment and Urban Systems 77:101361.

URL 1: Meddin (2021): The Meddin Bike-Sharing World Map'. Retrieved (5.01. 20) https://bikesharingworldmap.com/

Use of Spatio-temporal Flow Clustering Method to Identify Change in Shared Bike Usage Due to COVID-19 Lockdown in London

Abstract

Flow networks are data that can be used to study spatial interaction and relationships between locations. Advances in data collection allowed us to collect movement data faster, easier and more detailed than ever. That additional information allows us to create and use new methods for movement analysis. One of the main advantages of that advance is collection of information about the time. In this short paper, we use a new method to group flows using 4D data (space and time), we analyze behavior and movement change for the users of share bicycle system in London before and during the lockdown. The method is based on calculation of the spatio-temporal flow similarity and it enables us to simplify large datasets and show changes on the map. As an example, we use Santander London BSS, which has more than 700 stations distributed over London, and the system collects more than 800 thousand flows monthly. To show the changes, we detect cluster in April 2019 and April 2020. For each cluster we calculate parameters that we use to detect group size, total movement, and area. By comparing the results, we show how behavior of the cyclists was significantly changed because of the lockdown. The areas where bikes are used the most have been changes, we detected a change in time when bikes are used and reasons for using the BSS. We also show how detected changes align with the expected results due to the imposed limitations and guidelines

Keywords: *bike sharing systems, lockdown, movement flows, spatio-temporal analysis*

Izazovi geodeta milenijalaca

Stjepan Miletić[1], Monika Friščić[2]

[1] Zavod za fotogrametriju d.d., Borongajska cesta 71, Zagreb, Hrvatska, stjepan.miletic@zzf.hr

[2] Green Dust, II. Ravnice 1, Zagreb, Hrvatska, monika@strengthsagent.com

Sažetak

U današnjem poslovnom svijetu moguće je raditi u okruženju koje će se sastojati od četiri različite generacije, od kojih su milenijalci oni koji će do 2025. godine činiti približno ¾ svjetske radne snage. Zbog svojih specifičnosti, od velikog je značaja praćenje potreba, ponašanja i stavova milenijalaca kako bi im se tržište moglo prilagoditi. Nadalje, pred geodetsku struku postavljaju se novi izazovi koje nameće nova tehnologija sa znatno većim mogućnostima rada. Aktivnim proučavanjem stanja struke na tržištu moguće je prepoznati potrebe i područja u koja je potrebno uložiti dodatne resurse s ciljem da se sačuva, ili čak podigne, njezin dignitet. Ovim radom pokušat će se doći do odgovora na pojedina pitanja kada je riječ o stanju u struci i razlozima zašto ju pojedinci napuštaju, a sve sa stajališta milenijalaca – generacije koja će vjerojatno imati ključnu ulogu na budućnost geodezije.

Ključne riječi: *generacija, geodezija, izazovi, milenijalci*

1. Uvod

Prema američkom istraživaču Jasonu Dorseyu danas u svijetu živi pet generacija (URL 1), koje se razlikuju s obzirom na dob, geografiju i tehnologiju. Prema godini rođenja generacije se dijele u sljedeće kategorije (Tablica 1).

Tablica 1: Podjela generacija prema godini rođenja (URL 1).

Naziv generacije	Rođeni, od – do
Generacija Z	1996. – 2015.
Milenijalci	1977. – 1995.
Generacija X	1965. – 1976.
Baby boomeri	1946. – 1964.
Tradicionalisti	prije 1945.

Za napomenuti je kako godina rođenja svake pojedine generacije ovisi o zemljopisnom području, stoga treba uzeti u obzir okolnosti geografskog područja. Veliki, značajni događaji, koji su se dogodili na nekom području, mogu utjecati na određivanje granice između dviju generacija. Tako primjerice, teroristički napad na *Blizance*, koji se dogodio 11. rujna 2001. u New Yorku, ima veliki utjecaj na oblikovanje dviju generacija u Sjedinjenim Američkim Državama: milenijalaca i generacije Z (URL 2). Generaciji Z je gotovo nemoguće jasno se sjećati tog događaja i imati duboku emocionalnu povezanost s njime koja mijenja život (URL 3). Posljednji utjecaj odnosi se na tehnologiju; prema Dorseyu, tehnologija je za čovjeka nova samo ako se čovjek sjeća kako je bilo prije, u suprotnom je ne više nego takva kakvu trenutno poznaje. Primjerice, generaciju Z određuje stopljenost s informacijsko-komunikacijskom tehnologijom i konzumacija velikog broja sadržaja, koji im značajno smanjuje raspon pozornosti (Rupčić, 2021).

