ZBORNIK RADOVA

17. SIMPOZIJ OVLAŠTENIH INŽENJERA GEODEZIJE



PRAKTIČNA ZNANJA BUDUĆNOSTI U GEODEZIJI I GEOINFORMATICI

23. – 26. listopada 2024.

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

Hrvatska komora ovlaštenih inženjera geodezije

POREČ

23. – 26. listopada 2024.

PRAKTIČNA ZNANJA BUDUĆNOSTI U GEODEZIJI I GEOINFORMATICI

17. simpozij ovlaštenih inženjera geodezije

ZBORNIK RADOVA

U suradnji s Council of European Geodetic Surveyors

IMPRESUM

Naslov

Praktična znanja budućnosti u geodeziji i geoinformatici, Zbornik radova 17. simpozija ovlaštenih inženjera geodezije

Izdavač

Hrvatska komora ovlaštenih inženjera geodezije

Za izdavača

Ivan Kalina, 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, listopad 2024.

ISBN 978-953-49258-8-1

Copyright © Hrvatska komora ovlaštenih inženjera geodezije, 2024.

ORGANIZACIJSKI ODBOR

Predsjednica:

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

Članovi:

Adrijan Jadro, dipl. ing. geod.

Ivan Kalina, dipl. ing. geod.

Nataša Kapov Kostovski, dipl. ing. geod.

Antonija Majić, dipl. ing. geod.

Daria Došen, mag. ing. geod. et geoinf.

ZNANSTVENO-STRUČNI ODBOR

Predsjednica:

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

Članovi:

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

prof. dr. sc. **Branko Božić**
Univerzitet u Beogradu, Građevinski fakultet, Srbija

izv. prof. dr. sc. **Mladen Šoškić**
Univerzitet u Beogradu, Građevinski fakultet, Srbija

doc. dr. sc. **Dušan Petrovič**
Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Slovenija

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

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

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

doc. dr. sc. **Olga Bjelotomić Oršulić**
Sveučilište Sjever, Odjel za geodeziju i geomatiku, Hrvatska

UVODNIK

predsjednika Hrvatske komore ovlaštenih inženjera geodezije



Poštovane kolegice i kolege,
Članovi Hrvatske komore ovlaštenih inženjera geodezije, prijatelji

Ovogodišnji 17. Simpozij ovlaštenih inženjera geodezije kruna je godišnjeg rada njegovih organizatora i prijatelja Komore kako ove tako i prethodnih godina.

Simpozij ovlaštenih inženjera geodezije zamišljen je kao mjesto gdje se raspravlja, komentira i propitkuje trenutno stanje i budućnost geodetske struke u tehnološkom i društvenom aspektu u čijem je središtu čovjek, ovlašteni inženjer geodezije.

Artificial intelligence (AI), Umjetna inteligencija (UI) je skup tehnologija koje omogućuju računalima izvođenje niza naprednih funkcija, uključujući sposobnost da vide, razumiju i prevedu govorni i pisani jezik, analiziraju podatke, daju preporuke i više od toga.

Obzirom na uznapredovalu primjenu tehnologije i automatiziranih postupaka u geodetskoj struci 17. Simpozij ovlaštenih inženjera geodezije osmišljen je pod nazivom „Praktična znanja budućnosti u geodeziji i geoinformatici".

Simpozij je mjesto u kojem će se susresti mnogi ovlašteni inženjeri geodezije, stručni suradnici i suradnici ovlaštenog inženjera geodezije i međusobno podijeliti svoja osobna iskustva, znanja i postignuća na polju geodezije i geoinformatike. Naši cijenjeni predavači izložiti će svoje znanstveno stručne radove, a panelisti svojim iskustvom rasplamsati teme koje su im stavljene na raspravu. Uz glavnu temu Simpozija biti će nam kroz niz sesija, predavanja i panela predstavljen i niz drugih aktualnih tema.

UI ima veliku ulogu u današnjem poslovanju i donosi ogromne promjene, te doprinosi globalnoj ekonomiji s nevjerojatnim vrijednostima koje su izražene u desecima trilijuna dolara. Transformira procese, omogućuje naprednu analizu podataka i doprinosi stvaranju vrijednosti unutar organizacija, kao primjer su aplikacije koje utječu na način na koji radimo, učimo i stvaramo, poput ChatGPT-a.

Iako se većina kompanija oslanja na tehnološke aspekte umjetne inteligencije često zanemarujemo njen utjecaj na um, ponašanje, ljudske odnose i samu prirodu rada ovlaštenika i njegovih suradnika u području geodezije i geoinformatike. Izuzetno je važno stvaranje povjerenja između čovjeka i „stroja" iz čega trebamo sebi postaviti pitanje „jesmo li smo spremni".

Hrvatska komora ovlaštenih inženjera geodezije čuva ugled, čast i prava ovlaštenih inženjera geodezije, skrbi se da oni savjesno i u skladu sa zakonom obavljaju svoje poslove, te će kao i do sada olakšati prilagodbu svojim članovima približavajući im sva dostupna praktična znanja budućnosti u geodeziji i geoinformatici jer naposlijetku u središtu tehnološkog i društvenog aspekta je čovjek.

Zahvaljujem se Organizacijskom i Znanstveno-stručnom odboru Simpozija, pozvanim predavačima, panelistima, gostima iz Hrvatske i inozemstva, autorima radova, recenzentima članaka, voditeljima sesija, sponzorima i izlagačima.,

Predsjednik Hrvatske komore
ovlaštenih inženjera geodezije
Ivan Kalina, dipl. ing. geod.

UVODNIK

predsjednice Znanstveno-stručnog odbora 17. simpozija ovlaštenih inženjera geodezije



Poštovane geodetkinje i geodeti, cijenjene geoinformatičarke i geoinformatičari,

ovogodišnji 17. simpozij ovlaštenih inženjera geodezije usmjeren je na temu „Praktična znanja budućnosti u geodeziji i geoinformatici". Geodetsko-geoinformatička struka u svojem se ishodišnom dijelu oslanja na praksu, koja uključuje praktične radove na terenu, tzv. zemljomjerstvo. U svojem drugom, podjednako važnom dijelu, rezultat naših mjerenja jeste neki oblik grafičkog prikaza, odnosno u suvremenom svijetu, izrada modela (modeliranje). U oba slučaja, od nas kao stručnjaka, očekuje se kontinuirano praćenje i usvajanje novih tehnoloških, regulatornih i inih rješenja na kopnu i na moru. U posljednjih nekoliko desetljeća promjene u našoj struci i znanja koja svakodnevno trebamo usvajati su iznad svega što se moglo očekivati u ne tako davnoj prošlosti. Pitanje koje se nameće je - što nas čeka u budućnosti? Simpozijem ćemo pokušati predvidjeti i barem donekle spremniji dočekati ono što nam donosi sutra.

Zbornik radova 17. simpozija ovlaštenih inženjera geodezije podijeljen je u pet zasebnih cjelina. Svaka je od njih fokusirana na neki segment geodetsko-geoinformatičke struke i njezina sadašnjeg i budućeg razvoja. U teorijska znanja budućnosti naše struke svakako su uključeni edukacija i regulativa, kao ishodište budućeg razvoja. Praktičnu podršku struci daje razvoj novih tehnologija, kako hardverskih tako i softverskih. Danas je nezaobilazna i umjetna inteligencija. Postavši integralni dio naše struke omogućit će nam daljnji razvoj i brža i bolja rješenja tehničkih problema u struci. Ono čemu se uvijek vraćamo jeste i pitanje uređenja zemljišta, pa donosimo i nekoliko radova iz tog područja. Ukupno je pristiglo 25 radova u čijem čitanju ćete vjerujem uživati, ali isto tako pronaći i nešto novo što će vam pomoći u daljnjem radu. Simpozij će se i ove godine održati uživo i putem digitalnih komunikacijskih sredstava. Zahvaljujući podršci i sudjelovanju članova CLGE-a, Simpozij ima međunarodni karakter.

Zahvaljujem se predsjedniku Hrvatske komore ovlaštenih inženjera geodezije Ivanu Kalini i Upravnom odboru Komore te Organizacijskom odboru Simpozija na suradnji. Zahvaljujem se članovima Znanstveno-stručnog odbora Simpozija na aktivnom sudjelovanju u organiziranju Simpozija i recenziranju radova. U ime Znanstveno-stručnog odbora zahvaljujem se i djelatnicima tajništva Komore na izvrsnoj organizacijskoj podršci. Veliko hvala autorima radova i svim sudionicima Simpozija.

Vjerujem da ćemo tijekom trajanja 17. simpozija ovlaštenih inženjera geodezije, kroz niz panela i prezentacija dobiti odgovore na neka teorijska i praktična pitanja struke i usvojiti nova znanja potrebna za bolju budućnost geodetsko-geoinformatičke struke. Želim svima uspješan rad Simpozija!

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

SADRŽAJ

1. DIGITALIZACIJA PROSTORA I UMJETNA INTELIGENCIJA

Marijan Grgić, Philipp Meixner
Primjena integriranih mobilnih mjernih sustava za kartiranje, analizu i praćenje prometne infrastrukture 11

Zvonimir Nevistić, Željko Bačić, Kristina Marković
Razvoj funkcionalnosti digitalnog blizanca na primjeru Grada Pule 17

Vedran Vrhovac
Umjetna inteligencija u planiranju mreže 5. generacije 23

Ivana Radošević, Veronika Ilić
Automatizacija procesa analize i obrade hidrografskih i geofizičkih podataka 29

Robert Župan, Stanislav Frangeš, Adam Vinković, Ivana Racetin
Usporedba karata izrađenih umjetnom i ljudskom inteligencijom 35

Iva Cibilić, Vesna Poslončec-Petrić
Kalibracija pametnih telefona u svrhu volonterskog mjerenja buke 41

Adam Vinković, Robert Župan
Prostorno-vremenska analiza biciklističke aktivnosti upotrebom mnoštveno prikupljenih podataka 47

2. NOVI PRISTUPI UREĐENJU ZEMLJIŠTA

Stjepan Miletić, Filip Pavelić, Damir Delač
Prijedlog preporučene cijene proizvodnog sata geodetskog stručnjaka 55

Josip Vejmelka
Posebni režimi i njihova interakcija s ostalim zemljištem prilikom izrade geodetskih elaborata 61

Filip Pavelić, Stjepan Miletić, Zdenko Potlaček
Prijava na Javni poziv za komasaciju poljoprivrednog zemljišta – iskustva iz prakse 69

Josipa Budić, Damir Robić, Marinko Požega
Interoperabilnost zemljišnih podataka kao čimbenik postupka digitalne transformacije javne uprave 77

Franjo Ambroš, Vedran Stojnović, Vladimir Slivac, Dario Tot, Zoran Kovač, Damir Jelošek, Tihomir Zec
Izvlaštenje i procjena nekretnina radi izgradnje energetske infrastrukture 83

3. DALJINSKA ISTRAŽIVANJA I FOTOGRAMETRIJA

Nenad Brodić, Uroš Đurić, Mileva Samardžić-Petrović, Anastasija Martinenko, Marko Pejić
High-Resolution UAV-based Photogrammetry for 3D Modelling and Monitoring Changes of Earth Pillars: Case Study Devil's Town – Project Demonitor 93

Mateo Gašparović, Ivana Metić
Procjena dugotrajnog učinka klimatskih utjecaja primjenom podataka daljinskih istraživanja 99

Mateo Gašparović, Filip Radić, Ivan Lukačević, Boris Fuštar
Razvoj algoritma za potrebe industrijske fotogrametrijske izmjere 107

Marina Tavra, Ivan Racetin, Josip Peroš
Urbanizacija i klimatske promjene: Analiza kretanja površinske temperature u Gradu Splitu (2013.–2022.) primjenom satelitskih podataka 113

4. TEHNOLOGIJE SADAŠNJOSTI I BUDUĆNOSTI

Momir Mitrović, Mladen Šoškić, Igor Nedeljković
Izrada geodetskih podloga za projektiranje linijskih infrastrukturnih građevina primjenom multisenzorskih snimanja 121

Antonio Tupek, Mladen Zrinjski, Krunoslav Špoljar, Barbara Galić, Karlo Stipetić, Iva Međugorac
Porast srednje razine Jadranskog mora na Mareografskoj postaji Bakar 131

Dino Dobrinić, Franka Knežević
Earth Observation Data Cubes for Remote Sensing Analysis 139

Vanja Miljković, Iva Odak, Luka Babić, Ivana Hećimović
Hiperspektralna tehnologija i mogućnosti primjene 145

Loris Redovniković, Antun Jakopec
Mogućnosti primjene jeftinog LiDAR sustava za geodetsku izmjeru 151

5. EDUKACIJA I ZAKONSKE SMJERNICE U GEODETSKO-GEOINFORMATIČKOJ PRAKSI

Željko Bačić, Vesna Poslončec-Petrić, Danijela Ignjatović
Svemir – novi sadržaj studijskih programa geodezije i geoinformatike 159

Vlado Cetl, Olga Bjelotomić Oršulić, Sanja Šamanović, Danko Markovinović, Hrvoje Matijević, Nikola Kranjčić
Obrazovni resursi za integraciju BIM-a i GIS-a 165

Vesna Poslončec-Petrić, Željko Bačić
Modernizacija studijskih programa geodezije i geoinformatike kroz Erasmus+ KA2 projekte 171

Josip Šimić, Ilija Ćaćić, Jelena Jurišić
Primjena blockchaina i pametnih ugovora u pravnom prometu nekretinama 179

1.

DIGITALIZACIJA PROSTORA I UMJETNA INTELIGENCIJA

Primjena integriranih mobilnih mjernih sustava za kartiranje, analizu i praćenje prometne infrastrukture

***Marijan Grgić*[1], *Philipp Meixner*[1]**

[1] Meixner Vermessung ZT GmbH, Linke Wienzeile 4, Austrija, grgic@meixner.com, philipp@meixner.com

Sažetak

Integrirani mobilni mjerni sustavi omogućuju ekonomično i efikasno prikupljanje prostornih podataka u svrhu razvoja 3D pametnih gradova, brzog odgovora na prirodne katastrofe, razvoja upravljanja autonomnim vozilima, ali i obavljanja standardnih geodetskih zadataka izmjere. Takvi sustavi najčešće integriraju LiDAR (*Light Detection and Ranging*) i kamere visoke razlučivosti sa sustavima za praćenje položaja platforme u pokretu s koje se obavlja mjerenje – GNSS (*Global Navigation Satellite Systems*) i IMU (*Inertial Measurement Unit*) jedinicama. Intenzivnim razvojem i primjenom algoritama strojnog učenja i umjetne inteligencije, obrada podataka prikupljenih mobilnim sustavima često je automatizirana, a rezultati dostupni i u realnom vremenu. U ovom radu prikazan je razvoj i primjena mobilnih sustava za izmjeru, analizu i praćenje prometne infrastrukture kroz ostvarene projekte praćenja pukotina cestovne infrastrukture u Gornjoj Austriji, projekte izmjere autocesta u Austriji i Njemačkoj te projekt kartiranja, analize i praćenja tramvajske infrastrukture grada Beča, prvenstveno korištenjem Riegl VMX-2HA platforme, ali i drugih mjernih metoda. U radu je prikazana i integracija tako prikupljenih podataka za proširenje dvodimenzionalog GIS-a (*Geographic Information System*) 3D podacima te razvoj BIM-a (*Building Information Modeling*).

Ključne riječi: 3D GIS, BIM, LiDAR, mobilni sustavi izmjere, praćenje prometne infrastrukture

1. Uvod

Mobilna izmjera i integrirani sustavi u geomatici (*eng. Mobile Mapping Systems*) igraju ključnu ulogu u modernim metodama prikupljanja podataka i analize prostornih informacija. Takvi sustavi najčešće na pokretnoj platformi instaliranoj na prometnim vozilima na cestama, rijekama, moru i zraku ili instaliranoj na osobi/objektu u pokretu integriraju jedan ili više LiDAR (*Light Detection and Ranging*) senzora s jednom ili više kamera visoke razlučivosti, multispektralnim i hiperspektralnim senzorima, georadarima i sl., uz praćenje lokacije putem GNSS-a (*Global Navigation Satellite Systems*) i IMU (*Inertial Measurement Unit*) jedinica, ili drugim sustavima za pozicioniranje u zatvorenom prostoru (Khoshelham i Zlatanova, 2016; Elhashash,i dr., 2022). Mobilna izmjera najčešće podrazumijeva koregistraciju i georeferenciranje različitih podataka prikupljenih senzorima integriranim na platformi za vrijeme njihovog prikupljanja. Taj postupak u pravilu se odvija putem mobilnih aplikacija koje operaterima na terenu omogućuju jednostavno upravljanje sustavima i brzu obradu podataka te smanjuju ili u potpunosti poništavaju potrebu za naknadnom obradom podataka (vidjeti npr. Xu i dr., 2020).

Integrirani sustavi za mobilnu izmjeru u pravilu proširuju geodetske aktivnosti na aktivnosti za potrebe prostornog planiranja i upravljanja infrastrukturom, geološka i klimatološka istraživanja, arheoloških istraživanja i očuvanja kulturne baštine i dr. Budući da su platforme najčešće jednostavne za korištenje te veličinom, cijenom i namjenom prilagodljive za specifične zadatke čak i za primjenu u teško dostupnim područjima (vidjeti npr. Di Stefano i dr., 2021; Grasso i dr., 2023), često ih pronalazimo izvan „geodetske domene".

Korištenje mobilne izmjere i integriranih sustava za prikupljanje podataka ima značajne prednosti u izgradnji, praćenju i održavanju te rekonstrukciji i unaprjeđenju prometne infrastrukture, posebno željezničke i tramvajske (Corongiu i dr., 2020; Glira i dr., 2022; Alberti i dr. 2023). Mobilni sustavi omogućuju prikupljanje podataka bez ometanja normalnog rada infrastrukture, što smanjuje troškove i povećava sigurnost radnika na terenu. Uz to, mobilni sustavi izmjere omogućuju kontinuiranu/ponovljivu izmjeru bez gubitka kvalitete, posebno za željezničke i tramvajske sustave integracijom mjernih platformi na vozila na standardnim i ponovljivim rutama.

Primjena takvih sustava u željezničkoj (a i drugoj) infrastrukturi omogućuje precizno praćenje stanja tračnica, mostova i drugih ključnih komponenti. To rezultira boljim održavanjem i bržim identifikacijama potencijalnih problema, što smanjuje rizik od nesreća i povećava sigurnost putnika. Također, mobilni sustavi za kartiranje omogućuju detaljnu analizu geometrije tračnica i okoliša, stanje nasipa, tucanika i prometne signalizacije što je ključno za planiranje novih projekata i optimizaciju postojećih ruta (vidjeti npr. Soilán i dr., 2019). U kontekstu tramvajske infrastrukture,

mobilna izmjera omogućuje praćenje stanja kolosijeka, stanica i drugih objekata koji se intenzivnije mijenjaju od sličnih elemenata željezničke infrastrukture zbog značajnijeg utjecaja urbanizacije, građevinskih radova te drugih prometnih gradskih infrastruktura. Podaci dobiveni mobilnom izmjerom koriste se za kapitalne projekte planiranja, projektiranja i izvođenja rekonstrukcije i modernizacije tramvajskih mreža, ali i poslove održavanja kao što su kontrola rasta zelenila i njegova utjecaja na prohodnost vozila, vidljivost signalizacije i sl. Kontinuirano prikupljeni podaci također omogućuju precizno praćenje utjecaja urbanih razvojnih projekata na tramvajsku i drugu infrastrukturu, omogućujući pravovremeno planiranje i intervencije vezane uz kvalitetu usluge.

U ovom radu predstavljene su neke od aktivnosti tvrtke Meixner Vermessung ZT GmbH iz Beča u Austriji u okviru mobilne izmjere te integracije tako prikupljenih podataka u GIS (*Geographic Information System*) i BIM (*Building Information Modeling*) modele.

2. Mobilni sustavi za izmjeru – koncepti

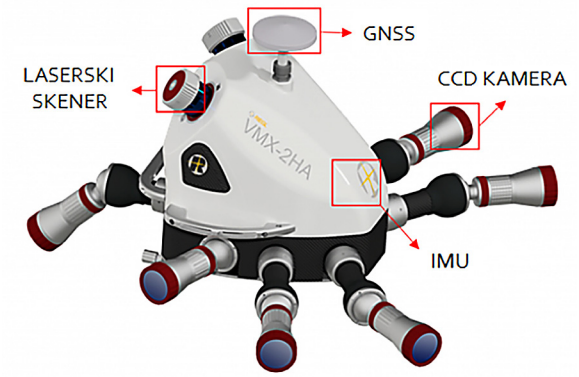
Komercijalni mobilni sustavi za izmjeru najčešće se dijele prema načinu prenošenja na – ručne (Slika 1) i sustave koji se prenose u ruksaku, na kolicima ili na vozilu. Osim takve podjele, česta je i ona prema lokaciji provođenja mjerenja – na uređaje za vanjsku ili unutarnju ili i jednu i drugu izmjeru (Elhashash i dr., 2022).



Slika 1: Primjer nosivog („ruksak“) mobilnog sustava za izmjeru, Navvis VLX 3, koji ostvaruje 1,28 milijuna mjerenja u sekundi uz maksimalni domet snopa od 300 m i ostvarivu preciznost od 5 mm te prikuplja fotografije koje pokrivaju 360° (Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)

Standardni moderni uređaji koji se koriste za izmjeru prometne i druge infrastrukture (Slika 2) najčešće objedinjuju LiDAR senzor s mogućnošću prikupljanja nekoliko milijuna točaka u sekundi i kameru koja prikuplja podatke 360° vidljivog polja te GNSS, IMU i odometar (ponekad i žiroskop te WI-FI (Wireless Fidelity) i/ili GSM (Global System for Mobile Communications)/CDMA (Code Division Multiple Access) modem za navigaciju putem mobilnih mreža) za praćenje lokacije te automatsku koregistraciju i georeferenciranje podataka. LiDAR senzor mora biti u mogućnosti prikupiti podatke pri različitim brzinama – tako je senzor s 32 laserska snopa preporučljiv za primjenu na platformama koje ostvaruju brzinu do 60 km/h, a senzor s 128 laserska snopa može se primijeniti i na brzinama od 100 km/h. Detaljan pregled senzora prema dosegu laserskog snopa, točnosti, broju snopova, vidljivom horizontalnom i vertikalnom polju i rezoluciji, broju ostvarivih mjerenja u sekundi i frekvenciji prikazan je u Elhashash i dr. (2022).

Iz geodetske perspektive posebno je važno ostvarivanje pouzdane apsolutne (nastavno i relativne) točnosti prikupljenog oblaka točaka i drugih podataka. To se ostvaruje fuzijom gore navedenih senzora kojima se pridaju težine ovisno o jačini i pouzdanosti pojedinog signala i same geodetske metode određivanja položaja. Iako je deklarirana točnost najjačih modela za mobilnu izmjeru (npr. Slika 2) često viša od 5 mm, ostvariva točnost može varirati te je za praćenja pomaka (npr. mostovi, brane, tuneli, fina infrastruktura) i druge specifične izmjere (npr. detaljna podzemna izmjera, izrada visokopreciznih geodetskih podloga, praćenje vertikalnih kretanja objekata i sl.) potrebno koristiti terestričke laserske skenere ili tradicionalne geodetske metode (vidjeti i Grgić i dr., 2023).





Slika 2: Primjer mobilnog sustava za izmjeru na pokretnoj platformi/vozilu, Riegl VMX-2HA, koji ostvaruje 3,6 milijuna mjerenja u sekundi uz maksimalni domet snopa od 475 metara i ostvarivu točnost od 5 mm i preciznost 3 mm te prikuplja fotografije koje pokrivaju 360° u rezoluciji do 240 MP (Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)

Sustavi mobilne izmjera kontinuirano se razvijaju s ciljem poboljšanja točnosti, brzine i učinkovitosti prikupljanja podataka. Aktualni razvoj uključuje integraciju umjetne inteligencije i strojnog učenja za automatsku analizu i interpretaciju podataka (npr. de



Slika 3: Desktop aplikacija Meixner Ulimited Viewer razvijena kako bi se omogućio brz i jednostavan pregled prikupljenih podatka (panoramski prikaz i oblak točaka) (Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)

Araújo Carvalho i dr., 2022), što dodatno smanjuje vrijeme potrebno za obradu i analizu podataka. Razvoj novih senzorskih tehnologija i poboljšanje postojećih u budućnosti omogućit će prikupljanje još preciznijih i detaljnijih podataka u različitim okruženjima.

3. Primjena mobilnih sustava za izmjeru

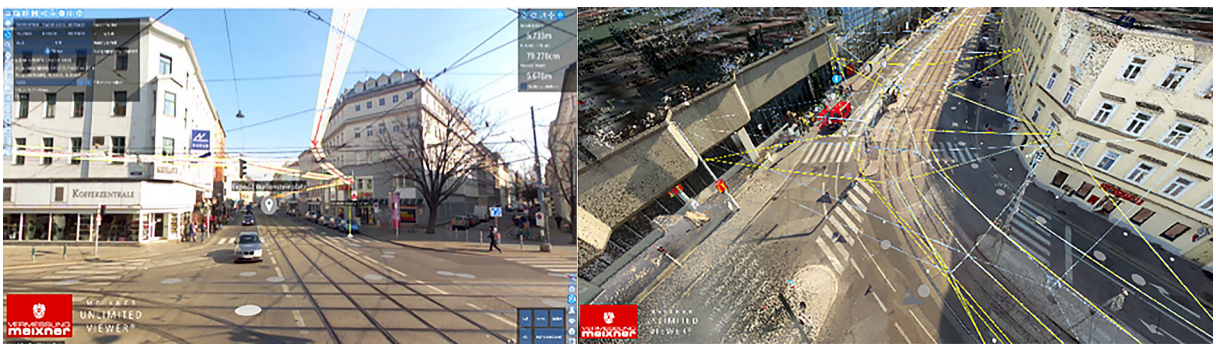
Tvrtka Meixner Vermessung ZT GmbH aktivno sudjeluje u više projekata mobilne izmjere za potrebe GIS/BIM modeliranja. Ispod su ukratko predstavljeni neki od aktualnih ili završenih projekata.

3.1. Tramvajska mreža grada Beča (Wiener Linien, 2021. – 2024.)

Projekt kartiranja i praćenja mreže tramvajske mreže grada Beča u Austriji obavlja se kontinuirano od 2021. godine. Mjerenja se izvode svake godine u duljini od 210 km, a osnovni zadatak praćenje je promjena u prohodnosti prometovanja na što utječu promjene u vegetaciji i/ili izgrađenim objektima. Pošto je zahtijevana točnost ostvarenog modela 5-10 cm, ova se mjerenja ne provode radi praćenja promjena ili pomaka tračnica, ali mogu biti korisna i za modeliranje karata buke, planiranja buduće signalizacije, praćenje prometnih nesreća i poboljšanje korisničkog iskustva boljim planiranjem nadogradnje mreža.

Projekt se obavlja Riegl VMX-2HA mobilnim platformama s osobnog vozila u (otprilike) desetodnevnoj mjernoj kampanji (osnovna geodetska podloga u pravilu je izrađena unaprijed), a zadatak je prikupljanje laserskih podataka uz mjerenje minimalno 2 milijuna točaka odnosno 2 x 250 linija u sekundi te panoramskih snimaka visoke razlučivosti (u primjeni LadyBug5 panoramska kamera 30 MP). Oblaci točaka povezuju se s panoramskim snimkama u Riegl RIPrecision softveru kako bi se omogućila naknada obrada i mjerenja u panoramskim scenama. Rezultati se klijentu isporučuju u .e57 formatu (uz standardne GIS formate), a za potrebe vizualizacije podataka tvrtka je razvila desktop aplikaciju Meixner Unlimited Viewer (Slika 3). Osim isporuke oblaka točaka, u projektu se isporučuju 3D podaci kao temelj 2.5D proširenja GIS-a.

U okviru projekta provodi se i kartiranje kablova tramvajske mreže i analiza njihove sigurnosti unutar mreže te u odnosu na drugu infrastrukturu (npr. električna, telefonska i sl. infrastruktura). Za potrebe ovog zadatka razvijen je algoritam za automatsku detekciju kablova, njihovu analizu te integraciju u CAD/GIS/BIM, ovisno o potrebi korisnika (primjer Slika 4).



Slika 4: Polu-automatski sustav za detekciju, kartiranje i analizu kablova tramvajske mreže razvijen za potrebe projekta (Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)



Slika 5: Isječak izrađenog BIM-a željezničke postaje u Hannoveru
(Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)

3.2. Mobilna izmjera kao nadopuna za BIM (Deutsche Bahn – DB Hannover, 2019. – 2022.)

Sustav mobilne izmjere Riegl VMX-2HA korišten je i kao dopuna detaljnoj izmjeri glavnog željezničkog kolodvora u Hannoveru u razdoblju od 2019. do 2022. To je područje u dužini od 100 km prvenstveno mjereno laserskim skenerima Leica RTC360, totalnim stanicama, GNSS-om i fotogrametrijom, a sustav mobilne izmjere korišten je kao nadopuna za dugačke trase željeznice bez nadzemno izgrađenih objekata u okolini.

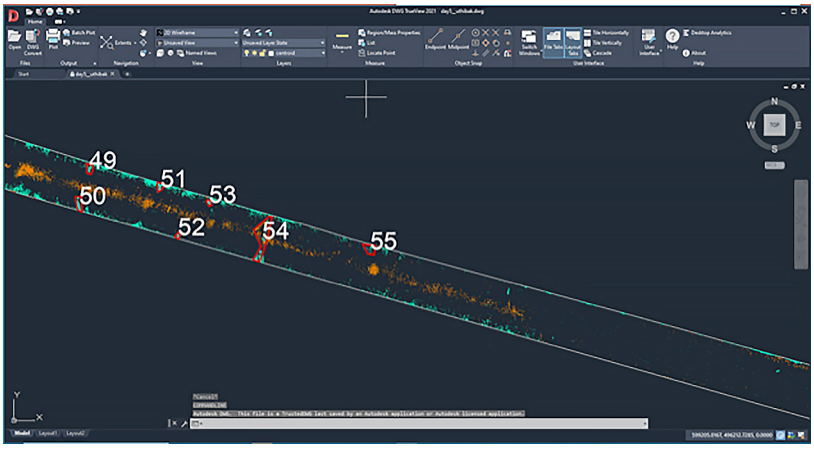
Izmjera je obavljena kao podloga planiranju dugoročne obnove kolodvora te kao podloga za kasnije upravljanje objektima. Izmjerom je prikupljeno više od 1200 TB podataka detaljnosti 1 cm (više od 20000 skenova terestričkim skenerima uz panoramske snimke). Svi podaci objedinjeni su u BIM model izrađen u Autodesk Revit softveru uglavnom u LOD100 (*eng. level of details*) i LOD200 razini detaljnosti, a kontrole podataka i modela koje su uključile geometrijske i semantičke kontrole te kontrole modela obavljene su u Navisworks i BIMcollab softverima. Detalji izrade BIM-a i izmjere prikazani su u Grgić i dr. (2023).

3.3. Praćenje cestovne infrastrukture duž Dunava (Viadonau, 2021.)

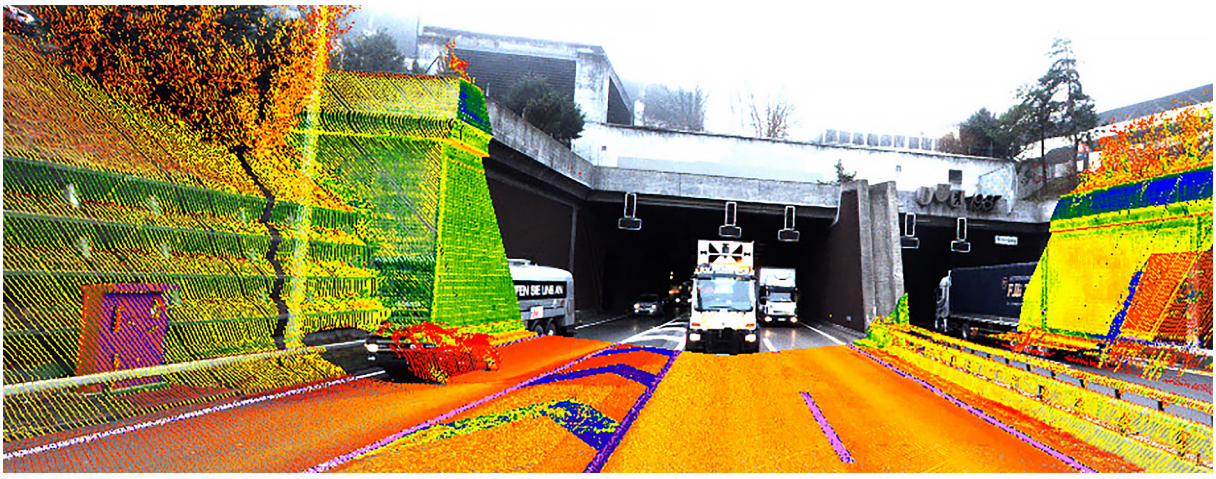
U nizu projekata, tijekom 2021. obavljen je projekt kartiranja i evidentiranja stanja putova (ceste i neasfaltirani putovi) mobilnim sustavima za izmjeru duž Dunava, od Passaua u Njemačkoj preko Beča u Austriji do Bratislave u Slovačkoj. Na 418 km dugoj trasi prikupljeno je više od 3 TB podataka koje čine oblaci točaka u rezoluciji 5 mm te više od 100.000 panoramskih snimaka. Stanje cesta evidentirano je automatskim metodama i primjenom strojnog učenja, ali i manualnim provjerama duž trase (Slika 6).

3.4. Praćenje cestovne infrastrukture u suradnji s tvrtkom ASFINAG (2020.)

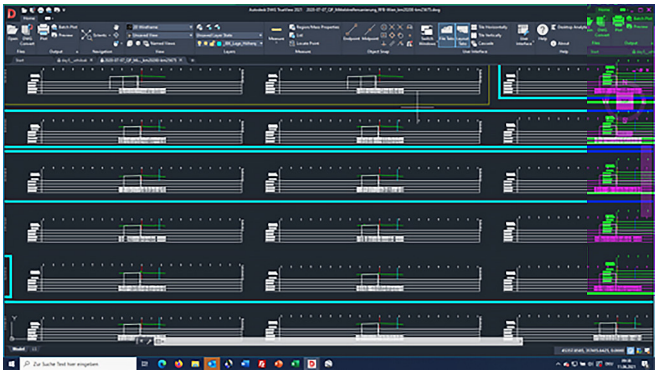
Tijekom 2020. mobilni sustav za izmjeru primijenjen je u projektu praćenja 40 km autocesta s austrijskom tvrtkom ASFINAG (Slika 7). Mobilni mjerni sustav Rie-



Slika 6: Manualne kontrole prikupljenih podataka o kvaliteti cestovne infrastrukture na trasi duž Dunava (Passau – Bratislava, Viadonau) (Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)



Slika 7: Mobilna izmjera austrijskih autocesta za detekciju površine cesta te prohodnosti i vegetacije koja utječe na odvijanje prometa (Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)



Slika 8. Analiza poprečnih profila kolnika (Izvor: arhiva tvrtke Meixner Vermessung ZT GmbH)

gl VMX-2HA ovdje je primijenjen za analizu kolnika, odnosno nagibe, oštećenja i slijeganja (Slika 8). Osim toga, podaci su primijenjeni za analizu prohodnosti za uvjete prijevoza izvanrednog tereta, posebno s obzirom na izgrađenu infrastrukturu, ali i vegetaciju kojom je infrastruktura okružena (Slika 8).

4. Zaključak

Na primjeru projekata izmjere tramvajske mreže grada Beča te praćenja cestovne infrastrukture duž Dunava i na austrijskim autocestama prikazana je primjenjivost mobilnih sustava izmjere za neovisnu i samostalnu izmjeru, uz određena ograničenja vezana uz ostvarivu točnost ovisno o uvjetima izmjere te brzini platforme na kojoj je mjerni sustav integriran.

Osim za samostalnu izmjeru, mobilni sustavi odlična su nadopuna većim projektima koji za dijelove projekta zahtijevaju nešto nižu razinu točnosti što je prikazano u projektu laserskog skeniranja i izrade BIM-a glavnog željezničkog kolodvora u Hannoveru u Njemačkoj. U takvim projektima mobilni su sustavi višestruko isplativiji i jednostavniji za primjenu čime ispunjavaju svoje osnovne karakteristike spomenute u uvodu – ekonomično i efikasno prikupljanje podataka. Zato će se za takve sustave u budućnosti, posebno uz daljnja poboljšanja hardvera i softvera, nalaziti i šire primjene.

Literatura

Alberti, F., Alessandrini, A., Bubboloni, D., Catalano, C., Fanfani, M., Loda, M., Paliotto, A. (2023): Mobile mapping to support an integrated transport-territory modelling approach. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 48, 1-7.

Corongiu, M., Masiero, A., Tucci, G. (2020): Classification of railway assets in mobile mapping point clouds. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 43, 219-225.

de Araújo Carvalho, M., Junior, J. M., Martins, J. A. C., Zamboni, P., Costa, C. S., Siqueira, H. L., Gonçalves, W. N. (2022): A deep learning-based mobile application for tree species mapping in RGB images. International Journal of Applied Earth Observation and Geoinformation, 114, 103045.

Di Stefano, F., Torresani, A., Farella, E. M., Pierdicca, R., Menna, F., Remondino, F. (2021): 3D surveying of underground built heritage: Opportunities and challenges of mobile technologies. Sustainability, 13(23), 13289.

Elhashash, M., Albanwan, H., Qin, R. (2022): A review of mobile mapping systems: From sensors to applications. Sensors, 22(11), 4262.

Glira, P., Ölsböck, K., Kadiofsky, T., Schörghuber, M., Weichselbaum, J., Zinner, C., Fel, L. (2022): Photogrammetric 3D mobile mapping of rail tracks. ISPRS Journal of Photogrammetry and Remote Sensing, 183, 352-362.

Grasso, N., Dabove, P., Piras, M. (2023): The use of SLAM and UAV technology in geological field for monitoring: the case study of the Bossea Cave. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 73-79.

Grgić, M., Geiger, J., Meixner, P. (2013): BIM - primjena prostornih podataka visoke rezolucije za učinkovito upravljanje infrastrukturom. V. Kongres o katastru u Bosni i Hercegovini, Neum, 2023.

Khoshelham, K., Zlatanova, S. (2016): Sensors for indoor mapping and navigation. Sensors, 16(5), 655.

Soilán, M., Sánchez-Rodríguez, A., del Río-Barral, P., Perez-Collazo, C., Arias, P., Riveiro, B. (2019): Review of laser scanning technologies and their applications for road and railway infrastructure monitoring. Infrastructures, 4(4), 58.

Xu, J., Ota, K., Dong, M. (2020): Big data on the fly: UAV-mounted mobile edge computing for disaster management. IEEE Transactions on Network Science and Engineering, 7(4), 2620-2630.

Integrated Mobile Measurement Systems for Mapping, Analysis, and Monitoring of Traffic Infrastructure

Abstract

Integrated mobile measurement systems enable economical and efficient collection of spatial data for the purpose of developing 3D smart cities, rapid response to natural disasters, development of autonomous vehicle management, etc., as well as performing standard geodetic surveying tasks. Such systems most often integrate LiDAR (Light Detection and Ranging) and high-resolution cameras with systems for tracking the position of the moving platform from which the measurement is performed - GNSS (Global Navigation Satellite Systems) and IMU (Inertial Measurement Unit) units. Through the intensive development and application of machine learning and artificial intelligence algorithms, the processing of data collected by mobile systems is often automated, and the results are available in real time. This paper presents the development and application of mobile systems for measuring, analyzing and monitoring the transport infrastructure through completed projects for monitoring cracks in the road infrastructure in Upper Austria, projects for measuring highways in Austria and Germany, and a project for mapping, analyzing and monitoring the tram infrastructure of the city of Vienna, primarily using Riegl VMX-2HA platform, but also other measuring methods. The paper also presents the integration of the data collected in this way for the expansion of the two-dimensional GIS (Geographic Information System) with 3D data and the development of BIM (Building Information Modeling).

Keywords: *3D GIS, BIM, LiDAR, mobile mapping systems, transport infrastructure monitoring*

Razvoj funkcionalnosti digitalnog blizanca na primjeru Grada Pule

Zvonimir Nevistić[1], Željko Bačić[1], Kristina Marković[2]

[1] Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, znevitic@geof.hr, zbacic@geof.hr

[2] Aerophoto ing, Faverijska ulica 7, Pula, Hrvatska, markovkristina@icloud.com

Sažetak

U današnje vrijeme, svjetska populacija ubrzano migrira u gradove i do 2050. godine 68 % stanovništva živjet će u gradovima. Time se stvara sve veća potreba za učinkovitim upravljanjem gradskim resursima i infrastrukturom. Uslijed ubrzanog trenda digitalizacije procesa planiranja, praćenja i upravljanja svim aktivnostima i resursima, kao rješenje za naglu urbanizaciju osmišljen je i razvija se koncept pametnih gradova. Pametni gradovi omogućuju bolje planiranje, upravljanje prometom, resursima i uslugama kako bi se zadovoljile potrebe korisnika i gradskih vlasti za učinkovitijem upravljanjem gradom. Uz koncept pametnih gradova pomoću kojega realiziramo planiranje i upravljanje, pored digitalnih senzora (Internet stvari) danas se sve više koristimo i tehnologijom digitalnih blizanaca. Digitalni blizanci predstavljaju virtualnu repliku fizičkih produkata, procesa ili sustava u svrhu boljeg donošenja odluka, razumijevanja, optimizacije i analiza tijekom čitavog životnog ciklusa proizvoda. Oni pronalaze sve širu primjenu te se koriste u gotovo svakom aspektu ljudskog djelovanja. Razvoj funkcionalnosti digitalnog blizanca na primjeru grada donosi brojne mogućnosti za poboljšanje učinkovitosti, održivosti i upravljanja urbanim područjima. Neki od ključnih aspekata razvoja funkcionalnosti digitalnog blizanca u kontekstu grada su upravljanje infrastrukturom, planiranje razvoja, upravljanje hitnim situacijama, praćenje i poboljšanje kvalitete životne sredine. U sklopu ovog rada opisane su aktivnosti uspostave modela digitalnog blizanca testnog područja grada Pule i razvoja mogućih primjena za poboljšanje kvalitete, sigurnosti i načina života u gradu Puli. Na osnovi razvijenih primjena (raspored stupova javne rasvjete, solarni potencijal krovova zgrada, optimizacija rasporeda uređaja video nadzora i drugo) provedene su različite analize, predikcije i simulacije korištenjem različitih softvera.

Ključne riječi: *digitalni dvojnici, primjena, Pula, urbanizacija*

1. Uvod

Danas u gradovima živi više od polovice svjetskog stanovništva, a dugoročne procjene ukazuju na daljnji trend urbanizacije s predviđanjima od 68 % posto urbanog stanovništva do kraja 2050. godine (UN, 2019). Iz tog razloga, međunarodna zajednica se od 2015. godine kroz niz sporazuma zalaže za provođenje politika održivog razvoja na globalnoj razini pri čemu se lokalne samouprave prepoznaju kao ključni partneri pri postizanju ciljeva (UN, 2020). Isto tako, na nacionalnoj razini donesena je Nacionalna razvojna strategija Republike Hrvatske do 2030. godine s naglaskom na razvoj pametnih i održivih gradova s ciljem jačanja regionalne konkurentnosti (NN, 2021). Sukladno trendovima, ključno je uvođenje suvremenih tehnoloških, logističkih i organizacijskih rješenja te stvaranje novog okvira urbanog razvoja čime će se osigurati održivi razvoj budućih gradova. Jedan od inovativnih koncepata upravljanja zajednicom je koncept pametnog grada koji podržava pametno upravljanje s ciljem stvaranja boljih usluga za gradske vlasti i stanovništvo. Implementacija koncepta olakšana je prodorom velikih količina podataka koji se prikupljaju, obrađuju, vizualiziraju i distribuiraju u gotovo realnom vremenu. S druge strane, realizacija je omogućena stvaranjem slike grada, replike stvarnog urbanog okruženja, što se danas materijalizira u kontekstu digitalnih blizanaca. Koncept digitalnih blizanaca pronalazi sve širu primjenu u modernom svijetu, a pogotovo u upravljanju gradovima s ciljem povećanja efikasnosti, ekonomičnosti, očuvanja okoliša i energetske učinkovitosti. Digitalni blizanci su primarni pokretači urbane digitalizacije te kao takvi ključni za postizanje navedenih strategija i ciljeva pametnog upravljanja i održivog razvoja. U ovom radu prikazan je postupak uspostave modela digitalnog blizanca testnog područja grada Pule i razvoja mogućih primjena za poboljšanje kvalitete, sigurnosti i načina života u gradu Puli. Ne testnom modelu provedena je analiza solarnog potencijala krovova zgrada te optimizacija rasporeda uređaja video nadzora u svrhu poboljšanja sigurnosti u gradu.