S obzirom na značajke svake pojedine generacije, za očekivati je kako će njihova međusobna suradnja i komunikacija imati određene izazove koje će trebati savladati. Ovaj rad usmjeren je na istraživanje preferencija vezano za budućnost milenijalaca u struci, otkrivanje njihovih izazova vezanih uz industriju 4.0 te potencijalno definiranje drugih izazova koje milenijalci prepoznaju, a koji bi mogli utjecati na budućnost struke.

2. Provođenje anketiranja/ istraživanja

Anketni upitnik od 20 pitanja kreiran je Google Forms alatom i poslan ispitanicima krajem lipnja 2022. godine. Potrebno je istaknuti kako je anketiranje ispitanika, uz korištenje e-maila, provedeno putem društvenih mreža (WhatsAppa i Facebooka) pri čemu je do izražaja došla brzina prikupljanja podataka. Ovdje su autori rada, najviše svojim individualnim zalaganjem u suradnji s ispitanicima testirali prikupljanje podataka putem spomenutih društvenih mreža. Nadalje, s obzirom na ciljanu skupinu istraživanja, metoda prikupljanja podataka putem društvenih mreža pokazala se veoma prikladnom. Anketiranje je napravljeno na uzorku od 88 ispitanika s područja cijele Republike Hrvatske. Iako je anketa primarno bila usmjerena na generaciju milenijalaca, istu je ispunio dio generacije Z (8%) i dio generacije X (19%) kako bi se po pojedinim pitanjima napravila usporedba stavova i mišljenja.

2.1. Analiza općih podataka

Prema spolu, ispunjavanju ankete pristupilo je 59% muškaraca i 41% žena. S obzirom na status zanimanja, 31% su geodetski tehničari dok su preostalih 69% inženjeri geodezije/prvostupnici geodezije i geoinformatike/magistri inženjeri geodezije i geoinformatike. Prema dobi, ispitanici su podijeljeni u četiri kategorije (Tablica 2). Kako nije moguće eksplicitno odrediti godine rođenja koje bi obuhvaćala svaka pojedina generacija, u različitim područjima svijeta te granice će poprimati drugačije vrijednosti. Za potrebe ovog rada definirana je granica milenijalaca uključujući razdoblje od 1982. do 1996. Međutim, iz te skupine dodatno su izdvojeni tzv. „stariji milenijalci" – od 1982. godine do 1986. godine. Razlog tom pristupu je događaj koji je oblikovao povijest Republike Hrvatske – Domovinski rat. „Stariji milenijalci" u vrijeme početka Domovinskog rata imali su od pet do osam godina. Uzevši u obzir podjednakost s događajem koji je oblikovao američku povijest, sličan pristup primijenjen je u ovom istraživanju.

Tablica 2: Podjela ispitanika prema dobi.

Dob	Udio ispitanika
do 25 godina (generacija Z)	8%
od 26 do 35 godina (milenijalci)	62%
od 36 do 40 godina (stariji milenijalci)	11%
41 godina i više (baby boomeri i generacija X)	19%

Podatak da oko 67% ispitanika ima više od šest godina radnog staža u privatnom sektoru ima svoje prednosti. Dakle, većina ispitanika ima određene godine radnog iskustva na temelju kojih može donijeti konkretne zaključke o struci i/ili prepoznati određene izazove. S druge strane, oko 33% onih koji imaju najviše do pet godina radnog iskustva, s obzirom da su na početcima svog profesionalnog razvoja, moći će kroz odgovore izreći svoja očekivanja od struke. Radno iskustvo u javnom sektoru imalo je 12% ispitanika. Kategorija poduzeća prema broju zaposlenih može se podijeliti na: mikro (do 10 zaposlenih), malo (do 50 zaposlenih) i srednje (do 250 zaposlenih). U malim poduzećima zaposleno je 54% sudionika istraživanja. Ovaj podatak je razmatran iz razloga što je puno veća vjerojatnost da će zaposlenik u malom poduzeću imati prilike stručno napredovati te se okušati u prikupljanju znanja iz različitih područja, što bi ga moglo zadržati kod trenutnog poslodavca.

3. Analiza rezultata ankete

Analiza rezultata ankete podijeljena je u tri dijela. U prvom će se sagledati kakav je odnos ispitanika prema njihovom poslu i kako trenutni posao na njih utječe. Druga analiza pokazat će kakve stavove ispitanici imaju prema struci i mogućnostima pokretanja vlastitog posla. U prva dva dijela napravit će se usporedba sa svjetskim istraživanjima. U posljednjem dijelu analize sažeti su svi ostali izazovi koje ispitanici prepoznaju kao možebitne te su u obliku smjernica sažeta mišljenja ispitanika kako savladati izazove koji predstoje geodetskoj struci.