2. Pametni gradovi i digitalni bliznaci

Pametni gradovi relativno su novi koncept nastao kao odgovor na sve veći trend urbanizacije. Ne postoji je-

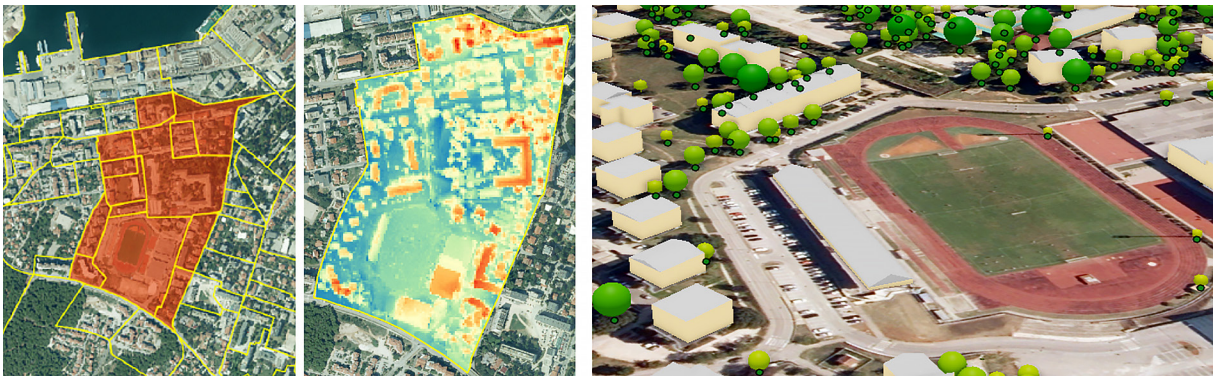
dinstvena definicija koncepta pametnog grada, a različite definicije identificiraju određene karakteristike koje mogu biti grupirane u nekoliko tematskih skupina koje čine grad pametnim (Nevistić i Bačić, 2022). Međunarodna unija za telekomunikacije (ITU) analizirala je više od stotinu različitih definicija pametnog grada, što je rezultiralo sljedećim: "Pametan održivi grad je inovativan grad koji koristi informacijske i komunikacijske tehnologije (ICT) i druga sredstva za poboljšanje kvalitete života, učinkovitosti urbanog grada i usluga te konkurentnosti, uz osiguravanje da zadovoljava potrebe sadašnjih i budućih generacija u pogledu ekonomskih, društvenih i ekoloških aspekata" (ITU, 2014). Prema Caragliu i dr. (2009) pametni grad se temelji na šest dimenzija: pametnoj ekonomiji, mobilnosti, okolišu, ljudima, pametnom življenju i upravljanju. Pametna ekonomija uključuje inovativnost, produktivnost i poduzetništvo; mobilnost karakterizira pristupačnost, dostupnost infrastrukture te održivi i sigurni prometni sustavi. Nadalje, pametni okoliš uključuje efikasnu brigu o resursima, smanjenje zagađenja okoliša te općenito održivi okoliš. Pod pametnim ljudima smatraju se e-vještine pojedinaca, rad u poslovima omogućenim ICT-om, pristup obrazovanju i obuci, upravljanje ljudskim resursima i kapacitetima, unutar društva koje poboljšava kreativnost i potiče inovacije. Nadalje, pametno življenje karakterizira bogati kulturni sadržaj, osigurana skrb, a sigurnost i kvaliteta života građana je na visokoj razini. Pametnu gradsku vlast (upravljanje) karakterizira jednostavnije donošenju odluka na temelju novih servisa i podataka prikupljenih senzorima, olakšano i povećano pružanje usluga građanima te političke strategije i razvojni planovi koji su održivi (Šain, 2022). Za uspješnu provedbu koncepta pametnog grada najvažnija je ICT tehnologija, odnosno senzori koji prikupljaju podatke o svim aspektima gradske sredine te na temelju kojih se omogućuju bolje analize i donošenje odluka. Senzori su povezani u jedinstvenu IoT (Internet of Things) mrežu bez koje ovaj koncept nije moguće realizirati. Uz navedeno, danas se sve više primjenjuje i tehnologija digitalnih blizanaca za poboljšanje upravljanja gradskim sredinama. Digitalni blizanac predstavlja digitalni prikaz koji sadrži opisne značajke odabranog objekta ili sustava proizvoda i usluga. Takav prikaz sadrži atribute, stanja i ponašanja objekta kroz modele, informacije i podatke u jednoj ili čak više faza životnog ciklusa (Stark i Damerau, 2019). Ovaj koncept može se primijeniti na mnogo razina, od medicine, svemirske tehnologije, autoindustrije, zrakoplovstva i drugih, a omogućuje digitalne replike objekata koje služe kao dinamički modeli koji reflektiraju stvarno stanje, ponašanje i rad stvarnog objekta u realnom vremenu. Dobiveni modeli mogu se koristiti za praćenje i nadzor, optimizaciju procesa i poboljšanja performansi, za simulacije, donošenje odluka, poboljšanje sigurnosti, edukaciju i dr. Kako takav, ovaj koncept primjenjiv je i na razini grada za uspješno praćenje, upravljanje, modeliranje i odlučivanje. Dok različiti upisnici osiguravaju podatke iz prošlosti, IoT senzori prikupljaju podatke iz sadašnjosti, digitalni blizanac pruža predikciju mogućih događaja iz budućnosti (Ruohomäki i dr., 2018).

3. Pula kao pametni grad

Kao testno područje za izradu modela digitalnih blizanaca i provođenje analiza odabran je grad Pula koji je 2008. godine uveo e-upravu, a danas je jedan od vodećih gradova s digitalnim uslugama za svoje građane. Osim e-uprave, omogućene su usluge e-vrtića, proračuna kojim se omogućuje informiranje javnosti o trošenju gradske imovine, e-račun, e-predmet za rješavanje upita gradskim vlastima te e-konzultacije putem kojih građani sudjeluju u donošenju odluka o razvoju grada (Tomašević, 2021). Temeljem Nacrta Akcijskog plana energetske učinkovitosti Grada Pule za period od 2022. do 2024. godine među provedenim analizama potrošnje energije i planiranim mjerama energetske učinkovitosti ističe se objekt Dom sportova Mate Parlov. Stoga, odlučeno je pristupiti uspostavi digitalnog blizanca četvrti u blizini navedenog objekta. Cilj je pokazati kako se uspostavom digitalnog blizanca i njegovih primjena može unaprijediti održivi razvoj grada i urbano planiranje (Marković, 2023). Uspostava obuhvaća izradu 3D modela na temelju dostupnih otvorenih podataka, podataka dobivenih od Državne geodetske uprave (DGU) i podataka ustupljenih od gradskih vlasti u Puli. Na dobivenom modelu provedene su određene simulacije za poboljšanje upravljanja gradskim resursima i sigurnosti u gradu.

3.1. Uspostava 3D modela

Kvalitetni digitalni 3D modeli urbanih područja temelj su razvoja digitalnih blizanaca gradova koji gradskim vlastima omogućuju poboljšanje provedbe raznih procesa od projektiranja, provođenja analiza, predikcija, optimizacije i urbanog planiranja. Za odabrano testno područje (Slika 1) izrada 3D modela temelji se na podacima Grada Pule, Upravnog odjela za komunalni sustav i gospodarenje imovinom i DGU-a. Svi dostupni podaci svedeni su na granice područja interesa. Na temelju aerofotogrametrijskih snimaka DGU-a (M 1:2000) izrađen je interpolirani digitalni model površine (DSM) i ortomozaik u Agisoft Metashape softveru. Nakon toga, u QGIS-u provedena je rasterska operacija razlike između dva generirana rastera, dobivenog DSM i DMR (digitalni model reljefa) ustupljenog od DGU-a. Dobiveni raster razlike ključan je za dobivanje apsolutnih visina zgrada u sloju normaliziranog digitalnog modela površine (nDSM) prikazanog na slici 1. Sljedeći korak uključuje pripremu i obradu prikupljenih vektorskih podataka zgrada, cesta i javne rasvjete, te shape datoteka granica područja. Svi ti podaci dobiveni su od Grada Pule. Na kraju je provedena izrada 3D modela na temelju pripremljenih podataka i naprednih algoritama ArcGIS Pro softvera. Dobiveni 3D model (Slika 1), na temelju kreiranog ortomozaika upotpunjen je prikazom stabala na odabranom području radi zornijeg prikaza stvarnog stanja. 3D modeli stabla izrađeni su *Detect Objects Using Deep Learning – Tree Detection* modulom unutar ArcGIS-a. Izrađena virtualna platforma može se koristiti za provođenje različitih analiza, procjena i simulacija određenih pitanja (Šain i dr., 2023).



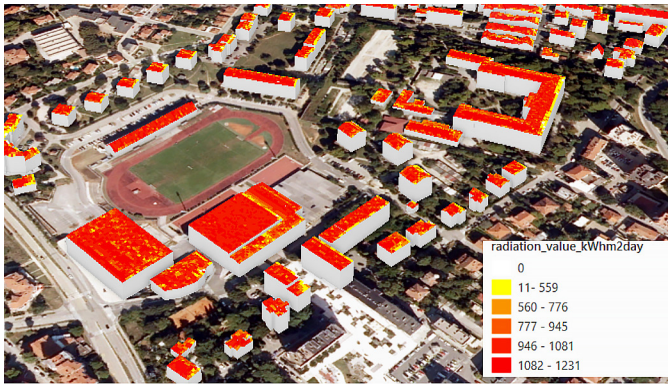
Slika 1: Prikaz testnog područja Grada Pule (lijevo), interpolirani nDSM model (sredina), 3D model testnog područja (desno) (Šain i dr. 2023)

3.2. Analiza solarnog kapaciteta

Na dobivenom 3D modelu testnog područja analizirani su krovovi i kapacitet postavljanja solarnih ćelija te izračun maksimalnog kapaciteta energije solarnih ćelija. Solarne ćelije predstavljaju jedan od efikasnih načina doprinosa očuvanju okoliša. Ovi obnovljivi izvore energije nude znatan potencijal globalne primjene kao zamjena za fosilna goriva, koja igraju ključnu ulogu u globalnom zatopljenju. Analiza je rađena u softveru ArcGIS Pro gdje je definirana nova lokalna scena koja sadrži DSM kao referentnu podlogu za provođenje analiza te je provedeno sjenčanje radi zornijeg prikaza objekata i visina. Koristeći alat *Area Solar Radiation* dobivena je procjena solarnog zračenja na krovovima zgrada. Ovaj alat koristi DSM, informacije o suncu i lokalne geografske podatke kako bi procijenilo koliko sunčeve energije dolazi na određeno područje tijekom različitih vremenskih perioda. Period izračuna postavljen je na 2023. godinu svakih sat vremena. Rezultat toga je rasterski sloj koji prikazuje solarnu radijaciju izraženu u Wh/m2. Da bi se olakšao daljnji proračun, korištena je *Raster Calculator* funkcija za preračunavanje vrijednosti u kWh/m2. Konačni raster (Slika 2) prikazuje količinu sunčevog zračenja za 2023. godinu u kWh/m2 diferencirano u žutoj skali boja od svjetlije sa slabijim i tamnije (narančaste) s jačim zračenjem. Analiza rezultata pokazuje da su južni dijelovi krovova izloženi većem solarnom zračenju, stoga je orijentacija prema Suncu ključni faktor pri postavljanju ćelija. Svjetlije nijanse piksela pojavljuju se zbog prisutnosti sjena ili prepreka, koje mogu biti različite prirode (drveće, građevine i dr).

Osnovna tri kriterija za postavljanje solarnih panela su nagib, količina solarnog zračenja i orijentacija prema Suncu. Prikladni krovovi trebaju imati nagib do 45° i prikupljati barem 850 kWh/m2 zračenja. Kako bi se dobile prikladne lokacije za postavljanje solarnih ćelija, izrađen je dodatan sloj orijentacije i nagiba s DSM-om kao ulaznim rasterom. Naredbom *Aspect* i *Slope* generirani su nagibi terena i smjer pada terena. Konačni raster (Slika 3) dobiven je *Con* modulom u kojem su postavljeni uvjeti nagiba do 45°, smjera pada terena (22.5° – 337.5° azimuta) i količine zračenja iznad 850 kWh/m2. Također, uvjet je postavljen da uzima u obzir sve krovove s nagibom manjim od 10 stupnjeva (neovisno o orijentaciji) kako bi se uzeli u obzir ravni krovovi koji su pogodni za postavljanje ćelija. Bijele boje na rasteru ukazuju na nezadovoljavanje kriterija za postavljanje solarnih panela.

Također, proveden je i izračun maksimalnog kapaciteta energije gdje je prvo bilo potrebno grupirati solarne ćelije prema površini koju one zauzimaju te zatim izračunati prosječnu količinu sunčeve radijacije pomoću alata *Zonal Statistics as Table*. Rezultat je atributna tablica koja sadrži informacije o ukupnom broju prikladnih ćelija, površini koju te ćelije pokrivaju i prosječnoj količini radijacije u kWh/m2. Uveden je i novi kriterij za odabir prikladnih zgrada tako da su identificirane sve zgrade čija je ukupna površina po-



Slika 2: Količina sunčevog zračenja u kWh/m2 na testnom području (Marković, 2023)



Slika 3: Pogodna područja za postavljanje ćelija (lijevo), potencijal proizvodnje električne energije (desno) (Marković, 2023)

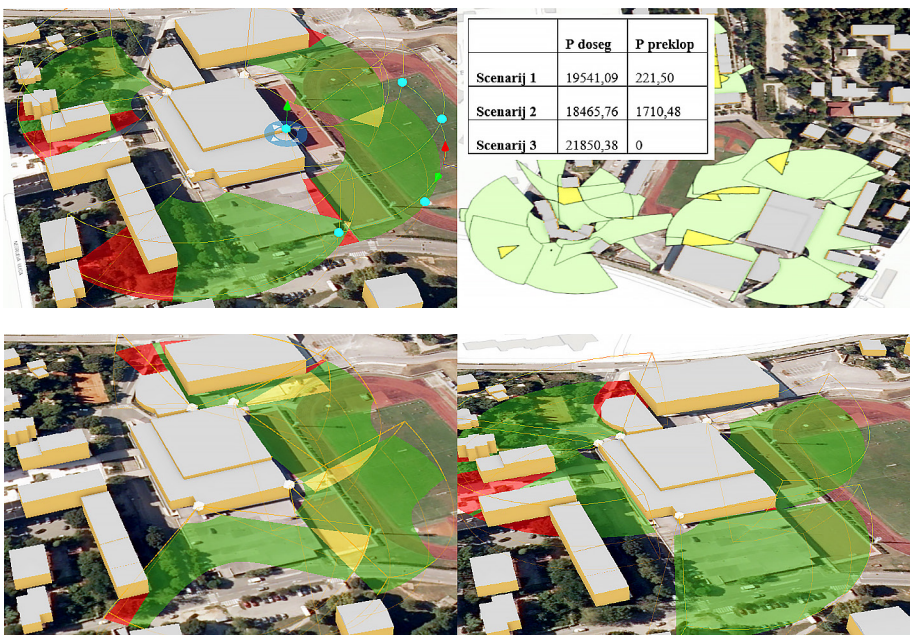
krivena prikladnim ćelijama veća od 30 m², a u tablicu je dodano novo polje s informacijama o ukupnoj godišnjoj količini radijacije koju prikupi iskoristiva površina svake zgrade što je poslužilo za izračun potencijala proizvodnje električne energije. Radi bolje usporedbe dobivenih podataka i njihove vizualizacije prikazane na Slici 3, proizvodnja električne energije izračunata je i prema formuli (Gorički i dr., 2017):

$$\frac{e}{m^2} = \frac{solar * Vsunce}{Vdan * efikasnost}$$

gdje je e/m² proizvedena električna energija iz solarnih panela po metru kvadratnom, solar predstavlja količinu solarnog zračenja, Vsunce prosječan broj sunčanih sati na području grada Pazina preuzet s DHMZ (2317.4 h), Vdan broj sati dnevnog svijetla u jednoj godini (4380 h), a efikasnost energetsku učinkovitost solarnih panela 15-20%.

3.3. Video nadzor prostora

Jedna od mogućnosti povećanja sigurnosti građana, ali i prometa u pametnim gradovima je postavljanje nadzornih kamera. Pri odabiru nadzorne kamere, ključnu ulogu ima razlučivost. Kamera odabrana za potrebe ovog istraživanja je model *DH-IPC-HDW5831R-ZE* s visokom razlučivošću od 8 MP, namijenjenoj za postavljanje na otvorenom prostoru te za neprekidno praćenje i snimanje danju i noću. Budući da ArcGIS Pro ima površinsko ograničenje za postavljanje *Viewshed* analiza (analiza vidljivosti), odabrana je mikrolokacija unutar JZ dijela testnog područja za provođenje analize postavljanja nadzornih kamera. U *Viewshed* modulu postavljeni su parametri dometa kamere prema specifikacijama odabrane kamere. Tijekom postavljanja kamera, prikazuju se tri različite boje: zelena označava područje koje je vidljivo kamerom bez preklapanja, crvena označava područje koje nije vidljivo iz tog položaja kamere, dok žuta



Slika 4: Prikaz scenarija 1 (gore lijevo), scenarija 2 (gore desno), scenarija 3 (dolje lijevo) postavljanja video nadzora te Površinske vrijednosti postavljenog nadzora (dolje desno)

boja ukazuje na područje koje se preklapa s drugim kamerama. Na odabranoj mikrolokacija kod Doma sportova Mate Parlov, kamere su postavljene u tri različita scenarija kako bi se odredio optimalan položaj kamera te se postigla maksimalna pokrivenost područja u svrhu povećanja sigurnosti prometa i građana. U prvom scenariju (Slika 4), kamere su postavljene s nagibom od 0°, a ovakav raspored kamera rezultira velikim nepokrivenim područjem, unatoč tome što svaka kamera ima široko vidno polje. Rješenje za ovu situaciju je ili dodavanje više kamera ili promjena njihovog nagiba. U drugom scenariju (Slika 4) kamere su postavljene u rasponu nagiba između -15° i -30° te je na taj način dobivena bolja pokrivenost promatranog područja uz rubove objekta, ali je smanjen doseg kamere, dobiveno je više preklapanja kamera i cijeli zapadni dio objekta ostao je nepokriven. U trećem scenariju (Slika 4) dolazi do ne preklapanja kamera, što ga čini. Većinski dio je uspješno pokriven te je samo mali dio područja ostao bez nadzora. Raspon smjera kamere kreće se od 72° do 327°, dok je nagib postavljen između -9° i -26°.

Za svaku poziciju kamere, stvoreni su poligoni koji predstavljaju pokrivenost kamere i poligoni koji označavaju njihovo preklapanje (Slika 4) oko objekata od interesa. Na temelju razlike između tih poligona, izračunate su površine pokrivenosti. Usporedbom numeričkih i grafičkih rezultata zaključujemo kako je na otvorenim prostorima poput parkova, trgova i sličnih mjesta, potreban manji broj kamera kojima postižemo iste ili čak veće površinske pokrivenosti, dok primjerice, na izgrađenim lokacijama, smanjenjem raspona kamere i smanjenjem ukupne pokrivenosti, povećavamo nadzor nad okolnim područjem objekta od interesa. Demonstrirani primjeri ukazuju kako se digitalni blizanac može efikasno primijeniti u fazi projektiranja video nadzora čime se štedi vrijeme, resursi i postižu maksimalni efekti.

4. Zaključak

Razvoj funkcionalnosti digitalnih blizanaca u gradovima donosi značajne prednosti i obećava transformaciju načina na koji gradovi upravljaju infrastrukturom, resursima i pružaju usluge svojim stanovnicima. Uspostava ovog koncepta omogućava poboljšanu učinkovitost i planiranje gdje digitalni blizanci omogućavaju gradskim vlastima da bolje razumiju kako se koristi infrastruktura te da planiraju njihovo unapređenje učinkovitijim pristupima što dovodi do smanjenja troškova i boljeg iskorištavanja resursa. Također, digitalni blizanci pružaju sposobnost brze reakcije na krizne situacije kao što su prirodne katastrofe, prometne nesreće ili pandemije. Osim toga, omogućavaju simulacije kako bi se unaprijed predvidjele i pripremile reakcije na potencijalne krizne situacije. U ovom radu je prikazano kako se na modelu digitalnog blizanca grada Pule jednostavno može provesti analiza ugradnje i učinkovitosti solarnih ćelija u svrhu uštede potrošnje energije te kako provesti analizu postavljanja nadzornih kamera za podizanje sigurnosti građana i prometa u dijelovima grada. Digitalni blizanci u gradovima imaju potencijal značajno unaprijediti kvalitetu života stanovnika, potaknuti održivi razvoj i pomoći gradskim vlastima u donošenju informiranih odluka.

Literatura

Caragaliu, A., Del Bo, C. i Nijkamp, P. (2009): Smart Cities in Europe, Journal of Urban Technology, 18 (48), 45-59.

Gorički, M., Poslončec-Petrić, V., Frangeš, S., Bačić, Ž. (2017): Analysis of Solar Potential of Roofs Based On Digital Terrain Model, Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLII-4/W3, 37–41.

International Telecommunicatin Union (ITU-T) (2014): Smart sustainable citites: An analysis of definitions. ITU-T Focus Group on Smart Sustainable Cities. Tecnical Report.Geneva.

Marković, K. (2023): Razvoj funkcionalnosti digitalnog blizanca na primjeru grada Pule, Diplomski rad, Geodetski fakultet, Sveučilište u Zagrebu.

Narodne novine (NN) (2021): Nacionalna razvojna strategija Republike Hrvatske do 2030. godine, Zagreb: Narodne novine d.d., 13.

Nevistić, Z., Bačić, Ž. (2022): The Concept, Realizations and Role of Geosciences in the Development of Smart Cities, Tehnički vjesnik, 29 (1), 330-336.

Ruohomäki, T., Kesäniemi, O., Airaksinen, E., Martikka, M., Huuska, P., Suomisto, J. (2018): Smart City Platform Enabling Digital Twin, 2018 International Conference on Intelligent Systems (IS), 155-161.

Stark R., Damerau T. (2019): Digital Twin, CIRP Encyclopedia of Production Engineering, Springer: Berlin, Heidelberg, 1-8.

Šain, L. (2022): Primjena digitalnog blizanca u upravljanju gradovima na primjeru Grada Pule, Diplomski rad, Geodetski fakultet, Sveučilište u Zagrebu

Šain, L, Nevistić, Z., Bačić, Ž. (2023): Application of Digital Twin in City Management, ICEOGI 2023. Online: IEEE Xplore, 2023.

Tomašević, T. (2021): Analiza karakteristika gradova u Hrvatskoj i primijenjenih pametnih rješenja, Diplomski rad, Sveučilište u Splitu, Ekonomski fakultet.

United Nations (UN) (2019): World Urbanization Prospects: The 2018 Revision (ST/ESA/SER.A/420), New York: United Nations.

United Nations (UN-Habitat) (2020): The Value of Sustainable Urbanization, Nairobi: UN- Habitat.

Development of Digital Twin Functionality Based on the Example of the City of Pula

Abstract

Nowadays, the world's population is rapidly migrating to cities and by 2050, 68 % of the population will live in cities. This creates an increasing need for efficient management of city resources and infrastructure. Due to the accelerated trend of digitalization of the planning process, monitoring and resource management, the concept of smart cities was designed as a solution for urbanization. Smart cities can enable better planning, traffic management, and services for citizens and authorities. With smart city concept, with which planning, and management can be realized, in addition to sensors (Internet of Things), today we increasingly use the digital twins technology. Digital twins represent a virtual replica of physical products, processes or systems for the purpose of better decision-making, understanding, optimization and analysis during the entire product life. They can be used in every aspect of human activities. The development of the city digital twin brings numerous opportunities for improving the efficiency, sustainability and management of urban areas. Some of the key aspects of developing digital twin in a city context are infrastructure management, development planning, emergency management, environmental quality monitoring and improvement. This paper presents the establishment of a digital twin model of the test area of the city of Pula and the development of possible applications for improving the quality and safety. Based on the developed applications (arrangement of public lighting, solar potential of building roofs, optimization of the video surveillance devices, etc.), various analyses, predictions and simulations were carried out using different software.

Keywords: *application, digital doubles, Pula, urbanization*

Umjetna inteligencija u planiranju mreže 5. generacije

Vedran Vrhovac[1]

[1]Ericsson Nikola Tesla, Krapinska 45, Zagreb, Hrvatska, vedran.vrhovac@ericssonnikolatesla.com

Sažetak

Planiranje mobilnih mreža 5. generacije izazovan je zadatak, posebice u urbanim sredinama. Zbog specifičnosti 5G tehnologije, koja koristi kraće valne duljine, potrebno je gušće postavljanje antena za održavanje kvalitete signala. U tu svrhu, prostorni podaci visoke razlučivosti postaju ključni za identifikaciju optimalnih lokacija za postavljanje antena. Tradicionalne metode prikupljanja takvih podataka vremenski su zahtjevne i često preskupe. Problemu se može doskočiti korištenjem umjetne inteligencije u sprezi s daljinskim prikupljanjem podataka. Sinergija ovih dviju tehnologija uvelike ubrzava i olakšava planiranje infrastrukture za telekomunikacijske mreže nove generacije. Primjena umjetne inteligencije omogućava efikasnije skupljanje i analizu prostornih podataka, omogućujući stvaranje detaljnih 3D modela urbanog okruženja koji se koriste za planiranje mrežne infrastrukture. Korištenjem AI (umjetna inteligencija), moguće je automatizirano prikupljati podatke o terenu, zgradama, vegetaciji i drugim relevantnim obilježjima koji su neophodni za ovo planiranje. Osim što AI značajno ubrzava proces, ona također omogućava skaliranje ovih aktivnosti na veća geografska područja bez proporcionalnog povećanja resursa potrebnih za obradu podataka. Umjetna inteligencija ne samo da pruža tehničku podršku u optimizaciji prostornih podataka, već i transformira način na koji organizacije pristupaju planiranju i implementaciji složenih infrastrukturnih projekata. Ova tehnološka sinergija između AI i prostornih podataka stvara nove mogućnosti za inovacije i efikasnost, čineći urbanu i telekomunikacijsku infrastrukturu sposobnijom da zadovolji rastuće zahtjeve modernog društva.