3.1. Odnos prema poslu i usporedba sa svjetskim istraživanjem

Prema Gallupovu istraživanju (URL 4) milenijalci će do 2025. godine činiti više od 75% radne snage. To je generacija koja je odrasla s tehnologijom i čak 85% njih internetu pristupa samo putem mobitela. Milenijalci trenutno čine najmanje angažiranu generaciju unutar radne snage – samo 30% milenijalaca je angažirano. Također, najčešće od svih drugih generacija mijenjaju poslodavca. Upravo zbog ovih podataka predmetno istraživanje milenijalaca za početak je obuhvatilo odnos prema poslu.

Kada je riječ o promjeni posla, 33% ispitanika niti jednom nije mijenjalo poslodavca, a od onih koji su mijenjali, najviše njih je to učinilo jednom (28%). Ako se u ovom pitanju proučava generacija milenijalaca, samo njih 28% nije do sada mijenjalo poslodavca. Podatak od 72% milenijalaca koji su mijenjali poslodavca jednom ili više puta, potvrđuje prethodno spomenute učestale promjene posla. Nastavno na ovo pitanje, bilo je postavljeno pitanje koliko su im važni aspekti života kada razmišljaju o radu u organizaciji. Bilo je ponuđeno ukupno osam aspekata. Ispitanici milenijalci na 1. i 2. mjesto stavljaju: novac i razne pogodnosti te pozitivnu radnu okolinu – isto kao svjetsko istraživanje. Prilika za kontinuirano učenje bila je na 3. mjestu (u svjetskom istraživanju to je 4. mjestu). Na 4. mjesto stavili su fleksibilnost koja se odnosi na radno vrijeme i lokaciju (u svjetskom istraživanju to je na 3. mjestu).

Sljedeća dva pitanja odnosila su se na zadovoljstvo poslom i osjećaj nadahnuća na poslu. Koliko je bitno razlikovati ova dva pojma govori istraživanje američkih lidera Erica Gartona i Michaela Mankinsa (URL 5). Nadahnuti zaposlenici će (osim što vjeruju da su dio izvanrednog tima, autonomni su u svom poslu te imaju priliku učiti i razvijati se svaki dan) smisao posla naći u misiji poduzeća i osjećat će se inspirirano vodstvom organizacije u kojoj rade, što će ih potaknuti na veće predanje svakodnevnom radu i, posljedično, povećanju produktivnosti. Istraživanje kaže da su nezadovoljni zaposlenici 29% manje produktivni od zadovoljnih zaposlenika, angažirani zaposlenici su 44% više produktivni od zadovoljnih zaposlenika, a nadahnuti zaposlenici su 225% više produktivni od zadovoljnih zaposlenika (URL 5).

Od svih ispitanika u ovom istraživanju, tek 13% osjeća se u potpunosti nadahnuto (ocjena 5). Zanimljiv podatak je kako su u toj kategoriji isključivo milenijalci, tj. nitko iz ostalih dobnih skupina nije svoje nadahnuće ocijenio najvišom ocjenom. Nešto više ispitanika, 41%, osjeća se djelomično nadahnuto (ocjena 4), dok se čak 46% ispitanika na poslu ne osjeća nadahnuto.

Što se tiče zadovoljstva poslom, od svih ispitanika, 23% je u potpunosti zadovoljno (ocjena 5), 45% se

osjeća djelomično zadovoljno (ocjena 4), a 32% se osjeća nezadovoljno. Nedostatak zadovoljstva i nadahnuća može biti poticaj za odlazak iz tvrtke, a nerijetko i napuštanje struke i poriv da se svoje „mjesto pod suncem" nađe u nekoj drugoj profesiji, o čemu će biti više govora u sljedećem poglavlju.