Ključne riječi: *strojno učenje, daljinska istraživanja, istraživanje objekata, obrada podataka*

1. Uvod

Pristup internetu danas je neizbježna stavka ekonomskih i privatnih aktivnosti. Internet danas koristimo za neformalnu komunikaciju, pristup društvenim mrežama, ali i za poslovnu korespondenciju, izvršavanje narudžbi i provođenje bankovnih aktivnosti. Zbog svoje fleksibilnosti on je postao danas kralježnica gospodarstva i kvalitetna mrežna povezanost je nužnost i razina usluge koju korisnici očekuju.

Osim što je internet početkom 21. stoljeća počeo prožimati ekonomske aktivnosti, pojavom pametnih telefona prije 20 godina promijenio se način na koji mu pristupamo. Umjesto bakrene parice ili optičkog kabla, medij za prijenos podataka postale su mobilne mreže 2. i 3. generacije koje su kasnije evoluirale u mreže 4. generacije. Sveprisutnost takvih mreža omogućila je brzo spajanje na internet pametnim telefonima što je pak potaknulo rast društvenih mreža i streaming usluga.

1.1. Mreže 5. generacije

Rast broja korisnika pametnih telefona pratio je rast kompleksnosti usluga koje se koriste na internetu. Kako dostupni kapaciteti mobilnih mreža ne bi bili zagušeni, 2019. započet je prelazak na mreže 5. generacije. Za razliku od prethodnih generacija mobilnih mreža, koje su bile evolucija, nova generacije mobilnih mreža je revolucija. Frekvencijski spektar je proširen iz postojećeg 800 / 900 MHz, tj. 1.800 / 2.600 MHz te on u mrežama 5. generacije obuhvaća od 3.800 MHz do 26 GHz. Više frekvencije mobilnost signala nude veću propusnost i niže latencije, što u konačnici rezultira boljim korisničkim iskustvom u korištenju Interneta.

Korištenje kraćih valnih duljina pred operatere mreže 5. generacije postavilo je nove zahtjeve prilikom njihovog projektiranja. Signal kraćih valnih duljina osjetljiviji je na fizičke prepreke u vidu građevina, (zbog smanjenog ogiba), reljefa, vegetacije, kao i na prisutnost vode u zraku (kiša ili magla).

Prigušenju signala se doskače postavljanjem veće broja antena, geometrijom te kombiniranjem signala kraćih i dužih valnih duljina. Povećanje broja antena iziskuje od operatera velike troškove izgradnje infrastrukture te se očekuje kako će globalno prebacivanje na mreže 5. generacije rezultirati ulaganjima od oko 2.000 milijardi američkih dolara. Kako bi se ti troškovi sveli na optimalnu razinu, operateri prije ulaganja provode detaljne analize kako bi se antene postavile na optimalne lokacije i na taj način postigao kompromis između kvalitete usluge i troškova ulaganja.

2. Uloga prostornih podataka u projektiranju mobilnih mreža

Zbog osjetljivosti mreže 5. generacije na prepreke u prostoru, prikupljanje opširnih prostornih podataka prije projektiranja mreže postao je obavezan zadatak. Od prostornih podataka koji se koriste očekuje se da su kvalitetni, ažurni i visoke rezolucije.

Prije početka projektiranja potrebno je pribaviti podatke o reljefu, u vidu DTM-a (digitalnog modela terene), visinama i vrstama prepreka, načinima korištenja zemljišta i položaju prometnica (Geodata team, Ericsson, 2020). Svi ti podaci stapaju se u podatak koji se naziva visina prepreka, a koji je u svojim karakteristikama sličan DSM-u (digitalnom modelu površine).

2.1. Digitalni model terena

Digitalni model terena potreban za projektiranje prikuplja se stereoparova zračnih i satelitskih snimaka rezolucije 0,3 do 1,0 m ili iz podataka LIDAR-a. Za gusta urbana područja poželjni su podaci sa snimaka do 0,5 m rezolucije koji će rezultirati DTM-om rezolucije 1,0 m. Za rjeđa urbana područja od DTM-a se očekuje rezolucija 5,0 m. DTM se isporučuje kao raster, GeoTIFF, u kojem pojedini pikseli predstavljaju nadmorsku visinu prema geoidu EGM96.

Tablica 1: Specifikacija točnosti DTM-a (Geodata team, Ericsson, 2020)

Rezolucija	Horizontala točnost	Vertikalna točnost	Izvor podataka
1,0 m	+/- 3,0 m	+/- 3,0 m	Stereoparovi rezolucije do 0,5m, LIDAR
5,0 m	+/- 5,0 m	+/- 5,0 m	Stereoparovi rezolucije do 1,0m, LIDAR

2.2. Građevine i vegetacija

Za planiranje lokacija antena neophodan je podatak o položaju građevina, a poželjni su podaci o vegetaciji (krošnjama stabala).

Podaci o zgradama se prikupljaju u razini LOD1 i pritom se uzima najviša točka zgrade kao visina poligona. Podatak o visini zgrade se prikuplja kao nadmorska visina najviše točke zgrade i relativna visina najviše točke nad terenom. Podaci o zgradama se prikupljaju u vektorski sloj, kao 3D poligoni, a za potrebne finalnog modela se pretvaraju u raster s visinskom predstavom.

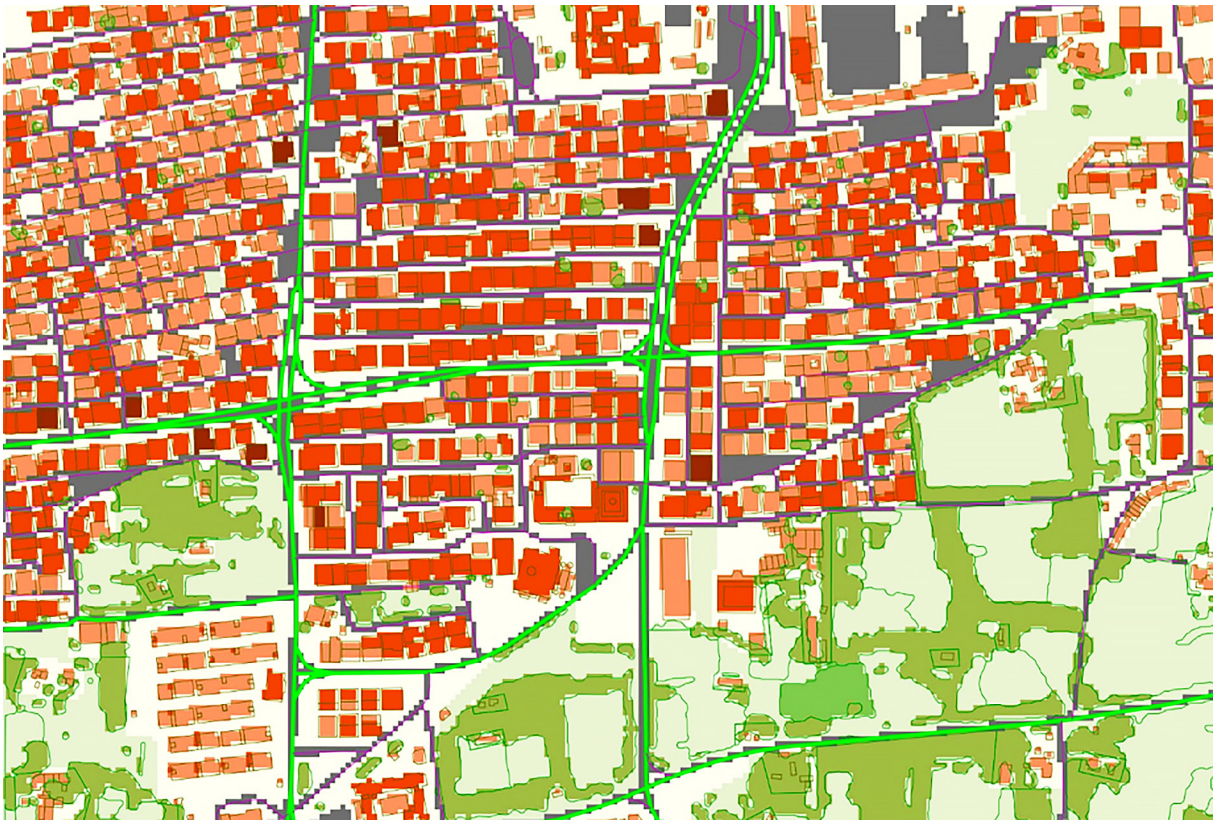
Vegetacija se predstavlja kao poligon s opsegom krošnje, a za najvišu točku poligona se uzima najviša točka krošnje. Za vegetaciju u manje kritičnim područjima moguće je koristiti generičke modele stabala tipičnih za područje projektiranja.

Tablica 2: Specifikacije za kartiranje podataka o građevinama i stablima (Geodata team, Ericsson, 2020)

Rezolucija	Horizontalna točnost	Vertikalna točnost	Minimalna površina objekta / krošnje stabla	Minimalna visina objekta / krošnje stabla	Izvor podataka
1,0 m	+/- 3,0 m	+/- 3,0 m	16 m^2	3 m	Stereoparovi rezolucije do 0,5m, LIDAR
5,0 m	+/- 5,0 m	+/- 5,0 m	25m^2	5 m	Stereoparovi rezolucije do 1,0m, LIDAR

2.3. Podaci o pokrovu zemljišta

Prigušenje signala uvjetovano je pokrovom zemljišta. Radiosignal se ne reflektira jednako od suhe, čvrste površine (asfalt, beton, stjenovito tlo) i vodene površine ili mokre livade. Iz tog razloga bitno je prikupiti podatke o načinu korištenja, tj. njegovom pokrovu, kako bi model propagiranja signala bolje predvidio jačinu signala.



Slika 1: Salalah (Oman), kartografski prikaz visina prepreka u prostoru (Geodata for 5G networks, 2020) (Geodata team, Ericsson, 2020.)

Pokrov zemljišta se dijeli na sljedeće kategorije (Geodata team, Ericsson, 2020):

1. Izgrađeno zemljište (zemljište pod objektima)
2. Otvorene suhe površine (stjenovito tlo, golo tlo, pješčana plaža)
3. Parkovi s niskom vegetacijom (travnjak s pretežito grmolikim biljkama)
4. Parkovi s visokom vegetacijom (travnjak s visokim, razvijenim stablima)
5. Rijetka šuma
6. Gusta šuma
7. Poluotvoreno područje (makija prošarana travnjacima)
8. Otvorena urbana područja (trgovi, parkirališta, široke prometnice)
9. Vodene površine (jezera, mora, rijeke).

Važno je napomenuti kako se kategorija izgrađeno zemljište dijeli u potkategorije ovisno o prosječnoj visini građevina.

Podaci o pokrovu zemljišta evidentiraju se kao RGB GeoTIFF datoteka. Svaka pojedina boja u rasterskoj datoteci odgovara pojedinoj kategoriji ili potkategoriji korištenja zemljišta.

2.4. Prometnice i linearne pojave

Prometnice i linearne pojave se evidentiraju u vektorsku datoteku. Svaka kategorija prometnica i linearnih pojava čini zasebnu vektorsku datoteku. Kako su vrste prometnica i pojava specifične ovisno o terenu, ne postoji njihova jasna kategorizacija već se ona određuje na početku projekta. Najčešće kategorije su (Geodata team, Ericsson, 2020):

1. Autoceste i glavne prometnice
2. Prometnice od lokalnog značaja
3. Ulice
4. Željeznica
5. Zračna luka
6. Obala jezera
7. Obala mora
8. Rijeke i potoci
9. Administrativne granice

2.5. Digitalni ortofoto

Na temelju ulaznih podataka (stereoparovi) i njihovih derivata (DTM, linearne pojave i prometnice) izrađuje se digitalni ortofoto. Njegova svrha je kontrolna, kako bi se kasnije izvršila provjera kvalitete prikupljenih podataka.

3. Prikupljanje podataka

Iz prethodnih poglavlja vidljivo je kako su za planiranje mreže 5. generacije potrebni opsežni i kvalitetni prostorni podaci. Klasične metode prikupljanja podataka omogućavaju prikupljanje od 10 do 50 km^2

tjedno, ovisno o kompleksnosti urbanog područja. Ukoliko na kartiranom području prevladaju tipizirani objekti i planska gradnja, prikupljanje podataka je olakšano, jer je moguće koristiti generičke, tipizirane objekte. Za urbane prostore koje odlikuje organski rast, velika većina objekata je unikatna po formi i položaju u odnosu na druge objekte. Kartiranje takvih urbanih sredina, posebice gustih gradskih jezgri, radno je zahtjevan i spor proces.

Prilikom izrade modela moguće se poslužiti javno dostupnim prostornim podacima, poput službenih DTM-ova, baza podataka o objektima i pokrovima zemljišta. Dostupnost takvih podataka uvelike ubrzava i olakšava pripremu ulaznih podataka za model propagacije radiosignala.

Najveći izazovi su u zemljama u razvoju, gdje su prisutne velike urbane sredine, ali bez uređenih državnih evidencija prostornih podataka. U Africi postoje urbane sredine površine veće od 1.000 km^2 s neplanskom gradnjom i velikom gustoćom objekata. U takvim situacijama prikupljanje podataka klasičnim metodama je veliki financijski i vremenski teret. Uz brzinu prikupljanja podataka od 10 km^2 tjedno, za velike urbane sredine bilo bi potrebno 2 godine rada. Rješenje za takve situacije je korištenje strojnih algoritama.

4. Neuronske mreže i prepoznavanje objekata

Neuronske mreže su forma strojnog učenja u kojem računalni algoritam oponaša rad neurona u mozgu. Postoji više vrsta neuronskih mreža, a za rad s prostornim podacima čiji je ulaz u rasterskom obliku pogodne su konvolucijske neuronske mreže. Zbog svojih karakteristika često se opisuju kao forma „računalnog vida".

Konvolucijske neuronske mreže rade na principu razbijanja rasterskog podatka na osnovne elemente pomoću jezgre (eng: *kernel*). Jezgra se definira kao polje od 3x3 ili više piksela, koje potom „šeće" po rasterskom podatku i uzrokuje ga. Prilikom svakog uzorka, računa se vrijednost jezgre i množi s aktivacijskom funkcijom. Kod konvolucijskih neuronskih mreža te funkcije su linearne rektificirane, a koriste se kako bi se izbjegli rezultati s negativnim vrijednostima. Naime, linearna rektificirana funkcija koristi samo pozitivni dio argumenta.

Osim što se definira veličina jezgre za uzorkovanje, u konvolucijskim mrežama definira se i brzina šetnje po rasteru. Kolika će ta brzina biti, opet ovisi o tome koliko je potreban detaljan izlazni podatak. U slučaju da želimo najveću detaljnost, jezgra će se šetati koracima od 1 piksela, što znači kako će kod jezgre 3x3 piksela, u sljedećem koraku 6 od tih 9 piksela biti ponovno uzorkovan. Uz veličinu koraka šetnje, moguće je definirati i obrub, tj. koliko piksela od ruba rasterskog podatka jezgra za uzorkovanja će preskočiti kako se ne bi utjecalo na izlazni podatak (URL 1).

Šetnjom jezgre po rasteru moguće je prikupiti samo specifične podatke pa je potrebno izvršiti više iteracije algoritma. Tako u prvoj iteraciji algoritam može prikupiti linijske podatke, potom krivulje pa točkaste i tako nastaviti dok se analiziraju svi elementi rasteri.

4.1. Treniranje neuronske mreže

Kako bi neuronska mreža odradila svoj posao sa zadovoljavajućom pouzdanošću, potrebno ju je naučiti na primjeru ulaznih podataka. Za tipičan projekt kartiranja grada za potrebe projektiranja mreže 5. generacije poželjno je uložiti oko tjedan učenja. O kvaliteti učenja algoritma direktno ovisi kvaliteta izlaznog podatka (URL 2).

Učenje neuronske mreže može se skratiti ako je koristimo na području koje dijeli slična geografska i urbanistička svojstva. Za Hrvatsku je dodatno učenje minimalno jer je arhitektura ujednačena na cijelom prostoru i potrebno je samo manje dodatno vrijeme utrošiti kako bi se model naučio na razlike u pokrovu zemljišta (npr. na kamenjar i makiju uz obalu i unutrašnjost Dalmacije).

Intenzivnije učenje modela je potrebno kada se radi kartiranje objekata koja ne dijele geografska i urbanistička svojstva. Geografija prostora u zemljama u razvoju, koje su najčešće tropske ili pustinjske, razlikuje se u znatnoj mjeri zbog različite vegetacije ili čak izostanka iste.

Razlike u arhitekturi i urbanizmu su još izraženije od geografskih. Algoritmi najlakši zadatak imaju sa planskom, tipiziranom gradnjom kakvu pronalazimo u predgrađima gradova u Sjevernoj Americi. U istočnoj Aziji je arhitektura specifična po tome što su krovovi, za razliku od Europe i Sjeverne Amerike, najčešće plavi. U Africi i Južnoj Americi su pak prisutne siromašne četvrti s kaotičnom arhitekturom, velikom gustoćom objekata i različitim materijalima gradnje.

Neuronska mreža može postići pouzdanost kartiranja objekata od 85 – 90%. S vremenom će ta pouzdanost rasti, ali već sada je dovoljno dobra. Prilikom kartiranja objekata za mreže 5. generacije bitnije je da neuronska mreža ne „preskoči" visoke građevine, dok izostanak manjeg udjela niskih građevina ili krošanja stabala je nešto što ne utječe toliko na samo projektiranje.

Neuronske mreže imaju prednost nad manualnim prikupljanjem podataka jer osim što rade u vidljivom dijelu spektra, moguće ih je koristiti na multispektralnim snimcima (npr: RGB-NIR) kako bi se olakšalo prepoznavanje objekata, a naročito načina korištenja zemljišta. Neuronske mreže omogućile su ubrzanje od 2 do 5 puta u odnosu na klasične metode prikupljanja podataka uz smanjene operativnih troškova (URL 3).

4.2. Radar sa sintetičkom aperturom (SAR)

Budućnost kartiranja objekata putem neuronskih mreža vjerojatno su snimci radara sa sintetičkom aperturom (objektivom). Radarske snimke su u prednosti jer nude podatak o visini, bolji kontrast i bolju filtraciju podataka. Uz sve to, na temelju polarizacije povratnog signala moguće je odrediti pokrov zemljišta, radi li se o travnjaku, jezeru, tresetištu ili mokroj

livadi. Nedostatak radarskih snimaka je što pate od perspektivnih distorzija pa je obavezno korištenje tomografskih snimaka, tj. radarskih snimaka iz više perspektiva kako bi se distorzije eliminirale. Prema preliminarnim istraživanjima, neuronske mreže na tomografskih radarskim snimcima rade 10x brže nego na tipičnom RGB rasterskom aerosnimku (URL 2).

5. Zaključak

Planiranje mreže 5. generacije zahtijeva opsežne i kvalitetne prostorne podatke, što predstavlja izazov posebno u gustim, urbanim sredinama. Projektiranje mreže bez kvalitetnih prostornih podataka može uzrokovati veće troškove i smanjenu funkcionalnost mobilne mreže. Tradicionalne metode prikupljanja podataka su vremenski intenzivne i posljedično skupe, posebice kada se primjenjuju u zemljama u razvoju, gdje ne postoje već uspostavljene baze prostornih podataka. U takvim situacijama korištenje naprednih algoritama i strojnog učenja u vidu neuronskih mreža, posebice konvolucijskih neuronskih mreža koje su se pokazale kao najbolji izbor za različite forme računalnog vida. Neuronske mreže, uz dobar trening, mogu značajno ubrzati i olakšati proces prikupljanja prostornih podataka uz visoku pouzdanost i kvalitetu.

Zbog neosjetljivosti neuronskih mreža na način prezentacija podataka, budućnost prikupljanja prostornih podataka vjerojatno leži u korištenju radarskih snimaka sa sintetičkom aperturom (SAR). Radar kao tehnologija nudi još brže i preciznije kartiranje uz dodatan benefit što je imun na vremenske utjecaje (oblaci), osvjetljenje i doba dana.

Literatura

Geodata team, Ericsson (2020): Geodata for 5G networks and Geodata layers for 3D model

URL 1: Mishra Mayank, Towards data science, Convolutional Neural Networks, Explained, https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939. (10.06.2024.).

URL 2: Geospatial intelligence, AI advances in imagery feature extraction. https://geoint.global/ai-advances-in-imagery-feature-extraction/ (24.05.2024.).

URL 3: Neil Flood, Fiona Watson, Lisa Collet, Using a U-net convolutional neural network to map woody vegetation extent from high resolution satellite imagery across Queensland, Australia, https://www.sciencedirect.com/science/article/pii/S0303243419302041 (14.06.2024.).

Artificial Intelligence in Planning 5th Generation Networks

Abstract

Planning 5th generation mobile networks is a challenging task, especially in urban areas. Due to the specific characteristics of 5G technology, which uses shorter wavelengths, denser placement of antennas is required to maintain signal quality. For this purpose, high-resolution spatial data becomes crucial for identifying optimal locations for antenna placement. Traditional methods of collecting such data are time-consuming and often too expensive. This problem can be addressed by using artificial intelligence in conjunction with remote data collection. The synergy of these two technologies greatly accelerates and facilitates the planning of infrastructure for next-generation telecommunication networks. The application of artificial intelligence enables more efficient collection and analysis of spatial data, allowing for the creation of detailed 3D models of the urban environment that are used for network infrastructure planning. Using AI, it is possible to automatically collect data on terrain, buildings, vegetation, and other relevant features necessary for this planning. In addition to significantly speeding up the process, AI also allows for scaling these activities to larger geographic areas without a proportional increase in the resources needed for data processing. Artificial intelligence not only provides technical support in optimizing spatial data but also transforms the way organizations approach the planning and implementation of complex infrastructure projects. This technological synergy between AI and spatial data creates new opportunities for innovation and efficiency, making urban and telecommunication infrastructure more capable of meeting the growing demands of modern society.