Naredna dva pitanja postavljena su prema svjetskom istraživanju Deloittea (URL 6) kako bi se napravila usporedba rezultata, a tiču se planiranog ostanka na trenutnom poslu. Istraživanja na svjetskoj razini kažu da generacija Z i milenijalci puno kraće vrijeme provode kod jednog poslodavca: generacija Z prosječno kod poslodavca ostaje 2 godine i 3 mjeseca, a milenijalci 2 godine i 9 mjeseci. Vidi se razlika u odnosu na generaciju X, koja u prosjeku ostaje 5 godina i 2 mjeseca, a Baby boomeri 8 godina i 3 mjeseca (URL 7). Analizirajući samo milenijalce među svim ispitanicima predmetne ankete, odlazak od trenutnog poslodavca unutar sljedeće dvije godine očekuje 41% milenijalaca (rezultat svjetskog istraživanja: 61%), dok se preostalih 59% milenijalaca izjasnilo da će ostati kod trenutnog poslodavca više od pet godina (rezultat svjetskog istraživanja: 39%) (URL 6). Podatak od 41% koji očekuju promjenu poslodavca kroz dvije godine nije iznenađujući ako se poveže podatak iz analize o učestalosti promjene posla – 72% milenijalaca najmanje jedan put je promijenilo posao, ali pozitivno je što je još uvijek puno manji nego u spomenutom svjetskom istraživanju.

3.2. Pogled na struku i usporedba sa svjetskim istraživanjem

Odnos prema struci ispitan je kroz nekoliko elemenata. Prvo je pitanje bilo žele li svoj radni staž do mirovine ostvariti u geodeziji. Od svih ispitanika, 68% je odgovorilo potvrdno. Sagledavajući samo populaciju milenijalaca, njih 34% izjasnilo da ne želi svoj radni staž do mirovine ostvariti u geodeziji. Povežemo li ove milenijalce s veličinom poduzeća u kojima rade i razlozima zbog kojih su razmišljali o promjeni profesije, utvrđuje se sljedeća činjenica: većina njih (54%) radi u malim poduzećima, i velika većina njih kao razlog zbog kojeg bi promijenili profesiju navodi veću plaću.

Iz tog razloga, bilo je postavljeno pitanje razmišljaju li ispitanici o promjeni profesije te koji su tome razlozi. Rezultati govore kako je 72% ispitanika razmišljalo o promjeni profesije, a kao najčešći razlozi navode se:

- veća plaća (43%),
- nezadovoljstvo ugledom i (ne)uređenošću struke (41%),
- novi izazovi i želja za promjenom (16%).

Ako se analizira samo populacija milenijalaca, čak 73% milenijalaca su razmišljali o promjeni profesije (odlazak u drugu struku). Iako bi odlaskom geodeta iz struke ona postala brojčano manja, ovom podatku bi trebalo pristupiti krajnje objektivno i postaviti određena pitanja, što može biti predmet nekog budućeg rada: Svojim odlaskom oni sa sobom odnose sva stečena znanja i razvijene talente u neku drugu profesiju. Hoće li pojedinci napuštanjem geodezije značajno „osiromašiti" cijelu struku? Budući da se, barem prema ovom istraživanju, radi uglavnom o milenijalcima: prijeti li geodeziji „rupa" u jednoj generacijskoj skupini koja se možda neće moći nadomjestiti? Nadalje, ispitanici su bili upitani koja dva ponuđena razloga bi ih najviše potaknula na otvaranje svoje firme (koja ne mora biti nužno vezana za struku). Prema Tablici 3, vidljivo je kako je jedan razlog otvaranja firme zajednički sa svjetskim milenijalcima, a to je povećanje vlastitih prihoda. Drugi razlog kojeg geodeti milenijalci ističu je zarada u odnosu na postignute rezultate, a ne dobivanje fiksne plaće, dok svjetski milenijalci ističu mogućnost kreiranja radnog vremena prema vlastitim preferencijama.

Sljedeća usporedba koja je napravljena u odnosu na svjetsko istraživanje odnosila se na industriju 4.0. Neke od glavnih značajki industrije 4.0 su (URL 8):

- digitalizacija industrije – povezanost strojeva, skladišta, logistike i opreme,
- integracija – unutar sektora organizacije te kroz raznolike poslovne partnere,

Tablica 3: Razlozi zbog kojih bi ispitanici/milenijalci pokrenuli vlastiti posao – usporedba sa svjetskim istraživanjem.

Ponuđeni razlozi	Svi ispitanici	Milenijalci (RH)	Milenijalci (svijet)
Želim zarađivati u odnosu na postignute rezultate, a ne raditi za fiksnu plaću	46%	44%	30%
Da zaradim više novaca / da povećam svoje prihode	39%	39%	62%
Želim biti svoj gazda / biti neovisan	27%	25%	33%
Želim imati bolji balans privatnog i poslovnog života	25%	20%	37%
Želim se okušati u novom načinu rada / to je za mene izazov	24%	30%	31%
Da radim onoliko sati koliko želim raditi	22%	23%	39%
Nemam druge opcije / za mene je to jedini način da zaradim za život	18%	19%	10%

Tablica 4: Odgovori ispitanika/milenijalaca o mogućem utjecaju industrije 4.0 na njihov posao – usporedba sa svjetskim istraživanjem.

Ponuđeni odgovori	Svi ispitanici	Milenijalci (RH)	Milenijalci (svijet)
Povećat će moj posao dopuštajući da se usredotočim na kreativniji, humaniji i vrjedniji rad	34%	38%	52%
Ne znam. Nisam siguran/na	32%	31%	8%
Zamijenit će dio ili sve moje obveze na poslu	22%	23%	17%
Neće imati nikakvog utjecaja na moj posao	12%	8%	23%

- pametni strojevi s mogućnošću neovisne razmjene informacija,
- pametne tvornice,
- kontrola optimizacije proizvodnje u realnom vremenu.

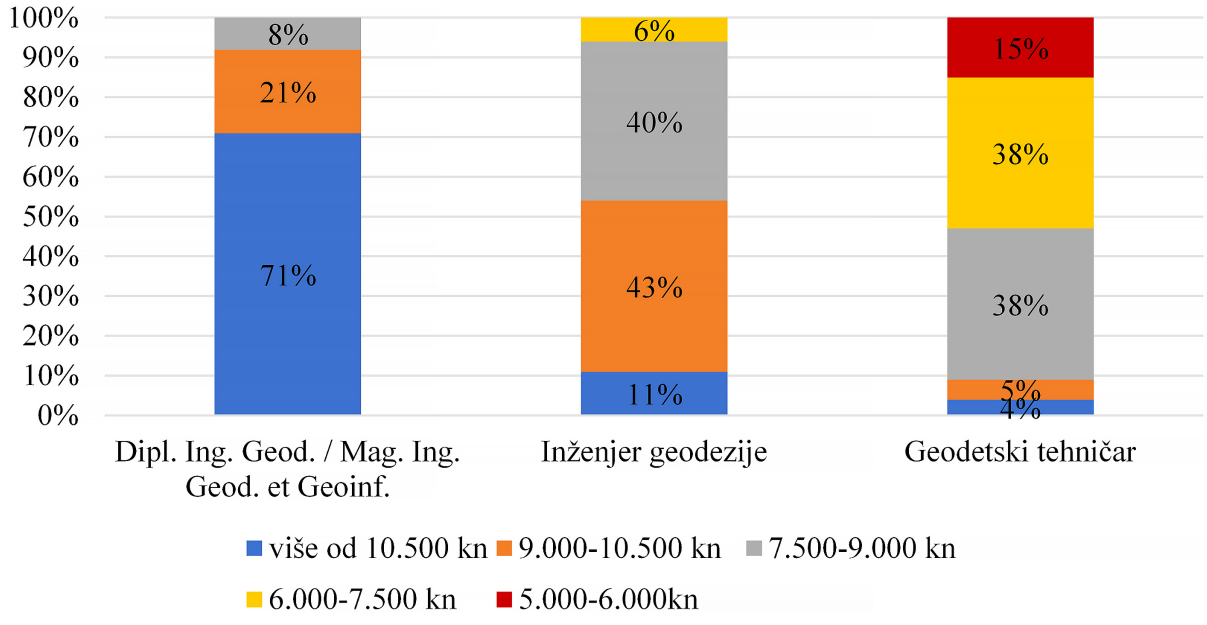
Za očekivati je kako će industrija 4.0 imati velikog utjecaja na zaposlenike. Uz potrebne dodatne zahtjeve na zaposlenike i IT obuku, nastat će nova vrsta interakcije između čovjeka i stroja, bit će više prostora za odlučivanje, upravljačke forme i strukture postat će decentralizirane. Kroz dva pitanja dotaknulo se ovo područje te su rezultati uspoređeni sa svjetskim istraživanjem (URL 5). Ispitanici su imali priliku izjasniti se kakav bi to utjecaj industrija 4.0 mogla imati na njihov posao na način da se odluče za jedan od četiri ponuđena odgovora (Tablica 4).

Može se zaključiti da ispitanici manje nego njihovi kolege na svjetskoj razini vide industriju 4.0 kao priliku za povećanje posla i mogućnost fokusiranja na kreativniji, humaniji i vrjedniji rad te veći broj smatra da će imati veliki utjecaj na njihov posao. Iznenađujuće je što čak 31% ispitanika (te isti postotak ispitanika milenijalaca) ne zna kakav će utjecaj biti ili nije sigurno, što otvara pitanje jesu li ispitanici dovoljno informirani i/ili educirani po pitanju ove teme.