Keywords: *machine learning, remote sensing, objects detection, data processing*

Automatizacija procesa analize i obrade hidrografskih i geofizičkih podataka

Ivana Radošević[1], Veronika Ilić[1]

[1] Hidrocibalae d.o.o., Ulica Dragutina Žanića - Karle 16, 32100, Vinkovci, Hrvatska, ivana.radosevic@hidrocibalae.hr, veronika.ilic@hidrocibalae.hr

Sažetak

U današnjem dinamičnom tehnološkom okruženju, napredci u područjima poput umjetne inteligencije, strojnog učenja i automatizacije postavljaju nove izazove pred industriju, posebno hidrografski sektor. S porastom zahtjeva i količine dostupnih podataka, automatizacija je postala ključna za poboljšanje procesa obrade podataka. Korištenjem naprednih senzora omogućeno je brzo i precizno prikupljanje velike količine podataka o morskom dnu i strukturama na njemu, minimizirajući ljudski nadzor. U ovom radu predstavljene su mogućnosti automatizacije podataka. Razvojem specifičnih algoritama i softvera omogućena je automatska detekcija objekata: podvodnih struktura, infrastrukturnih objekata, olupina brodova i eksplozivnih naprava. Automatizacija zasigurno može značajno povećati učinkovitost u brojnim zadacima kao što su klasifikacija sedimenta, trodimenzionalna detekcija stijena, kartiranje dna ili pak praćenje i monitoring cjevovoda. Primjenom matematičkih modela omogućeno je brzo filtriranje prikupljenih podataka kao i otklanjanje šumova u podacima. Automatsko kartiranje pospješuje vizualizaciju, a primjena analitičkih alata omogućava bolju identifikaciju ciljeva, anomalija i trendova. Uz dostupne alate, sve više se generiraju razvojni alati za izradu prilagođenih skripti pomoću programskih jezika. Kroz daljnji razvoj naprednih sustava očekuje se da će se prikupljeni podaci obrađivati i interpretirati s većom točnošću i brzinom, doprinoseći tako smanjenju troškova i povećanju učinkovitosti. Međutim, unatoč automatizaciji, i dalje je važan ljudski faktor u osiguravanju kvalitete podataka. Operatori moraju provoditi kontrolu kvalitete i osigurati da se standardi primjenjuju u softverima za obradu podataka.

Ključne riječi: *automatizacija, geofizika hidrografija, obrada podataka, tehnološki napredak*

1. Uvod

Hidrografija je znanstvena disciplina koja se bavi mjerenjem i opisivanjem fizičkih karakteristika morskih, riječnih i jezerskih dna. S razvojem tehnologije, prikupljanje i obrada podataka u hidrografiji doživjeli su značajne promjene. Korištenjem naprednih senzora i automatiziranih sustava, postalo je moguće precizno i brzo prikupiti i analizirati velike količine podataka.

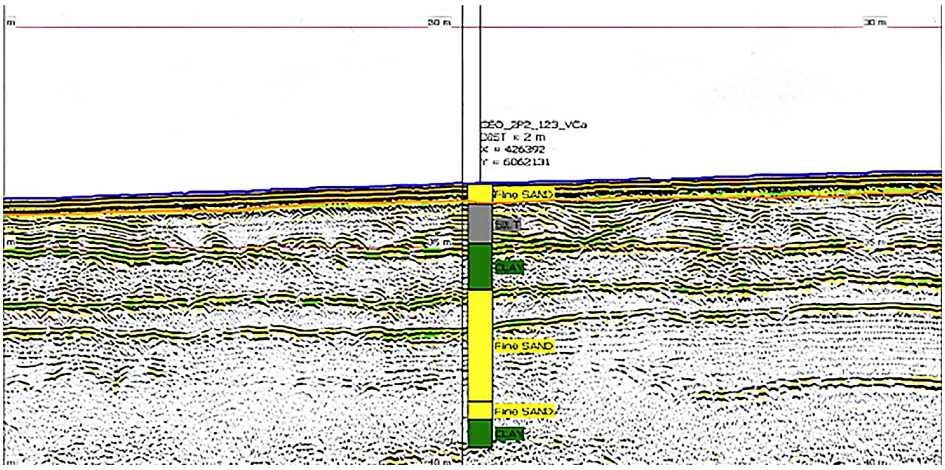
Razmatraju se metode automatizacije koje omogućuju bržu i efikasniju obradu podataka, uključujući automatsku detekciju objekata, kartiranje dna i reflektora, te primjenu skripti i alata za prilagodbu softverskih rješenja specifičnim potrebama. Posebna pažnja posvećuje se industrijskim primjenama i budućim trendovima u automatizaciji, koji obećavaju daljnje unapređenje učinkovitosti i preciznosti u hidrografskim istraživanjima. Na kraju, naglašava se važnost ljudskog faktora u osiguravanju kvalitete podataka, unatoč napretku automatizacije.

2. Prikupljanje i obrada podataka u hidrografiji

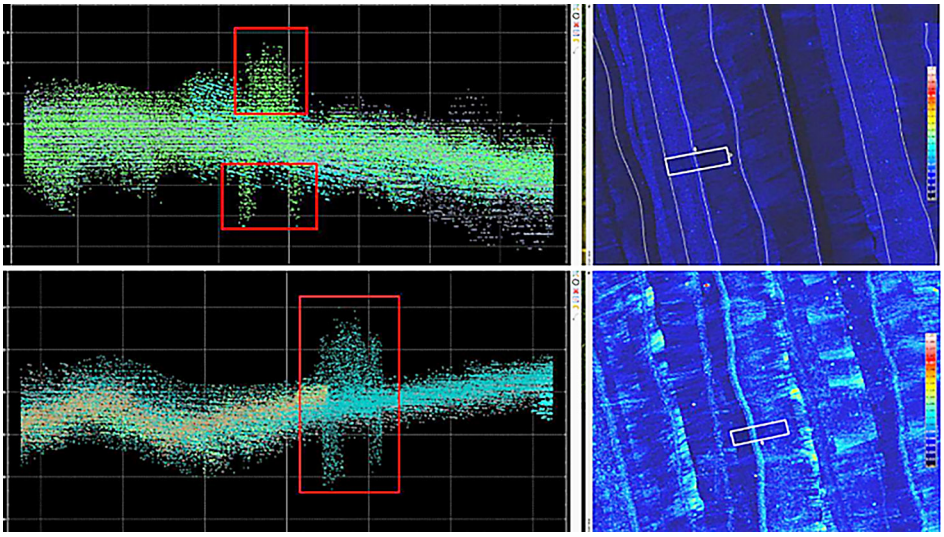
Prikupljanje i obrada podataka u hidrografiji temelji se na korištenju naprednih senzora i tehnologija koje omogućuju detaljno i precizno kartiranje podvodnog okruženja. Svaki od ovih senzora ima specifičnu primjenu i prednosti, omogućujući sveobuhvatnu analizu i vizualizaciju podataka. Automatizacija u prikupljanju i obradi podataka igra ključnu ulogu u poboljšanju učinkovitosti i točnosti, smanjujući potrebu za ručnim intervencijama i omogućujući bržu obradu velikih količina podataka.

2.1. Tehnologije i senzori

Različite tehnologije za podvodno istraživanje omogućuju detaljno kartiranje i istraživanje različitih karakteristika morskog dna. Magnetometar je senzor koji mjeri Zemljino magnetsko polje i koristi se za lociranje potopljenih ili zakopanih željeznih objekata na morskom dnu, kao i u geološkim istraživanjima magnetskih stijena, mineralnih naslaga te arheološkim istraživanjima metalnih artefakata. Panoramski dubinomjer (SSS) koristi akustičke impulse za stvaranje visoko detaljnih slika dna, ističući tamne i svijetle dijelove koji odražavaju jačinu odjeka, što je ključno za otkrivanje objekata i inspekciju podvodnih konstrukcija. Geološko-strukturni dubinomjer (SBP) koristi seizmičke valove za kartiranje slojeva sedimenta i stijena ispod vodenih površina, dok višesnopni dubinomjeri (MBES) omogućuju precizno snimanje i ra-



Slika 1: Interpretacija podataka geološko-strukturnog dubinomjera



Slika 2: Prikaz podataka MBES-a

zlučivanje detalja dna. Intenzitet backscatter-a, koji ovisi o sastavu morskog dna, koristi se za klasifikaciju i kartiranje raspodjele sedimenta, pružajući važne informacije za geološka istraživanja i procjenu opasnosti u podvodnom okruženju.

2.2. Metode automatizacije u obradi podataka

Metode automatizacije u obradi podataka igraju ključnu ulogu u ubrzanju i poboljšanju preciznosti procesa pri obradi složenih skupova podataka. Korištenje naprednih algoritama omogućuje efikasno filtriranje buke, ispravljanje oscilacija te automatizirano prepoznavanje i klasifikaciju objekata, što optimizira operativne procedure i osigurava pouzdane rezultate.

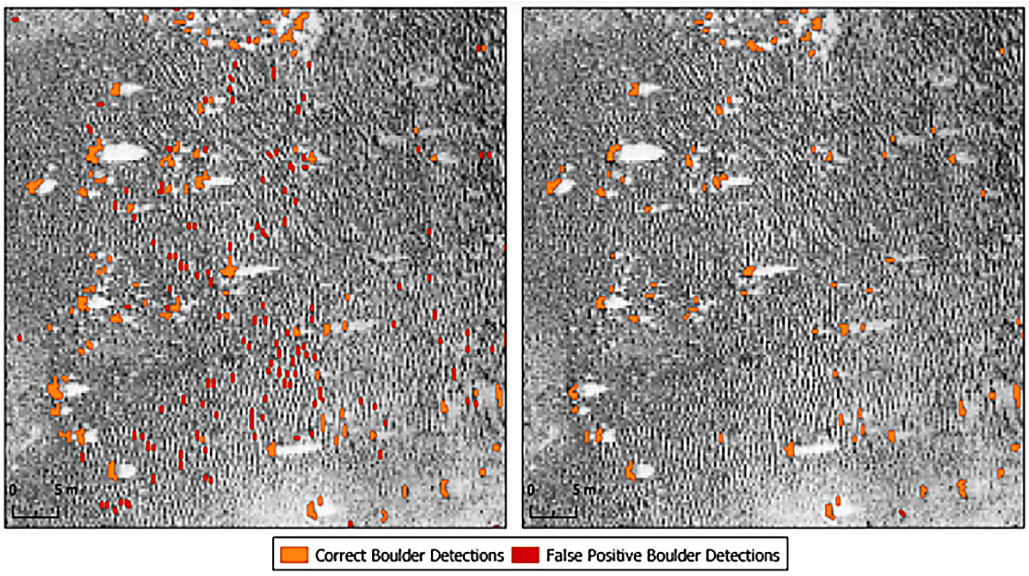
2.2.1. Automatizirani moduli

Automatizirani moduli za grupnu obradu podataka ubrzavaju i pojednostavljuju početnu obradu smanjujući i filtrirajući visokofrekventnu buku te ispravljajući oscilacije. Ovi koraci poboljšavaju ulazne podatke i omogućuju automatizaciju postupaka pri obradi. Primjer obrade podataka prikupljenih panoramskim dubinomjerom uključuje korekciju dometa i brzine kretanja za dobivanje preciznih mozaika te analizu podataka s ciljem prepoznavanja objekata, klasifikaciju geoloških formacija i identifikaciju anomalija. Softveri provode ove postupke kroz korake kao što su import podataka i definiranje postavki kako bi se osigurala točnost i kalibracija podataka u odnosu na položaj sonara (URL1).

2.2.2. Automatska detekcija objekata

Alati za automatsku detekciju objekata koriste specifično razvijene algoritme za učinkovitu analizu velikih količina podataka, omogućujući brzo i precizno otkrivanje i izdvajanje ključnih komponenti refleksija i sjena. Te komponente su ključne za prikaz, identifikaciju i mjerenje objekata u podacima panoramskog dubinomjera (SSS). Najveći izazov pri razvoju ovog alata bio je mjerenje visina gromada. Dok se duljina i širina mogu odrediti pomoću samog SSS mozaika, za mjerenje visine potrebno je znati udaljenost gromade od senzora i visinu senzora iznad morskog dna u trenutku prikupljanja podataka. Da bi se dobili ti ključni podaci, potrebno je izvršiti detekciju na svakoj pojedinačnoj SSS liniji, što zahtijeva automatiziranu korelaciju objekata kroz više SSS linija i nosi rizik od dvostruke detekcije.

Vrijeme potrebno za automatiziranu detekciju gromada procjenjuje se prema tri glavna kriterija: gusto-



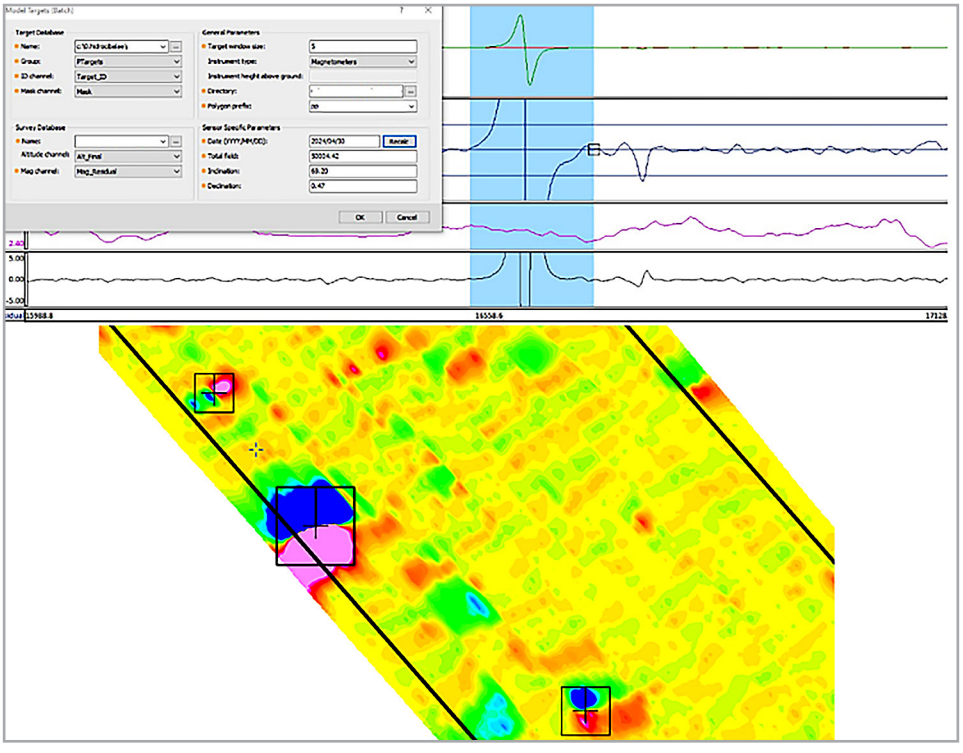
Slika 3: Rezultat skripte za automatsku detekciju objekata

ći objekta, morfologiji morskog dna i sedimentaciji, te ukupnoj površini. Gustoća objekta kategorizirana je u tri razine: niska gustoća (100–1.000 objekata na 0,01 km^2), srednja gustoća (1.000–3.000 objekata na 0,01 km^2) i visoka gustoća (>3.000 objekata na 0,01 km^2).

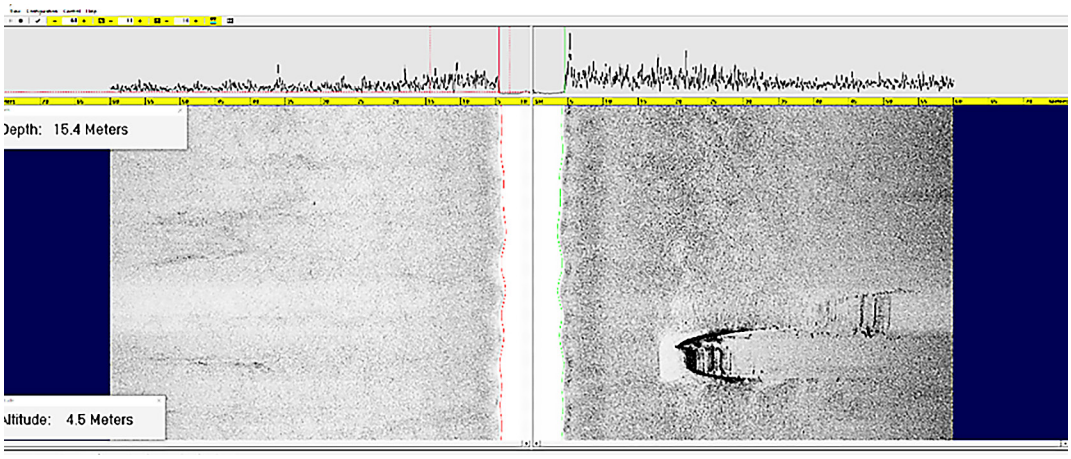
Oblici morskog dna i specifičnosti sedimentacije značajno utječu na vrijeme potrebno za dovršetak automatizacije. Područja ravnog dna sa muljem i pijeskom zahtijevaju manje vremena od heterogenih područja, kao što su područja s pješčanim naborima i šljunčanim sedimentom.

Kada se automatizirano rješenje za detekciju objekata primjenjuje na istraživački skup podataka, vrijeme potrebno za ručnu kontrolu kvalitete proporcionalno je veličini istraživanog područja. (URL 6)

S obzirom na veliki broj mogućih objekata identificiranih u standardnim istraživanjima mina (UXO), efikasni i pouzdani sustavi za automatsko prepoznavanje objekata koriste se za identificiranje objekata za daljnju karakterizaciju. Za podatke prikupljene magnetometrom cilj je identificirati sve značajke anomalija koje mogu biti uzrokovane potencijalnim minama, smanjiti vrijeme rada operatera i eliminirati



Slika 4: Izdvajanje anomalija



Slika 5: Kartiranje dna

subjektivnost operatera. Trenutni pristupi uključuju ručnu identifikaciju i određivanje praga amplitude, ali obje metode imaju svoje nedostatke. Četiri automatske metode koje se koriste su: algoritam za detekciju valova, klasteriranje pozitivnih i negativnih vrhova, dipol temeljen usklađeni filter i analitički signal (ESTCP, 2008). Automatske metode zahtijevaju pažljivo postavljene parametre i vizualni pregled rezultata zbog varijabilnosti podataka, potrebe za optimalnim postavkama algoritama i smanjenja lažno pozitivnih odnosno negativnih rezultata. U područjima s niskom pozadinskom bukom, ove metode značajno smanjuju vrijeme i troškove prepoznavanja anomalija, dok u područjima s visokim šumom može biti potrebna ručna intervencija. Pri tom je ostvarena i automatizacija u vidu modeliranja objekata, određivanja dubine, težine magnetskih objekata te magnetskog momenta.

Automatizirano detektiranje kontakata na 2D profilima uz određivanje dubina omogućeno je nad podacima prikupljenim geološko-strukturnim dubinomjerom. U pojedinim softverima automatizirane su funkcije koje omogućavaju brzo i precizno prepoznavanje kablova i cjevovoda. U softverima s posebno dizajniranim modulima za prepoznavanje kabela i cjevovoda sustav automatski registrira kontakte. Navedeni kontakti se automatski prepoznaju pomoću ultra visoke rezolucije, prikazujući jasnu hiperbolu koju softver čita kao gornji rub objekta. Takva automatizirana tehnika prepoznavanja kontakata uključuje automatsko određivanje dva parametra: sličnost vrha hiperbole i amplitudu hiperbole (URL2). Uz navedeno omogućeno je upravljanje i pregled podataka o kontaktima i njihovim parametrima u različitim prikazima.

2.2.3. Automatsko kartiranje dna i reflektora

Postupak automatskog kartiranja morskog dna uključuje odabir odgovarajućeg algoritma, prilagođenog specifičnom setu podataka. Na primjeru podataka prikupljenih panoramskim dubinomjerom dva najčešće korištena algoritma su: edge detection i treshold detection. Edge detection koristi tehnike obrade slike za identifikaciju granice između vodenog stupca i morskog dna. Posebno je učinkovit u situacijama s blagim promjenama topografije dna i u slučaju većeg šuma u vodenom stupcu. Threshold detection analizira svaki pojedinačni impuls zvučnog signala za precizniju detekciju i praćenje ciljeva pod vodom, a koristan je u situacijama s naglašenim promjenama topografije dna ili manjim šumom u vodenom stupcu (URL3).

U području podvodnog profiliranja sve se više koristi automatsko iscrtavanje horizonata i granica između formacija umjesto ručnog postupka (Li i dr., 2021). Glavni parametri za definiranje algoritma automatskog iscrtavanja uključuju metode obrade signala poput filtriranja i detekcije rubova za identifikaciju promjena u reflektiranim signalima. Pragovi detekcije se podešavaju prema amplitudama signala, frekvencijskom spektru i statističkim karakteristikama. Pri tome se uzima u obzir brzina zvuka u vodi, razlučivost sonara i geometrija snimanja. Nakon automatskog iscrtavanja, važno je provesti postprocesiranje radi eliminacije lažnih pozitiva i validaciju rezultata usporedbom s ručno iscrtanim ili referentnim podacima.

2.2.4. Izvoz

Zadnji korak u automatiziranoj obradi je izvoz podataka. Omogućen je izvoz podatka na različite načine, uključujući spremanje projekta, spremanje mozaika, izradu različitih izvještaja. Jedna od prednosti automatizirane obrade podataka je mogućnost spremanja i učitavanja postavki iz vanjske datoteke, što omogućava korisnicima da iste postavke koriste na više projekata i podijele s drugim korisnicima.

2.2.5. Skripte i alati

Geofizički softveri omogućuju korištenje GX Developer-a za kreiranje vlastitih algoritama i pristup projektnim bazama podataka. Podržani jezici su Python, C#, C++ i GX, a alati se mogu grupirati u prilagođeni izbornik. Automatizacija ponavljajućih zadataka u geofizičkim softverima je omogućena kroz primjenu skripti. Skripte sadrže niz radnji ili naredbi za automatsko izvršavanje zadatka, čime omogućuju

automatizaciju složenih ili repetitivnih zadataka te obradu velike količine podataka. Skripte se mogu uređivati i dijeliti s drugim korisnicima, štedeći vrijeme i povećavajući efikasnost rada. Uz skripte i GX developer, QA/QC alati automatski provjeravaju visinu senzora, uklanjaju nepouzdane podatke, određuju pokrivenost terena i popunjavaju praznine, osiguravajući brzu i točnu analizu geofizičkih istraživanja.

3. Budući trendovi i razvoj

Prema rezultatima provedenih anketa proizlazi rastuća važnost strojnog učenja i umjetne inteligencije. Čak 15% smatra da su ove tehnologije najutjecajniji pokretači inovacija u bliskoj budućnosti, 33% aktivno proučava njihov potencija, a 24% sudionika već razvija rješenja temeljena na strojnim učenju i AI što pokazuje da industrija prepoznaje ključnu ulogu ovih tehnologija. Budući trendovi u automatizaciji hidrografskih podataka uključuju daljnji razvoj umjetne inteligencije i strojnog učenja za još precizniju analizu podataka. Očekuje se da će se koristiti sve sofisticiraniji algoritmi za prepoznavanje objekata i analizu podataka, što će dodatno smanjiti potrebu za ručnom intervencijom. Također, integracija različitih senzora i tehnologija u jedinstvene sustave omogućit će sveobuhvatniju i točniju analizu. Razvoj novih softverskih alata i prilagodljivih sučelja također će omogućiti korisnicima veći stupanj kontrole i prilagodbe procesa obrade podataka specifičnim potrebama projekata.

Osim u smislu automatizirane obrade podataka provodi se i uvođenje automatizacije prilikom izmjere. U fokusu je sve više uvođenje autonomnih vozila (USV) i bespilotnih letjelica (UAV). Uz ostvarenje digitalne transformacije, prednost autonomnih plovila je to što mogu operirati u uvjetima koji su opasni za ljude omogućavajući kontinuirano prikupljanje podataka bez rizika po ljudske živote. Takvim kontinuiranim prikupljanjem osigurava se količina i kvaliteta prikupljenih podataka (URL 4). Automatizacija navigacije i planiranja istraživanja jedan je od primjera automatizacije u izmjeri. Razvijaju se softveri za automatsko planiranje putanje u realnom vremenu na temelju opažane dubine uzimajući u obzir zahtjeve pokrivenosti i gustoće. Osim navedenog, ostvaruje se i automatsko pozicioniranje praćenjem postojećih i poznatih struktura (URL5).