Drugo pitanje po kojem se radila usporedba sa svjetskim istraživanjem bilo je: „Pomaže li Vam organizacija razumjeti i pripremiti se za promjene industrije 4.0?“. Ovdje su sličnosti u odgovorima puno veće nego iz prethodnih usporedbi. Prema rezultatima ankete slijedi:

- 50% ispitanika milenijalaca se izjasnilo da im organizacija ne pomaže pripremiti se za promjene industrije 4.0 (svjetsko istraživanje: 49%),
- 25% ispitanika milenijalaca se izjasnilo da im organizacija pomaže pripremiti se za promjene industrije 4.0 (svjetsko istraživanje: 36%),
- 25% ispitanika milenijalaca se izjasnilo da ne zna (svjetsko istraživanje: 15%).

Nerijetko se govori o tome kako plaća zaposlenika u geodetskoj struci nije „kao nekada“, nije “ona koju zaposlenici zavrjeđuju” – što je već spomenuto u razlozima o promjeni profesije. Posljednje, vjerojatno i najzanimljivije pitanje ispitanicima koje se odnosilo



Slika 1: Mišljenja ispitanika o prosječnoj neto plaći iskusnog zaposlenika po radnim mjestima.

na ovaj dio analize, bilo je vezano za neto plaće određenih radnih mjesta. U priopćenju Državnog zavoda za statistiku, prosječna neto plaća po zaposlenom za veljaču 2022. godine iznosila je 7.452 kune. U građevinarstvu, kao području djelatnosti, prosječna neto plaća iznosila je 5.963 kune, dok je za područje stručnih, znanstvenih i tehničkih djelatnosti prosječna neto plaća iznosila 8.106 kuna (URL 9).

Iz Slike 1 vidljivo je kako bi po mišljenju ispitanika iskusni geodetski tehničar trebao imati neto plaću od 6.000 do 9.000 kuna. Slična je situacija kada su u pitanju neto plaće inženjera – dvije kategorije, raspon ukupno od 6.000 do 9.000 kn, dobile su najveći broj odgovora. Čak 71% ispitanika smatra da bi neto plaća diplomiranog inženjera geodezije, odnosno magistra inženjera geodezije i geoinformatike, trebala biti više od 10.500 kn.

Iz ove analize o plaćama zaključuje se kako ispitanici smatraju da bi iskusni geodetski tehničar trebao biti plaćen otprilike u visini prosječne neto plaće u Republici Hrvatskoj. Kada je riječ o neto plaćama diplomiranih inženjera geodezije/magistara inženjera geodezije i geoinformatike, one bi trebale, prema mišljenju ispitanika, poprimati iznose veće od 10.500 kuna. Najveća prednost tih rezultata je što geodeti cijene sebe i svoj rad. Smatraju da ono što rade ima vrijednost i da bi trebalo biti vrednovano barem u visini prosječne neto plaće u Republici Hrvatskoj. S druge strane, veliki problem je ako se to ne ostvari u praksi, može polučiti da geodeti u sve većem broju krenu „napuštati" struku.

3.3. Mogući izazovi za geodetsku struku i kako im se oduprijeti

Treći dio analize obuhvaća dva otvorena pitanja u kojima su ispitanici mogli napisati svoje mišljenje u obliku komentara. Prvo se odnosilo na izazove koje prepoznaju u struci osim industrije 4.0, a drugo, što bi geodeti trebali učiniti kako bi uspjeli odgovoriti na izazove koji im predstoje. Cilj ovog dijela upitnika bio je da, osim izazova koje ovaj rad pretpostavlja za geodetsku struku i milenijalce, otvorimo i ostale teme važne za struku, a koje ispitanici prepoznaju kao potencijalne izazove za njihov profesionalni razvoj kao i za tržište rada geodeta. Osim toga, neke od ovih spoznaja mogu biti poticaj za buduća razmišljanja i istraživanja. Uz izazove industrije 4.0, ispitanici prepoznaju još i sljedeće izazove:

- 12x spomenuto: neusklađenost zakonske regulative, subjektivna pravna tumačenja, neznatan utjecaj struke na donošenje zakonske regulative,
- 11x spomenuto: narušen dignitet struke, neetičko poslovanje, korupcija, sporost u pokretanju novih projekata,
- 11x spomenuto: loš sustav tržišnog natjecanja, damping cijena i nelojalna konkurencija,
- 11x spomenuto: ulaganja u novu opremu, software, slaba iskoristivost bespilotnih letjelica u struci, (ne)suradnja s IT sektorom,
- 10x spomenuto: nedovoljan rad na ljudskim potencijalima – mogućnost usavršavanja, psihološki aspekti rada s ljudima, poslovna komunikacija, management, razvoj timske suradnje, otkrivanje i razvoj individualnih kvaliteta radnika, komunikacija sa strankama.

Prema mišljenju ispitanika, kako bi geodeti uspjeli odgovoriti na izazove koji im predstoje, trebali bi učiniti sljedeće:

- 15x spomenuto: usklađivanje zakonske regulative,
- 13x spomenuto: stručno (digitalizacija, zakoni, procesi, pravilnici, inovacije, modernizacija) i poslovno usavršavanje (npr. vođenje firme – procesa, sustava, financija te vođenje ljudi – timova, rješavanje konflikata, komunikacija, suradnja),
- 11x spomenuto: zaštititi cijene i povećati vrijednost geodetskog posla,
- 11x spomenuto: strateško brandiranje i razvoj struke, koordiniraniji nastup HKOIG-a i DGU-a, suradnja s bliskim i povezanim strukama,
- 9x spomenuto: uložiti u nove tehnologije i edukaciju radnika za njihovo korištenje,
- 6x spomenuto: na rukovodeće pozicije postaviti ljude koji imaju sposobnost voditi za dobrobit svih, bez političkih konotacija,
- 5x spomenuto: modernizirati kurikulum u školama i fakultetima (aplikacije, programiranje, upravljanje timovima, razvoj radnih procesa, financijska pismenost).

Iz njihovih otvorenih komentara može se zaključiti da imaju razvijeno kritičko mišljenje te su spremni ponuditi rješenja za izazove koje vide.

4. Zaključak

U današnjem poslovnom svijetu moguće je raditi u okruženju koje se sastoji od četiri različite generacija koje oblikuju tehnologija, dob i geografija. Svaka od njih ima svoje specifičnosti što uzrokuje mnoge izazove koje je potrebno savladati. Predmet ovog rada bilo je provođenje istraživanja u geodetskoj struci s posebnim osvrtom na milenijalce – generaciju koja bi mogla imati ključnu ulogu u usmjerenju geodezije u budućnosti.

Analizom rezultata uočena je sličnost sa svjetskim trendom kada je u pitanju učestalost promjene posla. Prema svjetskim pokazateljima milenijalci mijenjaju posao u prosjeku svakih 2 godine i 9 mjeseci. Prema rezultatima ankete, 72% geodeta milenijalaca mijenjalo je posao najmanje jednom. Mnogi svjetski trendovi jasno pokazuju kako je izuzetno važno imati zadovoljnog, a još bolje nadahnutog zaposlenika. Kada se analizira zadovoljstvo ispitanika, samo 23% potpuno je zadovoljno, 45% djelomično, a preostalih 32% osjeća se nezadovoljno. Analizirajući nadahnutost ispitanika, situacija je još lošija; samo 13% osjeća se nadahnuto, 41% djelomično nadahnuto, a čak 46% ne osjeća se nadahnuto. Kao najčešći razlog za promjenu profesije ispitanici navode: veću plaću, nezadovoljstvo stanjem u struci te nove izazove i želju

za promjenom. Kao dva najčešća razloga zbog kojih bi pokrenuli vlastiti posao, navode zaradu sukladno postignutim rezultatima te povećanje prihoda. To je djelomično usklađeno s rezultatima svjetskih istraživanja u kojem milenijalci također navode povećanje prihoda kao razlog pokretanja samostalnog posla. Ono što milenijalci u svijetu navode kao drugi razlog je raditi onoliko sati koliko žele.

Po pitanju plaća u geodetskoj struci, odgovori ispitanika upućuju da iskusan geodetski stručnjak po njihovu mišljenju zaslužuje plaću koja je, kada je riječ o geodetskim tehničarima, najmanje u visini prosječne plaće u Republici Hrvatskoj. Uz izazove industrije 4.0, ispitanici prepoznaju još neke: potrebu za poboljšanjem zakonske regulative i povećanja uključivosti, problem nelojalne konkurencije, ugled i dignitet struke u društvu, manjak ulaganja u novu opremu. Iako predstoje veliki izazovi za geodetsku struku – što u pogledu međugeneracijskih razlika, što u pogledu industrije 4.0 – postoje rješenja kako odgovoriti na iste. Kao odgovor na izazove, ispitanici predlažu: postaviti logičnu zakonsku regulativu, poslovno se usavršavati, zaštititi cijene geodetskih usluga. Zasigurno će generacija milenijalaca imati veliki utjecaj na geodetsku struku i definiranje njezina statusa na tržištu što je velika privilegija, ali istovremeno i odgovornost prema generacijama koje dolaze. Za budućnost geodetske struke važno je da svaka generacija da najbolje od sebe. Starije generacije, uz kontinuirano učenje, svojim znanjem mogu doprinijeti razvoju potencijala i talenata koje imaju mlađe generacije, odnosno milenijalci. Ako milenijalci budu prepoznali i iskoristili svoje talente te hrabro preuzeli odgovornost za struku, podići će njezin dignitet.