4. Zaključak

Automatizacija procesa analize i obrade hidrografskih i geofizičkih podataka igra ključnu ulogu u modernom hidrografskom sektoru. Korištenje naprednih senzora i automatskih metoda omogućuje brzo i precizno prikupljanje i obradu velike količine podataka, smanjujući potrebu za ljudskim nadzorom i povećavajući učinkovitost. Primjene u industriji pokazale su se vrlo korisnima, posebno u naftnoj i plinskoj industriji, pomorskoj navigaciji i podvodnoj arheologiji. Budući razvoj u ovom području obećava daljnje poboljšanje preciznosti i učinkovitosti, uz značajne uštede vremena i troškova. Unatoč napretku tehnologije, ljudski faktor ostaje ključan u osiguravanju kvalitete podataka i prilagodbi automatskih sustava specifičnim uvjetima i potrebama istraživanja.

Literatura

ESTCP (2008): Cost and Performance Report - Target Picking Methods for Magnetic Data, MM-0502, 1-7.

Li, S., Zhao, J., Zhang, H., & Qu, S. (2021): An integrated horizon picking method for obtaining the main and detailed reflectors on sub-bottom profiler sonar image. Remote Sensing, 13(15), 2959

URL1: AUTO PROCESSING ADVANCEMENTS AND THE FUTURE OF SONARWIZ, https://chesapeaketech.com/autoprocessing/ (14.06.2024.).

URL2: Sub-bottom specialist Geophysical solution provider, https://geo-matching.com/media/migrationhlhkb3.pdf (14.06.2024.).

URL3: Sidescan Auto Processing Settings, https://chesapeaketech.com/wp-content/uploads/docs/SonarWiz7_UG/HTML/sidescan_sonar_data.htm?ms=AQAAAAAAAAAAAAAAAAAAAAAAAAAAABA&st=MA%3D%3D&sct=NjQ1&mw=MjQw (14.06.2024.).

URL4: The future of hydrographic surveying: balancing automation and human expertise, https://www.hydro-international.com/content/article/the-future-of-hydrographic-surveying-balancing-automation-and-human-expertise (14.06.2024.).

URL5: AI is enabling a transformation toward autonomous hydrographic operations, https://www.eiva.com/about/eiva-log/ai-enabling-autonomous-hydrographic-operations (14.06.2024.).

URL6: An automated data processing approach to boulder detection, https://www.hydro-international.com/content/article/an-automated-data-processing-approach-to-boulder-detection (14.06.2024.).

Automation of Hydrographic and Geophysical Data Analysis and Processing

Abstract

In today's dynamic technological environment, advancements in areas such as artificial intelligence, machine learning, and automation present new challenges for industry, especially the hydrographic sector. With the increasing demands and volume of available data, automation has become crucial for improving data processing. The use of advanced sensors enables the rapid and precise collection of large amounts of data about the seabed and its structures, minimizing human supervision. This paper presents the possibilities of data automation. The development of specific algorithms and software allows for the automatic detection of objects: underwater structures, infrastructure objects, shipwrecks, and explosive devices. Automation can significantly enhance efficiency in numerous tasks such as sediment classification, three-dimensional rock detection, seabed mapping, and pipeline monitoring. The application of mathematical models enables the rapid filtering of collected data and the elimination of noise. Automatic mapping improves visualization, and the use of analytical tools allows for better identification of targets, anomalies, and trends. With available tools, more and more development tools are being generated for creating custom scripts using programming languages. Through the further development of advanced systems, it is expected that collected data will be processed and interpreted with greater accuracy and speed, contributing to cost reduction and increased efficiency. However, despite automation, the human factor remains important in ensuring data quality. Operators must conduct quality control and ensure that standards are applied in data processing software.

Keywords: *technological advancement, automation, data processing, hydrography, geophysics*

Usporedba karata izrađenih umjetnom i ljudskom inteligencijom

Robert Župan[1], Stanislav Frangeš[1], Adam Vinković[1], Ivana Racetin[2]

[1] Sveučilište u Zagrebu – Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, robert.zupan@geof.unizg.hr, stanislav.franges@geof.unizg.hr, adam.vinkovic@geof.unizg.hr

[2] Sveučilište u Splitu, Fakultet građevinarstva, arhitekture i geodezije, Matice hrvatske 15, Split, Hrvatska, iracetin@gradst.hr

Sažetak

Usporedba karata izrađenih umjetnom i ljudskom inteligencijom otkriva duboke razlike u pristupu i rezultatima dizajna. Ljudska inteligencija, koja stoji iza dizajna karata, naglašava kreativnost, originalnost i prilagodljivost. Ljudski dizajneri, prvenstveno kartografi, koriste svoju imaginaciju, iskustvo i osjećaj za estetiku kako bi stvorili jedinstvene i estetski privlačne karte koje zadovoljavaju složene potrebe korisnika. Njihov pristup podrazumijeva duboko razumijevanje konteksta i ciljeva kartografije te pažljivo prilagođavanje dizajna i oblikovanja karata prema tim parametrima. S druge strane, umjetna inteligencija koristi algoritme i modele strojnog učenja za generiranje karata. Takvi algoritmi mogu brzo analizirati i obraditi velike količine podataka, što rezultira brzim generiranjem karata (Chang i dr., 2021). Međutim, umjetnoj inteligenciji može nedostajati kreativnosti i originalnosti, jer njezini rezultati ovise o podacima na kojima je trenirana i podučavana, kao i algoritmima koji se koriste. Dok kartografi mogu prilagoditi dizajn karti specifičnim potrebama i preferencijama korisnika, umjetna inteligencija je ograničena na ono što je naučila iz postojećih podataka. Kvaliteta i estetika karata mogu varirati, pri čemu ljudski dizajneri često postižu višu razinu zahvaljujući njihovom iskustvu i kreativnosti, s pretpostavkom da će napredak u umjetnoj inteligenciji omogućiti generiranje sve kvalitetnijih karata. U konačnici, odabir između karata stvorenih umjetnom i ljudskom inteligencijom ovisi o specifičnim potrebama projekta, dostupnim resursima i željenim karakteristikama krajnjih korisnika karata.

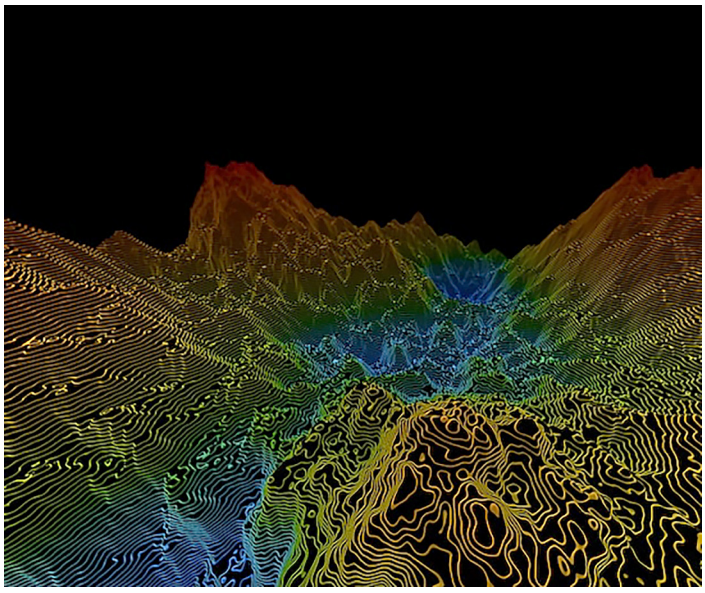
Ključne riječi: *dizajn, kartografija, umjetna inteligencija*

1. Uvod

U današnjem digitalnom dobu, kartografija, znanost izrade i proučavanja karti, doživjela je značajnu transformaciju zahvaljujući napretku u umjetnoj inteligenciji (AI). Tradicionalno, izrada karti bila je domena ljudskih stručnjaka, kartografa, koji su se oslanjali na svoje znanje, iskustvo i kreativnost kako bi precizno prikazali zemljopisne informacije. No, s razvojem AI tehnologija, pojavile su se nove metode koje omogućuju automatsko generiranje karti, što je donijelo brojne prednosti, ali i izazove. Umjetna inteligencija (AI) je područje računalne znanosti koje se bavi stvaranjem računalnih sustava koji mogu izvoditi zadatke koji zahtijevaju ljudsku inteligenciju. To uključuje sposobnost učenja, zaključivanja, rasuđivanja, prepoznavanja uzoraka, donošenja odluka i rješavanja problema. Umjetna inteligencija teži stvaranju računalnih sustava koji mogu simulirati ljudsku inteligenciju (HI) na način koji je koristan za različite aplikacije. Karte izrađene umjetnom inteligencijom koriste napredne algoritme strojnog učenja i dubokog učenja za analizu velikih količina podataka u vrlo kratkom vremenu. Ovi sustavi mogu integrirati podatke iz različitih izvora, uključujući satelitske snimke, senzore i geoprostorne baze podataka, kako bi stvorili detaljne i ažurirane kartografske prikaze. Prednosti AI-a u kartografiji uključuju brzinu obrade podataka, mogućnost automatskog ažuriranja informacija te sposobnost prepoznavanja obrazaca koji bi mogli proći nezapaženo ljudskim okom. S druge strane, ljudska inteligencija u kartografiji donosi duboko razumijevanje konteksta i sposobnost interpretacije podataka na način koji je često izvan dosega trenutnih AI sustava. Ljudski kartografi mogu primijeniti svoju intuiciju i iskustvo kako bi izradili karte koje su ne samo tehnički precizne, već i vizualno privlačne te lako razumljive korisnicima (Župan i Frangeš, 2015). Oni također mogu prilagoditi karte specifičnim potrebama različitih korisnika, što je ključno za uspješno komuniciranje geografskih informacija. Usporedba karti izrađenih umjetnom i ljudskom inteligencijom otkriva kompleksan odnos između tehnologije i ljudske vještine. Dok AI donosi revoluciju u efikasnosti i obradi podataka, ljudski kartografi osiguravaju da karte ostanu relevantne, točne i korisne. Kroz ovu usporedbu, istražit ćemo kako se ove dvije metode nadopunjuju i koje su njihove prednosti i nedostatci u suvremenoj kartografiji.

2. Područje istraživanja

Istraživanje usporedbe karti izrađenih umjetnom (AI) i ljudskom inteligencijom obuhvaća više aspekata,



Slika 1: Visinski prikaz terena izrađen umjetnom inteligencijom (URL 1)

uključujući tehničke, metodološke i praktične komponente. Ovo područje istraživanja je interdisciplinarno, povezujući geografiju (Zhao i dr., 2021), računalne znanosti, kartografiju i umjetnu inteligenciju (Klumpp, 2019, Iyer, 2021), s ciljem boljeg razumijevanja načina na koji te dvije različite metode pridonose suvremenoj kartografiji.

Tehnički aspekti istraživanja uključuju analizu algoritama koji se koriste u AI sustavima za generiranje karti. Ovi algoritmi obuhvaćaju strojno učenje, duboko učenje i obradu prirodnog jezika, omogućujući automatizaciju procesa kartiranja. Istraživači proučavaju točnost, brzinu i efikasnost ovih algoritama te kako se nose s velikim količinama podataka iz različitih izvora. Osim toga, istražuje se sposobnost AI sustava da prepoznaju i interpretiraju složene geografske obrasce te njihova sposobnost prilagodbe u stvarnom vremenu.

Metodološki aspekti fokusiraju se na usporedbu različitih pristupa i tehnika koje koriste ljudski kartografi i AI sustavi. Ljudski kartografi (kao suprotnost kartografiji umjetne inteligencije) koriste tradicionalne metode, uključujući ručno crtanje i digitalnu obradu, uzimajući u obzir kulturne, socijalne i ekološke faktore. S druge strane, AI sustavi primjenjuju automatizirane procese koji se oslanjaju na velike podatkovne setove i računalne modele. Istraživanje se bavi pitanjem kako ove metode utječu na kvalitetu i preciznost izrađenih karti, te koje su prednosti i nedostaci svake metode.

Praktični aspekti uključuju primjenu izrađenih karti u različitim domenama, kao što su urbanističko planiranje (Zhang i Nakajima, 2022), navigacija (Rocha i Lopes, 2020), upravljanje prirodnim resursima i krizno upravljanje (Ivić, 2019). Istraživači analiziraju kako se karte izrađene AI-jem koriste u usporedbi s kartama koje su izradili ljudski stručnjaci. Posebna pažnja posvećuje se upotrebljivosti, točnosti i pouzdanosti karti u stvarnim situacijama. Također se istražuju ekonomski aspekti, uključujući troškove izrade i održavanja karti.

Ovo područje istraživanja nastoji identificirati kako se umjetna i ljudska inteligencija mogu najbolje integrirati kako bi se iskoristile njihove komplementarne prednosti. Dok AI donosi brzinu i efikasnost, ljudski kartografi osiguravaju kontekstualnu točnost i relevantnost. Kombinacija ovih pristupa može rezultirati naprednijim i pouzdanijim kartama koje zadovoljavaju sve veće zahtjeve suvremenog društva.

2.1. Pregled dosadašnjih radova

Istraživanja na temu usporedbe karti izrađenih umjetnom inteligencijom (AI) i ljudskom inteligencijom obuhvaćaju širok spektar studija, od tehničkih analiza do praktičnih primjena (Slika 1). Dosadašnji radovi pružaju vrijedne uvide u razlike i sličnosti između ova dva pristupa u kartografiji.

Tehničke usporedbe. Jedan od ključnih aspekata istraživanja je tehnička usporedba algoritama korištenih u AI sustavima i tradicionalnih metoda koje koriste ljudski kartografi (Fairbairn, 1994). Studija objavljena u časopisu "Geoinformatics" analizirala je točnost i brzinu obrade podataka kod AI sustava u usporedbi s ručno izrađenim kartama. Rezultati su pokazali da AI sustavi mogu obraditi i integrirati velike količine podataka mnogo brže od ljudskih kartografa, ali su ponekad imali problema s preciznošću u složenim geološkim i urbanim područjima.

Metodološke analize. Metodološki pristupi također su bili predmet brojnih istraživanja. Rad objavljen u "Cartography and Geographic Information Science" usporedio je različite tehnike koje koriste ljudski kartografi i AI sustavi. Ljudski kartografi često koriste kreativne i intuitivne metode koje omogućuju prilagodbu specifičnim potrebama korisnika, dok AI sustavi koriste standardizirane algoritme koji omogućuju dosljednost i brzinu, ali mogu nedostajati fleksibilnosti.

Praktične primjene. Praktična primjena AI u kartografiji bila je predmet mnogih studija. Istraživanje provedeno od strane "Journal of Urban Planning and

Development" analiziralo je upotrebu AI generiranih karti u urbanističkom planiranju. Zaključeno je da su AI karte izuzetno korisne za brzo generiranje planova i simulacija, ali ljudski kartografi su ključni za finalnu provjeru i prilagodbu tih planova prema specifičnim lokalnim uvjetima i potrebama.

Interdisciplinarna istraživanja. Interdisciplinarna istraživanja također igraju značajnu ulogu u razumijevanju ove teme. Rad objavljen u "International Journal of Geographical Information Science" istraživao je kako se kombinacija AI i ljudske ekspertize može koristiti za poboljšanje kartografskih procesa. Zaključeno je da suradnja između AI tehnologija i ljudskih stručnjaka može rezultirati preciznijim i korisnijim kartama.

Kritički osvrti. Kritički radovi često ističu nedostatke trenutnih AI sustava, kao i prednosti ljudske intuicije i kontekstualnog razumijevanja. U radu objavljenom u "Progress in Human Geography" naglašeno je da iako AI može značajno ubrzati proces izrade karti, ljudska prisutnost je neophodna za osiguranje točnosti i interpretacije podataka u kontekstu specifičnih društvenih i kulturnih uvjeta.

Dosadašnji radovi naglašavaju važnost kombinacije AI i ljudske inteligencije u kartografiji (Kang, 2020, Ai, 2022, Gao, 2021, Kocoń i dr., 2023). Dok AI donosi brzinu i mogućnost obrade velikih količina podataka, ljudski kartografi osiguravaju kontekstualnu točnost i prilagodljivost, čime se stvara sinergija koja može značajno unaprijediti suvremenu kartografiju (Gao i dr., 2023, Wang i dr., 2020, Hancock, 2022).

2.2. Prikupljanje podataka

Prikupljanje podataka za usporedbu geografskih karata izrađenih umjetnom inteligencijom (UI) i ljudskom inteligencijom (LI) zahtijeva pažljiv plan i strukturu kako bi se osigurala relevantnost, pouzdanost i preciznost podataka. Problematika usporedbe zahtijeva mnoge kriterije analize pa ćemo spomenuti samo najvažnije. Kriteriji usporedbe mogu uključivati:

- Točnost: Kako precizno karte prikazuju geografske značajke i prostorne odnose?
- Estetiku: Koliko su karte vizualno privlačne i pregledne?
- Funkcionalnost: Koliko su karte korisne za različite svrhe (navigacija, planiranje, obrazovanje)?
- Korisničko iskustvo: Kako korisnici doživljavaju karte u smislu upotrebljivosti i intuitivnosti?

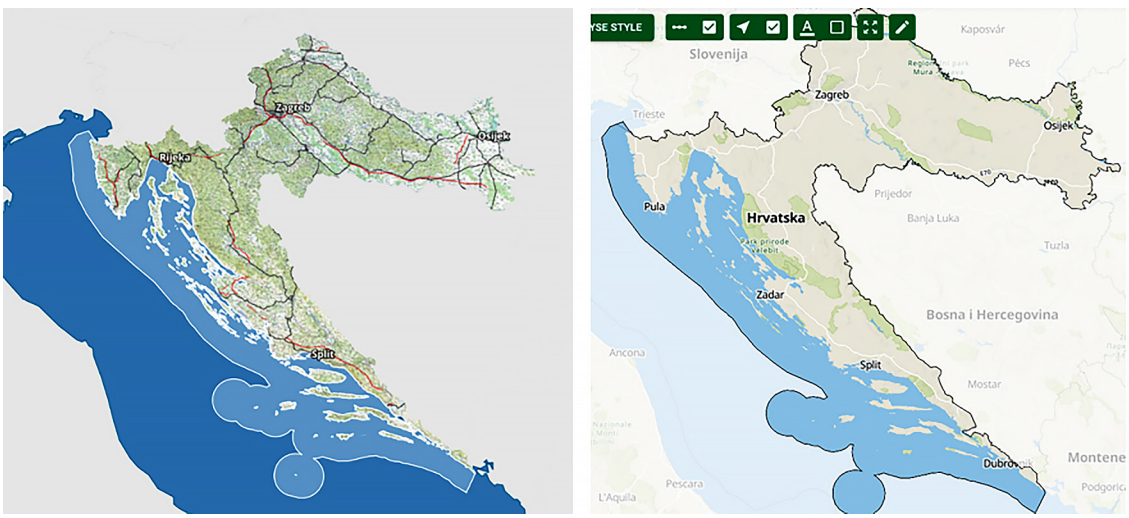
Pri traženju relevantnih primjera treba imati na umu:

- Karte izrađene UI: prikupljanje karata generirane korištenjem različitih UI tehnologija, poput satelitskih karata, topografskih karata ili karata nastalih korištenjem algoritama dubokog učenja.
- Karte izrađene LI: Prikupite karte koje su dizajnirali profesionalni kartografi koristeći tradicionalne metode i alate.

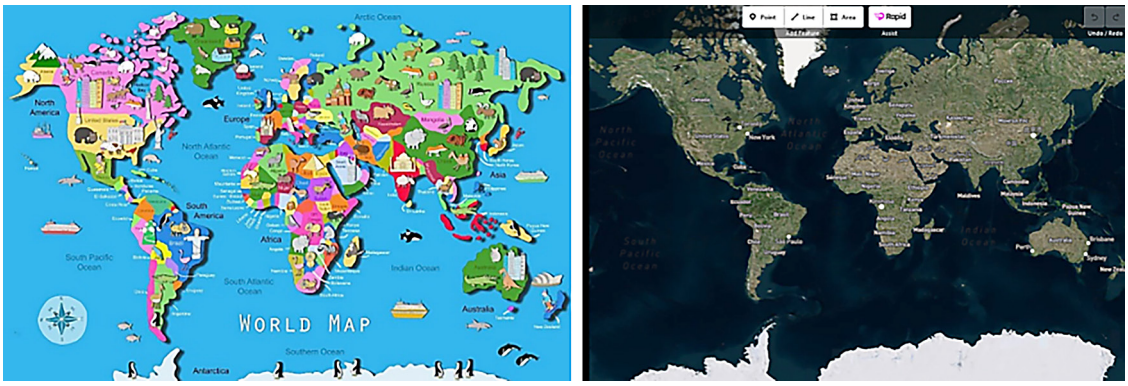
Treba izabrati karte koje pokrivaju slična geografska područja, mjerila i razine detalja kako bi usporedba bila što objektivnija.

Na portalu Better Maps moguće je jedino dobiti kartu nekog područja (Slika 2), dok složenije upite ne može se procesirati (ne postoji mogućnost davanja rezultata ako se unese opis karte koju treba izraditi, npr. izradi kartu svih bitaka u drugom svjetskom ratu ili izradi kartu koja prikazuje sve trgovine u Poreču i sl.).

Primjer na Slici 3 upravo zorno pokazuje na kojoj je trenutno razini AI, jer se mogu postavljati upiti samo koji sadrže lokacije koje su već unesene na neku od karata, najčešće je to Google Maps, Google Earth ili OpenStreetMap karta u podlozi a točkaste signature se stavljaju na lokacije koje se prepoznaju na karti iz teksta koji vraća AI kao odgovor na upit. Zbog čekanja na odgovor AI za pitanje sa Slike 3 potrebno je 7–8 sekundi za generiranje odgovora i karte na ekranu. AI je kod izrade karata na niskim razinama u odnosu na HI pogotovo za izradu prikaza kao na Slici 4, iako za neke druge slučajeve može se dobiti također



Slika 2: Topografska karta Hrvatske u mjerilu 1:200 000 izrađena s HI (lijevo, Geoportal DGU, URL 2), topografska karta Hrvatske dobivena pomoću AI (desno, portal Better Maps, URL 3)



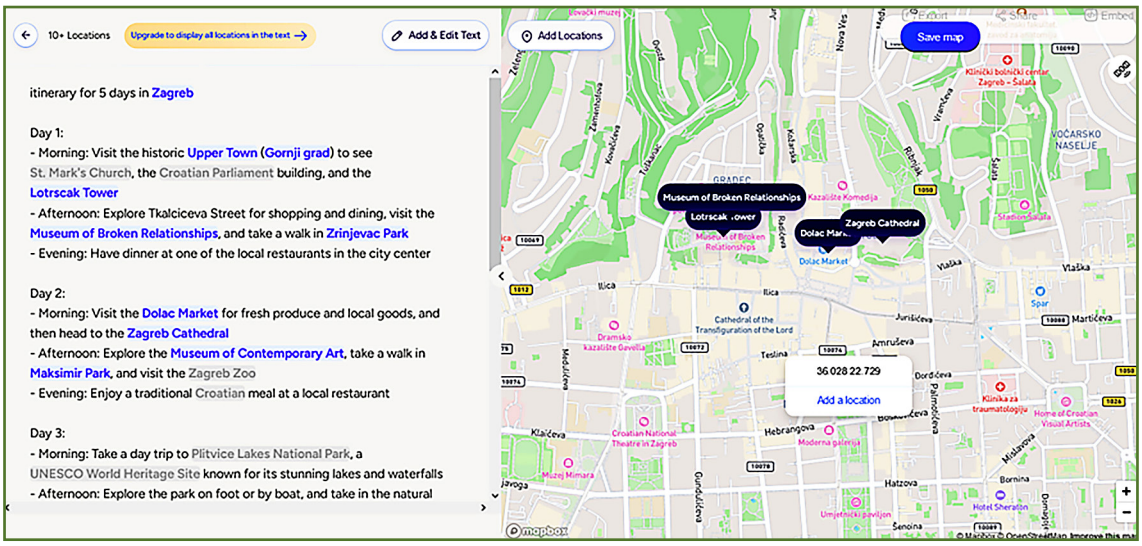
Slika 3: Lijevo je prikazana dječja karta svijeta koju je čovjek ili HI izradio digitalnom tehnologijom (URL 4), a desno također dječja karta svijeta, ali vidljivo je da AI ne radi razliku između karte svijeta i dječje karte svijeta te ne razlikuje te pojmove (URL 5)

upitan rezultat i još nema dostupnih istraživanja koji bi ispitali točnost i druge parametre izrade karata i kartama srodnih prikaza. Umjetna inteligencija (AI) može stvoriti geografsku kartu na različite načine, a ovisi o vrsti problema koji se rješava i vrsti tehnika koje se primjenjuju. Evo nekoliko načina na koje AI može stvarati geografske karte:

1. Generiranje karata pomoću strojnog učenja: Učenjem s tim podacima, AI modeli mogu naučiti prepoznavati uzorke i karakteristike u slikama ili podacima te generirati nove karte na temelju tih uzoraka (URL 6).
2. Detekcija i segmentacija objekata: AI sustavi mogu koristiti tehnike računalnog vida kako bi detektirali i segmentirali različite objekte na geografskim slikama, poput cesta, rijeka, zgrada ili vegetacije. Ove informacije zatim se mogu koristiti za stvaranje detaljnih geografskih karata (URL 7).
3. Analiza prostornih podataka: AI može analizirati velike količine prostornih podataka kako bi otkrio uzorke ili trendove koji su važni za stvaranje geografskih karata (URL 8).
4. Određivanje najboljih putanja: AI može koristiti algoritme pretraživanja kako bi odredio optimalne putanje između različitih točaka na karti (URL 9).
5. Interpolacija podataka: AI može koristiti tehnike interpolacije kako bi predvidio vrijednosti geografskih atributa na nepoznatim lokacijama na temelju dostupnih podataka. To može biti korisno za stvaranje glatkih i kontinuiranih geografskih karata.
6. Klasifikacija terena: Na primjer, moguće je klasificirati različite tipove tla, vegetacije ili vodenih tijela.

3. Zaključak

Već je vizualnom usporedbom jasno da AI treba još učiti i da će trebati jako puno dostupnih podataka na webu u obliku karata uz njihove opise i kada AI bude na razini da nauči čitati i interpretirati karte i grafiku na način kako to rade ljudi tada ćemo imati rezultate izrade karata vizualno, funkcionalno, estetski i u svakom drugom pogledu kao i kod HI. Za sada čini se da se radi o pomalo nespretnom simuliranju ljudske



Slika 4: Raspored turističkog obilaska Zagreba u pet dana (itinerary for 5 days in Zagreb)

inteligencije. Izrada karata je složen proces, a AI se bar za sada nije razvio do te mjere da se možemo za potrebe ovakve analize šire poigrati s njom. Slično se događalo s pojavom Google Mapsa kao prvog kartografskog besplatnog web portala koji je prikazivao dosta siromašne karte po sadržaju, ali ipak za cijeli svijet, koje nisu bile dorasle ni za usporedbu s klasično izrađenim kartama, pa su sljedećih godina korisnici navikavani i prilagođavani na takve karte i da ih koriste za samo ograničene svrhe. Slično se događa s AI kartama koje se razvijaju i ubuduće će AI postati alat koji će nam dati brže, više i bolje karte.

Literatura

Ai, T. (2022): Some thoughts on deep learning empowering cartography, Journal of Geography and Cartography, 5 (2), 25–40.

Chang, V., Mou, Y., Xu, Q. A. (2021): The ethical issues of location-based services on big data and IoT, In Modern Industrial IoT, Big Dana and Supply Chain, Proceedings of the IIoTBDSC 2020, Springer, Singapore, 195–205.

Fairbairn, D. J. (1994): The frontiers of cartography: mapping a changing discipline, The Photogrammetric Record, 14 (84), 903–915.

Gao, S. (2021): Geospatial artificial intelligence (GeoAI), Vol. 10, Oxford University Press, New York.

Gao, S., Hu, Y., Li, W., Zou, L. (2023): Special issue on geospatial artificial intelligence, GeoInformatica, 27 (2), 133–136.

Hancock, K. (2022): Cognitive Artificial Intelligence and Predictive Modeling Algorithms, Virtual Navigation and Geospatial Mapping Tools, and Remote Sensing Data Fusion Techniques in the Immersive Metaverse Environment, Journal of Self-Governance and Management Economics, 10 (3), 40–55.

Ivić, M. (2019): Artificial intelligence and geospatial analysis in disaster management, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 42, 161–166.

Iyer, L. S. (2021): AI enabled applications towards intelligent transportation, Transportation Engineering, 5, 100083.

Kang, Y. (2020): Integrating Artificial Intelligence in Cartography: Using Deep Learning for Map Style Transfer and Map Generalization, Master Thesis, University of Wisconsin, Madison.

Klumpp, M. (2019): Artificial Intelligence Applications, Operations, Logistics and Supply Chain Management, 637–662.

Kocoń, J., Baran, J., Kanclerz, K., Kajstura, M., Kazienko, P. (2023): Differential dataset cartography: Explainable artificial intelligence in comparative personalized sentiment analysis, In International Conference on Computational Science, Springer Nature Switzerland, Cham, 148–162.

Rocha, S., Lopes, A. (2020): Navigation based application with augmented reality and accessibility, In Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems, 1–9.

Wang, P., Luo, C., Pan, F., Zhu, Y. (2020): Analysis and Research of Artificial Intelligence Algorithms in GPS Data, IEEE Access.

Zhang, Y., Nakajima, T. (2022): Exploring the Design of a Mixed-Reality 3D Minimap to Enhance Pedestrian Satisfaction in Urban Exploratory Navigation, Future Internet, 14 (11), 325.

Zhao, B., Zhang, S., Xu, C., Sun, Y., Deng, C. (2021): Deep fake geography? When geospatial data encounter Artificial Intelligence, Cartography and Geographic Information Science, 48 (4), 338–352.

Župan, R., Frangeš, S. (2015): Web cartography, Hand book, University of Zagreb – Faculty of Geodesy, Zagreb.

URL 1: Visme, https://my.visme.co, (14.6.2024.).

URL 2: Geoportal DGU, https://geoportal.dgu.hr/, (14.6.2024.).

URL 3: Better Maps, https://app.bettermaps.ai/create-map/, (14.6.2024.).

URL 4: 4BP, https://4.bp.blogspot.com/-n96yvZP4SUE/XFNxjp3KS3I/AAAAAAABgE8/IR7i7vuY6jsLCRjnMkGSeq3MOf-hrDTegCLcBGAs/s1600/world-map-for-children.jpg, (14.6.2024.).

URL 5: RapidEditor, https://rapideditor.org, (14.6.2024.).

URL 6: GeographyRealm, https://www.geographyrealm.com/ai-digitize-data-scanned-maps/, (14.6.2024.).

URL 7: Sentisight, https://www.sentisight.ai/?utm_source=google&utm_medium=cpc&utm_campaign=generalwest&gad_source=1&gclid=CjwKCAjwmrqzBhAoEiwAXVpgovC9Ik673A3Vcg6uQvsY7bs7p1fayMcqs84D7VqtiV0-9apmOeXzGBoCbewQAvD_BwE, (14.6.2024.).

URL 8: MapFlow, https://www.google.com/url?sa=t&source=web&rct=j&opi=89978449&url=https://mapflow.ai/&ved=2ahUKEwjvg7_huuCGAxV09LsIHR1ZCM4QFnoECBEQAQ&usg=AOvVaw1ci4CM-SuSKTci3XE61gv5, (14.6.2024.).

URL 9: AndroidPolice, https://www.androidpolice.com/ai-powered-app-routora-optimize-google-maps-multi-stop-routes/, (14.6.2024.).

Comparison of Maps Created by Artificial and Human Intelligence

Abstract

The comparison between maps created by artificial intelligence and human intelligence reveals profound differences in approach and design outcomes. Human intelligence, which underpins map design, emphasizes creativity, originality, and adaptability. Human designers, primarily cartographers, use their imagination, experience, and sense of aesthetics to create unique and aesthetically pleasing maps that meet the complex needs of users. Their approach involves a deep understanding of the context and goals of cartography, carefully adapting the design and layout of maps according to these parameters. On the other hand, artificial intelligence utilizes algorithms and machine learning models to generate maps. These algorithms can quickly analyse and process large amounts of data, resulting in the rapid creation of maps. However, artificial intelligence may lack creativity and originality, as its results depend on the data it has been trained on and the algorithms used. While cartographers can tailor map designs to the specific needs and preferences of users, artificial intelligence is limited to what it has learned from existing data. The quality and aesthetics of maps can vary, with human designers often achieving higher levels due to their experience and creativity, assuming that advancements in artificial intelligence will enable the generation of increasingly high-quality maps. Ultimately, the choice between maps created by artificial and human intelligence depends on the specific needs of the project, available resources, and the desired characteristics for end-users of the maps.

Keywords: *artificial intelligence, cartography, design*

Kalibracija pametnih telefona u svrhu volonterskog mjerenja buke

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

[1] Sveučilište u Zagrebu Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, iva.cibilic@geof.unizg.hr, vesna.posloncec-petric@geof.unizg.hr

Sažetak

Utjecaj svakodnevne i dugotrajne izloženosti konstantnoj buci u nekim slučajevima može rezultirati kroničnim bolestima poput povišenoga krvnog tlaka ili kardiovaskularnih problema. Ekološka zajednica u zadnjem desetljeću sve veću pažnju stavlja na problem zagađenja urbanih sredina bukom. Kontrola buke u okolišu pojavljuje se kao ključna briga društva ne samo za javno zdravlje već i za društvenu dobrobit. U posljednje vrijeme raste interes za volonterske pristupe mjerenju razine buke u okolišu korištenjem pametnih telefona kao mjernih uređaja za mjerenje zvuka. Pametni telefoni postali su sveprisutni komunikacijski uređaji za većinu stanovništva. Relativno maleni s bogatim skupom aplikacija, niskom potrošnjom energije i nekoliko vrsta senzora kao što su GPS, mikrofon, žiroskop, akcelerometar, barometar, čini ih dobrim kandidatom za izradu aplikacija za mjerenje i praćenje različitih parametara okoliša. Međutim, nedostatak kalibracije pametnog telefona može dovesti do značajnih odstupanja u prikupljenim podacima. Ovaj rad ima za cilj potvrditi učinkovitost pametnih telefona za mjerenje buke mobilnim aplikacijama koje koriste mikrofon kao senzor detekcije jačine zvuka u okolini korisnika. Kalibracija pametnog telefona, koja je obično odgovornost korisnika, predstavlja potencijalni izvor pogreške i ključan je korak u ostvarivanju povoljnih rezultata. Rad je usredotočen na principe kalibracije za precizno mjerenje razina zvuka pomoću mikrofona ugrađenih u pametne telefone. Da bismo to postigli, nudimo pregled dostupnih metoda za učinkovito umjeravanje standardnog mikrofona pametnog telefona.

Ključne riječi: *buka, kalibracija, mikrofon, pametni telefon, senzor*

1. Uvod

Brzi rast stanovništva, urbanizacija i socioekonomske promjene doveli su do alarmantnog porasta broja stanovnika u urbanim sredinama (UNHABITAT 2022), a s tim i velikog zagađenja bukom (Schwela, 2021), što predstavlja značajan rizik za ljudsko zdravlje (Rossi i dr., 2018). Nedavne procjene Europske agencije za okoliš (eng. *European Environment Agency*, EEA) pokazuju da je oko 20% europskog stanovništva svakodnevno izloženo opasnim razinama buke (Eulalia, 2023).

Kako bi se zaštitila dobrobit ljudi, posljednjih je godina uvedeno više propisa kako bi se uspostavile sigurne razine izloženosti, identificirali prikladni slušni pokazatelji i predložile strategije upravljanja bukom. Na primjer, Europska unija (EU) donijela je direktivu 2002. godine kojom poziva države članice da izrade karte buke i akcijske planove za svoje urbane sredine (EU, 2002). Predložena je izrada karata buke (za svaki grad članice sa preko 250 000 stanovnika) koje se integriraju u urbanističke planove kao osnova za smanjenje buke, zajedno s politikama održivog razvoja, koje su osmišljene za poboljšanje kvalitete života građana (Costa i dr., 2022). S tim u vezi, karta buke može prevesti razine buke u klasificirane vrijednosti za kartografski prikaz i daljnju analizu i korištenje.

Međutim, karte buke generiraju se pomoću specijaliziranog softvera koji kombinira modele emisije buke i akustične disperzije s geoprostornim i prometnim podacima (Grubeša i dr., 2018). Iako nude opći pregled distribucije buke i utjecaj inicijativa za smanjenje buke, često su kritizirani da su nerealni, posebno kada se uzmu u obzir vremenske promjene u razinama buke (Picaut i dr., 2021).

Uzimajući u obzir službene karte buke, također treba obratiti pažnju na njihovu ažurnost. Zakonom o zaštiti od buke (NN, 14/21) propisano je da se strateške karte buke izrađuju svakih 5 godina, što je značajan vremenski period. Izrađene strateške karte su javno dostupne svima na korištenje, međutim, u formatima koji nisu a) čitki običnim korisnicima i b) ne pružaju pristup sirovim podacima za istraživače i znanstvenike. Sve to utječe na njihovu korisnost i uporabljivost.

Noviji i sve popularniji pristup uključuje angažman zajednice u prikupljanju podataka. Korištenjem pametnih telefona opremljenih prijemnicima globalnog satelitskog navigacijskog sustava, pojedinci mogu aktivno pridonijeti prikupljanju podataka o buci u okolišu (Picaut i dr., 2021). Ti se podaci zatim mogu prikazati na interaktivnim kartama i koristiti za izradu karata buke unutar GIS-a. Iako ovaj pristup participativnog očitavanja možda ne nudi istu razinu točnosti kao tradicionalne metode, on predstavlja jeftinu alternativu opsežnim i skupim infrastrukturama senzora (Poslončec-Petrić i dr., 2021). Kombi-

nirajući podatke iz različitih izvora i uzimajući u obzir vremensku dinamiku, ova metoda ima potencijal proizvesti realističnije karte buke (Picaut i dr., 2019) i povećati svijest građana o izloženosti buci (Torres i Barros, 2017).

Glavni koncept volonterskog prikupljanja podataka jest njihovo dijeljenje sa zajednicom. Kako bi se to ostvarilo, omogućeno je njihovo objavljivanje putem servera na mreži. Uz određene dozvole korisnici dijele prikupljene podatke i tako se stvara baza dostupna svima za korištenje. Prikupljeni podaci o buci stoga moraju zadovoljiti određene uvijete kako bi bili usporedivi i primjenjivi.

Jedan od najvećih izazova u spomenutom konceptu prikupljanja podataka jest relevantnost prikupljenih podataka. Podaci se prikupljaju različitim mobilnim uređajima, čija točnost nije ujednačena. Također, podaci se prikupljaju u različitim uvjetima mjerenja. Kako bi se mjerenja građana uskladila, nužan korak prije provođenja samih mjerenja jest kalibracija mjernog uređaja. Uz pravu metodu kalibracije, podaci o razinama buke prikupljeni pametnim uređajima predstavljaju prikladne rezultate (Pődör i dr., 2015).

Princip volonterskog prikupljanja podataka buke temelji se na jeftinom, jednostavnom pristupu velikim skupovima podataka. Osim što je postupak kalibracije nužan, trebao bi biti i jednostavan (kako bi ga svi korisnici mogli savladati i primijeniti), jeftin (bez dodatnog troška korisnika) i ispravan (Torres i Barros, 2017).

U ovom radu usporedit će se dostupne metode kalibracije koje nude mobilne aplikacije na pametnim uređajima koje se koriste za volontersko prikupljanje podataka.

2. Mobilne aplikacije za volontersko prikupljanje podataka buke

Pametni uređaji sveprisutni su u svakodnevnom životu građana. Razvojem tehnologije povećava se i broj ugrađenih senzora na pametnim uređajima, pa tako neki od njih sadrže senzore za mjerenje temperature, tlaka, čak i izloženost svjetlu. Postoji bezbroj mogućnosti za prikupljanje podataka o okolišu i okruženju korištenjem pametnih telefona. To se isto odnosi i na mikrofone, odnosno senzore pomoću kojih se mogu prikupljati podaci o buci, što znači da pametni telefon potencijalno može poslužiti kao zgodan mjerač razine buke.

Danas postoji mnoštvo mobilnih aplikacija koje, uz pristup senzoru uređaja, koriste te podatke. Međutim, velika većina ne omogućava spremanje sirovih podataka, što je nužan preduvjet za njihovu obradu.

Također, potiče se proširivanje koncepta participativne znanosti na koncept otvorene znanosti. Poželjno je da je kod, bilo za aplikaciju, infrastrukturu prostornih podataka ili sučelje objavljen kao otvoreni kod. Isto tako, da su prikupljeni podaci dostupni u otvorenome pristupu svima na korištenje, s naglaskom na zajednicu znanstvenika i istraživača.

U nastavku su navedene najčešće korištene mobilne aplikacije za mnoštveno prikupljanje podataka buke. Spomenute su aplikacije odabrane jer su korištene od strane autora, dostupne za preuzimanje na pametne uređaje, i najčešće spominjane u literaturi, a zadovoljavaju kriterije za mnoštveno prikupljanje podataka o buci.

2.1. Noisetube

Jedan od prvih projekata uspostavljenih za participativno prikupljanje i obradu akustičnih podataka je Noisetube. Projekt je započeo 2008. u Sony Computer Science Lab, a sastoji se od web servera i aplikacije za pametne uređaje. Za kalibraciju ova aplikacija koristi tablicu "kalibrirana vrijednost izmjerene vrijednosti", tablicu za svaki model telefona, a zatim primjenjuje interpolaciju u intervalu u kojem je mjerenje (Torres i Barros, 2017). Izvorno su generirali ružičasti šum na različitim razinama svakih 5 dB, od 30 do 105 dB. Zatim su primjenom inverzne funkcije kao ispravke naknadne obrade dobili rezultate s pogreškom od 4 dB (Maisonneuve i dr., 2009).

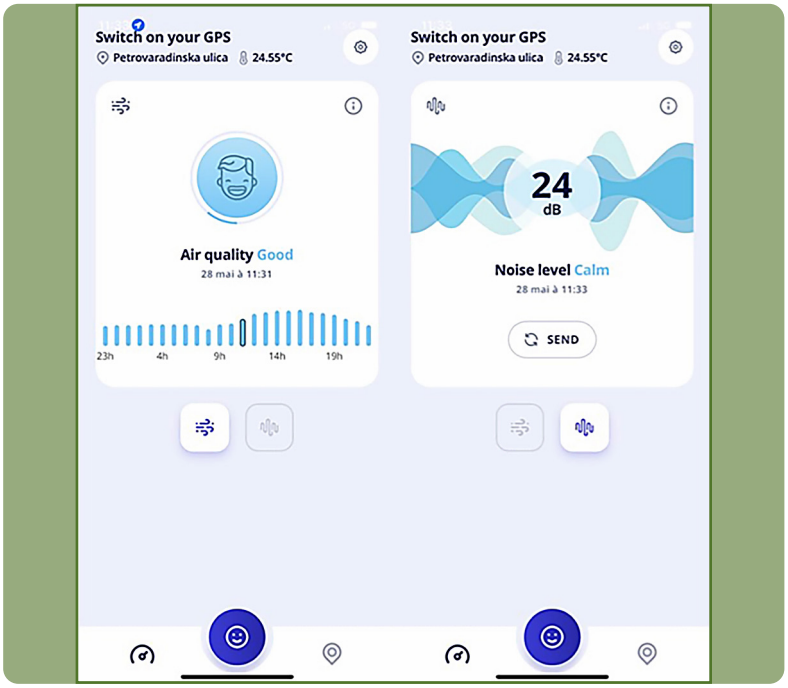
Aplikacija je bila jedan od ključnih alata tijekom iScope projekta (Poslončec-Petrić i dr., 2016), inicijalno omogućena za IOS i Android razvojne platforme. Nažalost, nakon 2015. godine nije bilo ažuriranja i aplikacija je ugašena.

2.2. Ambiciti

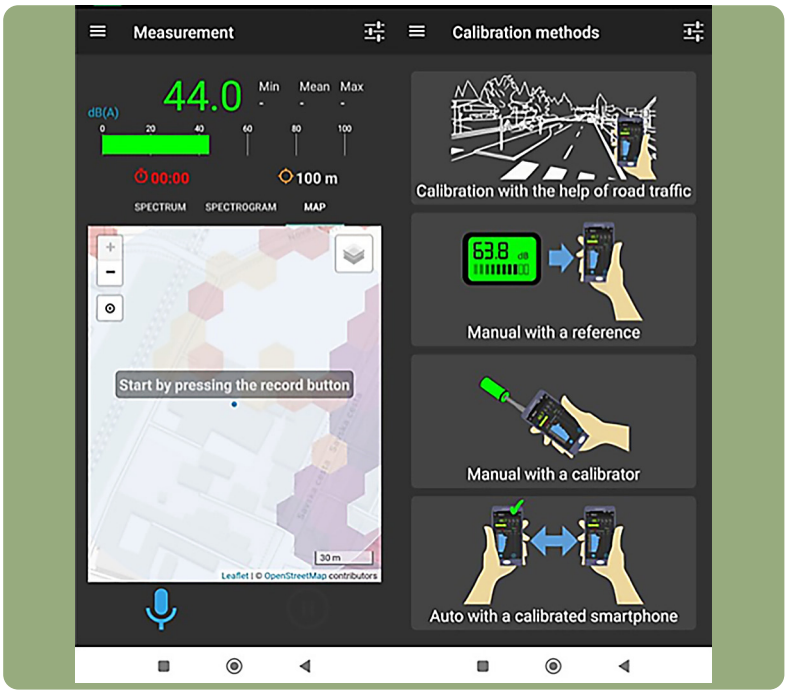
Ambiciti (prethodnog naziva SoundCity) informira o individualnoj i kolektivnoj izloženosti buci i onečišćenju zraka. Mjeri ambijentalne razine buke i nudi korisnicima mogućnost objavljivanja prikupljenih podataka na server (Hachem i dr., 2019). Glavna ideja projekta je omogućiti korisnicima izbor najboljeg smjera za kretanje urbanom sredinom kako bi smanjili izloženost visokim razinama buke (Slika 1). Ova usluga navigacije omogućena je u Amsterdamu, Londonu, Hamburgu, Helsinkiju, Parizu, San Franciscu i mnogim gradovima u Švicarskoj (URL 1). Aplikacija je dostupna za preuzimanje na IOS i Android platformi. Ventura i dr. (2017) su opisali primijenjeni algoritam u Ambiciti aplikaciji, međutim, jedan od glavnih nedostataka jest nemogućnost ručne kalibracije, te je iz tog razloga izuzeta iz daljnjeg ispitivanja.

2.3. Hush City

Hush City (URL 2) je besplatna mobilna aplikacija koja potiče korisnike na identifikaciju i procjenu mirnih urbanih područja kako bi stvorili otvoreni skup podataka i omogućili vizualizaciju razina buke u gradovima. Cilj projekta je angažirati građane da označe lokacije na kojima nema velike buke i na taj način potaknuti urbaniste i vladajuće za nadzor i zaštitu identificiranih područja. Hush City usvojila su gradska vijeća Berlina (2018.) i Limericka (2019.) u kontekstu izrade planova mirnih područja (URL 3, 4). Aplikacija je dostupna za preuzimanje na IOS i Android platformi, ali je zadnji put ažurirana 2021. godine i ne omogućava korištenje bez prethodne registracije koja ne radi. Iz toga razloga ova aplikacija nije testirana.