Literatura

Rupčić, N. (2021): Značajke post-milenijalaca ili generacije Z kao novih sudionika na tržištu rada, Zbornik radova Veleučilišta u Šibeniku, 15, 47–60.

URL 1: The Generations Birth Years, https://jasondorsey.com/about-generations/generations-birth-years/, (25.6.2022.).

URL 2: Top Gen Z Questions Answered, https://jasondorsey.com/about-generations/gen-z/, (25.6.2022.).

URL 3: 19 Years on Does a Post – 9/11 Generation Remember the Attacks?, https://www.voanews.com/a/usa_19-years-does-post-911-generation-remember-attacks/6195752.html, (26.6.2022.).

URL 4: How Millennials Wants to Work and Live, https://www.gallup.com/workplace/238073/millennials-work-live.aspx, (26.6.2022.).

URL 5: Engaging Your Employees Is Good, but Don't Stop There, https://hbr.org/2015/12/engaging-your-employees-is-good-but-dont-stop-there, (25.6.2022.).

URL 6: 2018 Deloitte Millennial Survey, Millennials disappointed in business, unprepared for Industry 4.0, https://www2.deloitte.com/content/dam/Deloitte/global/Documents/About-Deloitte/gx-2018-millennial-survey-report.pdf, (25.6.2022.).

URL 7: Millennials or Gen Z: Who's Doing the Most Job-Hopping, https://www.careerbuilder.com/advice/how-long-should-you-stay-in-a-job, (26.6.2022.).

URL 8: Industrija 4.0, Hrvatska gospodarska komora, https://www.hgk.hr/documents/hgk-industrija-4058d8c59722f1e.pdf, (26.6.2022.).

URL 9: Prosječne mjesečne neto i bruto plaće zaposlenih za veljaču 2022., Državni zavod za statistiku, https://podaci.dzs.hr/2022/hr/29042, (26.6.2022.).

Challenges of Millennial Surveyors

Abstract

In today's business world, it is possible to work in an environment consisting of four different generations, of which millennials are the ones who will make approximately ¾ of the worlds' workforce by 2025. Due to their specificities, it is of great importance to monitor the needs, behaviour and attitudes of millennials so that the market can adapt to them. Furthermore, the geodetic profession faces new challenges imposed by new technologies with considerable wide possibilities. By actively studying the state of the profession on the market, it is possible to recognize needs and areas in which additional resources need to be invested in order to preserve, or even increase, the dignity of geodetic profession. This paper offers insights into some background reasons for the current state of the profession and the reasons why some leave it, all from the point of view of millennials – a generation that will probably play a key role in future of geodesy.

Keywords: *challenges, generation, geodesy, millennials*

SPONZORI

generalni

Geomatika SMOLČAK d.o.o.

zlatni

GEO CENTAR

Ericsson Nikola Tesla

srebrni

GeoWILD

brončani

GEOSUSTAVI GEODETSKI INSTRUMENTI I PRIBOR

GEOSOFT

listlabs

KOMTEH 30+ godina

ArcGeo

GEODETSKI ZAVOD RIJEKA 70 1952-2022

GEODETSKI ZAVOD d.d. SPLIT
ZAVOD ZA PROJEKTIRANJE I IZVOĐENJE GEODETSKIH POSLOVA

ACES

gd geodist

GeoMIR.software
G6+CAD
AUTODESK AUTOCAD OEM

GEODATA

Geo Grupa d.o.o. Zagreb

Geoprojekt d.d. Opatija

GEOPROJEKT

GENERALI

oganj

ISBN 978-953-49258-2-9

Uz potporu

OPATIJA
OPATIJSKA RIVIJERA
TURISTIČKA ZAJEDNICA GRADA OPATIJA

Pokrovitelji

Zoran Milanović
predsjednik Republike Hrvatske

REPUBLIKA HRVATSKA
Ministarstvo prostornoga uređenja, graditeljstva i državne imovine

REPUBLIKA HRVATSKA
Državna geodetska uprava

HRVATSKE VODE