Slika 1: Sučelje Ambiciti mobilne aplikacije (izvor: autor)



Slika 2: Sučelje Noise Capture aplikacije (izvor: autor)

2.4. NoiseCapture

NoiseCapture projekt je potpuno u skladu sa svim zahtjevima koje volonterska zajednica treba (URL 5). Cilj uspostave platforme je osigurati dugoročno prikupljanje podataka kako bi se stvorila referentna baza podataka za dugoročno proučavanje zvuka (Picaut i dr., 2019). Poštivanje privatnosti i korištenje osobnih podataka također je temeljni element projekta; aplikacija ne prikuplja osobne podatke, a otvaranje korisničkog računa za korištenje aplikacije nije nužno. Naposljetku, velika pažnja usmjerena je u kvalitetu prikupljenih akustičnih podataka, integrirajući provjerene algoritme za obradu zvuka i omogućavajući korisnicima nekoliko metoda za kalibraciju pametnog telefona (Slika 2).

S obzirom na sve navedeno, u nastavku će se istražiti mogućnosti kalibracije unutar NoiseCapture sučelja kao najboljeg pokazatelja uspostave volonterskog prikupljanja akustičnih podataka.

3. Metode kalibracije u NoiseCapture aplikaciji

Umjeravanje (kalibriranje, baždarenje) je skup postupaka kojima se u određenim uvjetima uspostavlja odnos između vrijednosti mjernih veličina koje pokazuje neko mjerilo, neka tvarna mjera, neka usporedbena tvar ili neki mjerni sustav i odgovarajućih vrijed-

nosti ostvarenih pramjerama (URL 6). Umjeravanje osigurava sukladnost očitanja umjerenih mjerila. Korištenjem NoiseCapture mobilne aplikacije dostupna su četiri načina provođenja kalibracije (URL 7):

a. Kalibracija uz pomoć prometa – temelji se na niskoj varijabilnosti prosječne emisije buke pojedinačnih vozila. Glavna prednost ove metode je u tome što ne zahtjeva drugu opremu, odnosno uređaj. Metoda se sastoji od mjerenja razine buke nekoliko vozila dok prolaze kroz različite mjerne točke. Izmjerene razine uspoređuju se s razinama koje očekuje numerički model, a razlika služi kao pomak za sljedeća mjerenja. Usporedba s mjeračem razine zvuka klase 1 na 6 kontrolnih točaka pokazuje prosječnu pogrešku od -0,6 ± 1,2 dB(A) (Aumond i dr., 2020).

b. Usporedna kalibracija i c) Ručna kalibracija sa drugim uređajem – metodologija se temelji na poznavanju referentne vrijednosti za vrijednost buke Leq tijekom određenog vremena. Referentni uređaj može biti akustični kalibrator, prethodno kalibrirani pametni telefon ili mjerač razine zvuka (eng. *Sound Level Meter*, SLM). Ova referentna vrijednost se zatim uspoređuje s izmjerenim Leq pomoću pametnog telefona. Razlika između ove dvije vrijednosti daje faktor korekcije koji se primjenjuje na ulazni signal na pametnom telefonu.

c. Automatska kalibracija sa unaprijed kalibriranim mobilnim uređajem - u ovoj metodi, pametni telefon koji je već kalibriran pomoću NoiseCapture aplikacije može kalibrirati jedan ili više pametnih telefona. Postupak je u potpunosti automatski., a cijelim sustavom upravlja referentni (unaprijed kalibrirani) pametni telefon.

Nužno je naglasiti da se faktor korekcije primjenjuje na cijeli signal, odnosno da više-frekvencijska kalibracija nije moguća. Također, iskazane vrijednosti su u decibelima (dB), a ne db(A).

U Tablici 1 dan je pregled dobivenih vrijednosti razina zvuka obavljen usporednom kalibracijom i ručnom kalibracijom sa drugim uređajem u NoiseCapture mobilnoj aplikaciji. Kao referentni uređaj korišten je TROTEC SL300 uređaj (URL 9). Pametni telefon na kojem je instalirana i testirana aplikacija je Xiaomi 13 Lite (URL 10).

S obzirom da su mjerenja obavljena u kontroliranim uvjetima, smatramo kako su pogodni za usporedbu. Odabran je isti pametni uređaj kako bi se eliminirale razlike u tehničkim specifikacijama različitih uređaja. Sva mjerenja su obavljena 13.06.2024., u rasponu od 15 minuta, i tijekom mjerenja razina buke bila je konstantna. Provođenje kalibracije bilo je jednostavno, upute na sučelju same aplikacije jasne i koncizne te nije bilo problema u njihovom provođenju. Usporedno vrijeme očitavanja vrijednosti je bila jedna minuta. Iz očitanih vrijednosti vidljiva je varijacija u iznosima od 0.3 (dB) do 1.1 (dB) nakon usporedne kalibracije, i raspon vrijednosti do 0.6 (dB) nakon ručne kalibracije, što je dobar pokazatelj njihove pouzdanosti.

Isti dan obavljena je kalibracija uz pomoć prometa, istim mobitelom i referentnim uređajem. Odstupanja u očitanjima variraju između 1.6 (dB) i 3.5 (dB), a jedan od razloga može biti različita dinamika prometa i različita osjetljivost mikrofona na podražaje.

Automatska kalibracija sa unaprijed kalibriranim mobilnim uređajem nije testirana. Razlog tome je što ne posjedujemo dva ista pametna telefona te ne možemo izbjeći tehničku pogrešku u mikrofonu samog uređaja.

4. Zaključak

Strateške karte buke izrađuju se standardiziranim metodologijama i temelje se na različitim izvorima buke, kao što su cestovni promet, željeznički promet, industrijska postrojenja. Čovjekova okruženost bukom u urbanim sredinama puno je kompleksnija situacija koju je teško vizualizirati. Svima dostupni senzori u današnjim pametnim telefonima omogućuju njihovo korištenje putem mobilnih aplikacija za volontersko prikupljanje razina buke. Istaknuta prednost mjerača razine buke koji se temelji na pametnom telefonu je ta što može pružiti mjerenja razine buke gotovo bez dodatnih troškova - bez dodatnih troškova hardvera i bez dodatnog tereta nošenja dodatnog uređaja. Intuitivno i jasno sučelje jasno daje korisniku do znanja da je proces prikupljanja mjerenja proces podložan pogreškama i da je njegov zadatak osigurati što objektivnije podatke. Kako bi se smanjile razlike u tehničkim ograničenjima, nužan korak prije svakog mjerenja je kalibracija mjernog uređaja, u ovom slučaju pametnog telefona. Aplikacija NoiseCapture obuhvaća sve aspekte uspješnog mjerenja razine buke u korisnikovom okruženju, a testirane metode kalibracije unutar sučelja su se pokazale uspješnima i njihovi rezultati su zadovoljavajući. Predloženi pristup pruža identifikaciju zagađenja bukom i pomaže stvaranju svijesti ljudi o visokim razinama buke u njihovom okruženju.

Tablica 1: dobivene razine buke u ovisnosti od načina kalibracije

	Maksimalna razina zvuka [db] u Noise Capture	Minimalna razina zvuka [db] u Noise Capture	Maksimalna razina zvuka [db] na TROTEC SL300	Minimalna razina zvuka [db] na TROTEC SL300
Usporedna Kalibracija	36.5	31.6	35.4	31.9
Ručna kalibracija	35.1	32.1	35.1	31.5

Literatura

Aumond, P., Can, A., Gozalo, G. R., Fortin, N., Suárez, E. (2020): Method for in situ acoustic calibration of smartphone-based sound measurement applications, Applied Acoustics, Volume 166, 2020, 107337, ISSN 0003-682X, https://doi.org/10.1016/j.apacoust.2020.107337

Costa, D. G., Peixoto, J. P. J., Jesus, Thiago C., Portugal, P., Vasques, F., Rangel, Elivelton O., Peixoto, M. (2022): A Survey of Emergencies Management Systems in Smart Cities, Published in IEEE Access 2022, Environmental Science, Engineering, Computer Science

EU (2002): Directive 2002/49/EC of the European Parliament and the Council of 25 June 2002 relating to the assessment and management of environmental noise. Off. J. Eur. Communities 2002, 189, 2002.

Eulalia, P. (2023): Noise Pollution Is a Major Problem, Both for Human Health and the Environment. Dostupno na poveznici: https://www.eea.europa.eu/publications/environmental-noise-in-europe.

Grubeša, S.; Petoši´c, A.; Suhanek, M.; Đurek, I. (2018): Mobile crowdsensing accuracy for noise mapping in smart cities. Automatika 2018, 59, 286–293

Hachem, S., Mallet, V., Ventura, R., Pathak, A., Issarny, V., Raverdy, P. G., and Bhatia, R. (2015). „Monitoring noise pollution using the urban civics middleware," in 2015 IEEE First International Conference on Big Dana Computing Service and Applications (BigDataService), Piscataway, NJ, pp. 52–61

Maisonneuve, N., Stevens, M., Niessen, M. E., Steels, L. (2009): Noisetube: Measuring and mapping noise pollution with mobile phones, Information technologies in environmental engineering. Springer, 2009, pp. 215–228

NN 14/21: Zakon o zaštiti od buke, Narodne novine 14/2021.

Picaut, J.; Boumchich, A.; Bocher, E.; Fortin, N.; Petit, G.; Aumond, P. (2021): A smartphone-based crowd-sourced database for environmental noise assessment. Int. J. Environ. Res. Public Health 2021, 18, 7777.

Picaut, J.; Fortin, N.; Bocher, E.; Petit, G.; Aumond, P.; Guillaume, G. (2019). An open-science crowdsourcing approach for producing community noise maps using smartphones. Build. Environ. 2019, 148, 20–33.

Pődör, A., Révész, A., Ócsai, A., Ladomerszki, Z. (2015): Testing some Aspects of Usability of Crowdsourced, Journal for Geographic Information Science, Geospatial Minds for Society, GI_Forum, 2015 Volume 3, 2015, 354-358. 10.1553/giscience2015s354

Poslončec-Petrić, V., Cibilić, I., Frangeš, S. (2022). Crowdsourcing Application in the Development of a Dynamic Noise Map. In: Ademović, N., Mujčić, E., Akšamija, Z., Kevrić, J., Avdaković, S., Volić, I. (eds) Advanced Technologies, Systems, and Applications VI. IAT 2021. Lecture Notes in Networks and Systems, vol 316. Springer, Cham. https://doi.org/10.1007/978-3-030-90055-7_54

Poslončec-Petrić, V., Vuković, V., Frangeš, S., Bačić, Ž. (2016): Voluntary noise mapping for smart city, ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., IV-4/W1, 131–137, https://doi.org/10.5194/isprs-annals-IV-4-W1-131-2016, 2016.

Rossi, L.; Prato, A.; Lesina, L.; Schiavi, A. (2018): Effects of low-frequency noise on human cognitive performances in laboratory. Build.Acoust. 2018, 25, 17–33.

Schwela, D. (2021): Environmental noise challenges and policies in low-and middle-income countries. S. Fla. J. Health 2021, 2, 26–45.

Torres, F. & Barros G. J. (2017). Sound Noise Levels Calibration with Smart-phones.

UNHABITAT (2022): Envisaging the Future of Cities, World Cities Report 2022, https://unhabitat.org/sites/default/files/2022/06/wcr_2022.pdf

Ventura, R., Mallet, V., Issarny, V., Raverdy, P-G., Rebhi, F. (2017): Evaluation and calibration of mobile phones for noise monitoring application, J. Acoust. Soc. Am. 142, 3084–3093, https://doi.org/10.1121/1.5009448

URL 1: Ambiciti, first mobile app for street-level air and noise pollution launches in Europe, https://eit.europa.eu/news-events/news/ambiciti-first-mobile-app-street-level-air-and-noise-pollution-launches-europe, (4.6.2024.).

URL 2: Hush City, https://opensourcesoundscapes.org/hush-city/, (4.6.2024.).

URL 3: Berlin wird leiser, https://www.antonellaradicchi.it/portfolio/berlin-wird-leiser/, (4.6.2024.).

URL 4: Hush City Limerick, https://www.antonellaradicchi.it/portfolio/hush-city-4-limerick-eglc2020/, (4.6.2024.).

URL 5: NoiseCapture, https://noise-planet.org/noisecapture.html, (4.6.2024.).

URL 6: Umjeravanje. Hrvatska enciklopedija, mrežno izdanje. Leksikografski zavod Miroslav Krleža, 2013. – 2024. https://www.enciklopedija.hr/clanak/umjeravanje, (28.5.2024.).

URL 7: NoiseCapture calibration, https://noise-planet.org/noisecapture_calibration.html, (28.5.2024.).

URL 8: Zvuk, Razina zvuka, https://edutorij-admin-api.carnet.hr/storage/extracted/6b9de2eb-c6d7-412b-8afc-c0820325b64d/razina-zvuka.html, (28.5.2024.).

URL 9: Mjerni uređaj razine zvuka SL300, https://hr.trotec.com/proizvodi-i-usluge/mjerni-uredaji/emisija/mjerni-uredaji-razine-zvuka/sl300-mjerni-uredaj-razine-zvuka/, (28.5.2024.).

URL 10: Xiaomi 13 Lite, https://mi.hr/xiaomi-13-lite-8-256gb-black.html, (28.5.2024.).

Calibration of Smartphones in the Volunteer Noise Measurement

Abstract

The impact of daily and long-term exposure to constant noise can in some cases result in chronic diseases such as increased blood pressure or cardiovascular problems. In the last decade, the environmental community has been paying more and more attention to the problem of noise pollution in urban areas. Noise control in the environment appears as a key concern of society not only for public health but also for social well-being. Recently, there has been a growing interest in volunteer approaches to measuring noise levels in the environment using smartphones as sound measuring devices. Smartphones have become ubiquitous communication devices for the majority of the population. Relatively small with a rich set of applications, low power consumption and several types of sensors such as GPS, microphone, gyroscope, accelerometer, barometer, makes them a good candidate for creating applications for measuring and monitoring various environmental parameters. However, the lack of smartphone calibration can lead to significant discrepancies in the collected data. This paper aims to validate the effectiveness of smartphones for measuring noise with mobile applications that use a microphone as a sensor to detect the sound volume in the user's environment. Smartphone calibration, which is usually the user's responsibility, is a potential source of error and is a critical step in achieving favourable results. The work is focused on calibration principles for precise measurement of sound levels using microphones built into smartphones. To achieve this, we provide an overview of the available methods for effectively calibrating a standard smartphone microphone.

Keywords*: calibration, microphone, noise, sensor, smartphone*

Prostorno-vremenska analiza biciklističke aktivnosti upotrebom mnoštveno prikupljenih podataka

***Adam Vinković*[1], *Robert Župan*[1]**

[1] Geodetski fakultet, Kačićeva 26, 10 000 Zagreb, Hrvatska, avinkovic@geof.hr, rzupan@geof.hr

Sažetak

Vožnja bicikla predstavlja zdravu, ekonomičnu i za okoliš prihvatljivu alternativu motoriziranom prometu. U urbanim sredinama je posljednjih nekoliko godina zabilježen sve veći broj biciklista što je djelomično uzrokovano pandemijom koronavirusa. U želji da se poveća sigurnost prometa, a time i broj biciklista na cestama, gradske vlasti ulažu značajna sredstva u planiranje i izgradnju biciklističke infrastrukture. Kako bi se opravdalo financijska ulaganja te potvrdilo uspješno povećanje sigurnosti prometa, potrebno je raspolagati podacima o količini biciklističkog prometa. Dok za motorizirani promet postoji niz metoda za prikupljanje i analizu prometnog toka, podaci za biciklistički promet tradicionalno se prikupljaju ručnim brojanjem u vršnim satima ili automatskim brojačima na pojedinim točkama prometne mreže. Na taj način prikupljanje podataka na većem području u pravilu je financijski zahtjevno, vremenski dugotrajno, a prostorna i vremenska pokrivenost nisu dostatne za modeliranje uzorka biciklističkog prometa. Upotreba mobilnih aplikacija u praćenju sportskih aktivnosti doprinijela je velikoj količini tzv. mnoštveno prikupljenih prostornih podataka. Takve aplikacije omogućuju prikupljanje podataka neovisno o prostoru i vremenu, te kontinuirano bilježe rast broja korisnika što predstavlja izvrsnu priliku za istraživanje i analizu biciklističkog prometa. No samo manji postotak ukupne biciklističke populacije koristi mobilne aplikacije prilikom biciklističke aktivnosti što predstavlja izazov u pogledu njihove reprezentativnosti. U ovom radu izradit će se prostorno-vremenska geovizualna analiza jednog skupa mnoštveno prikupljenih podataka u svrhu razumijevanja biciklističke aktivnosti na području grada Zagreba.

Ključne riječi: *biciklistička aktivnost, biciklistički promet, geovizualna analiza, mnoštveno prikupljeni podaci, mobilna aplikacija*

1. Uvod

Vožnja bicikla, koju kolokvijalno nazivamo i biciklira-nje, dobiva sve veću važnost i ulogu u prometnim sustavima razvijenih zemalja. Neki od ključnih razlo-ga za to su prednosti koje su i znanstveno dokazane poput promicanja zdravlja, ekonomske isplativosti i smanjenja utjecaja na okoliš u usporedbi s motorizi-ranim vozilima (Lee i Sener, 2020). Posebice u urba-nim okruženjima koja karakteriziraju kratke udalje-nosti prometnih puteva i velika gustoća naseljenosti, popularnost biciklizma naglo je porasla posljednjih godina, a taj je trend dodatno ubrzan globalnom pandemijom koronavirusa (Büchel i dr., 2022). Ovaj porast biciklizma predstavlja kako prilike, tako i iza-zove za urbaniste i donositelje odluka koji teže una-prijediti sigurnost u prometu te razviti infrastrukturu koja može zadovoljiti rastući broj biciklista. Gradske su se vlasti diljem različitih regija odazvale tom tren-du ulaganjem značajnih resursa u planiranje i razvoj biciklističke infrastrukture (Buehler i Pucher, 2022). Ti napori usmjereni su ne samo na podršku trenutnom broju biciklista, već i na poticanje većeg broja ljudi da odaberu bicikl kao prijevozno sredstvo. Učinko-vito planiranje i izgradnja biciklističke infrastruktu-re ključni su ne samo za zadovoljenje trenutnih za-htjeva, već i za poticanje budućeg rasta sudjelovanja u biciklizmu. Za opravdanje tih ulaganja i procjenu učinkovitosti poboljšanja sigurnosti, ključni su de-taljni podaci o volumenu biciklističkog prometa. Za razliku od motoriziranog prometa, gdje se podaci o prometnom toku već desetljećima sustavno prikupljaju i analiziraju različitim metodama (Nordback i dr., 2013), poput automatskih brojača ili naprednih sustava nadzora, dobivanje točnih podataka o bicikli-stičkoj aktivnosti donosi posebne izazove koji u struč-noj literaturi još uvijek nisu dostatno obrađeni. Tradi-cionalno, podaci o volumenu biciklističkog prometa prikupljaju se ručnim brojanjem tijekom vršnih sati ili postavljanjem automatskih brojača na određenim lokacijama unutar prometne mreže. Međutim, ti su metodološki pristupi često skupi, vremenski zahtjev-ni te zasigurno ne pružaju dovoljnu prostornu i vre-mensku pokrivenost potrebnu za pouzdanu analizu uzoraka biciklističkog prometa na većim dijelovima urbanih područja (Jestico i dr., 2016).

Široka dostupnost mobilnih uređaja i pojava mobilnih aplikacija namijenjenih praćenju sportskih aktivnosti otvorila je novi pristup prikupljanju prostornih poda-taka. Takve aplikacije omogućuju korisnicima da ne-ovisno o lokaciji i vremenu bilježe svoje rute i razinu

aktivnosti, stvarajući vrijedne skupove prostornih podataka. Tim putem pojedinci dobrovoljno sudjeluju u prikupljanju velike količine podataka koje nazivamo mnoštveno prikupljeni podaci (MPP). U engleskom jeziku koristi se izvedenica '*crowdsourcing*', koja dolazi od engleskih riječi *'crowd'* (što znači mnoštvo ili gomila) i *'source'* (što znači izvor), te označava postupak u kojem se zajednica nepovezanih sudionika koristi za prikupljanje usluga ili podataka s ciljem rješavanja specifičnog problema koji bi inače bio previše radno intenzivan ili neisplativ (Misra i dr., 2014). Rastuća popularnost takvih aplikacija značajno je povećala dostupnost podataka o ponašanju biciklista, nudeći istraživačima i urbanistima neviđenu priliku za proučavanje i analizu trendova u biciklističkom prometu. Ipak, važno je napomenuti da, dok mobilne aplikacije pružaju vrijedne uvide u navike segmenta populacije biciklista, njihova upotreba i dalje je ograničena na manji postotak ukupne biciklističke populacije, što predstavlja izazov u pogledu reprezentativnosti šire biciklističke zajednice (Broach i dr., 2023). U tom kontekstu, ovaj rad ima za cilj istražiti implikacije tih trendova i napredaka u razumijevanju ponašanja biciklista na području Grada Zagreba upotrebom metoda geovizualne analitike.

2. Područje istraživanja, materijali i metode

Područje istraživanja je područje Grada Zagreba koje se proteže na 641,2 km^2, sastoji od 17 gradskih četvrti i prema posljednjem popisu stanovništva ima oko 770 tisuća stanovnika (URL 1). Ukupna duljina biciklističkih staza na području Zagreba, prema podacima dostupnima na web-stranici Portala otvorenih podataka Grada Zagreba (URL 2), iznosi 268,9 km. Za dobivanje tog iznosa potrebno je skinuti csv datoteku i zbrojiti duljine svih segmenata biciklističke mreže koji uključuju i neasfaltirane površine poput Savskog nasipa. Za provjeru smo skinuli s navedene web-stranice i shp datoteku, u kojoj se nalaze prostorni podaci biciklističkih staza, te učitali u geoinformacijskom sustavu QGIS i dobili vrijednost od 260,5 km.

U analizi biciklističke aktivnosti korišteni su podaci najpoznatije svjetske mobilne aplikacije (platforme) za praćenje tjelesnih aktivnosti — Strava Metro. Podaci su dostupni besplatno na zahtjev, ali uz uvjet da se u prijavi detaljno opiše projekt za koji će biti korišteni. U izradi ovog rada omogućen je pristup u svrhu doktorskog istraživanja. MPP-i aplikacije Strava predstavljaju globalno najznačajniji izvor za istraživanje biciklističke aktivnosti jer u odnosu na konkurentne aplikacije imaju najveći broj korisnika i zabilježenih aktivnosti (URL 3). Aplikacija omogućuje korisnicima bilježenje fizičkih aktivnosti pomoću GNSS tragova (koordinata) točaka kroz koje se prolazi i vremenskih oznaka povezanih s tim točkama. Dobiveni podaci su agregirani u različite geometrijske jedinice od kojih su za ovo istraživanje potrebni linijski segmenti prometne mreže. Generirani podaci uključuju prostorne datoteke u shp formatu i atributne tablice u csv formatu, koje pružaju informacije o broju putovanja tijekom različitih vremenskih okvira (dnevni, mjesečni ili godišnji) te prema svrsi putovanja, poput utilitarne vožnje (npr. putovanje na posao) i rekreativne vožnje. Jedna od glavnih značajki ovakvih MPP-a je njihova sposobnost da funkcioniraju kao kontinuirani sustav brojanja koji pokriva cijelo područje interesa (Lee i Sener, 2021). Za razliku od tradicionalnih sustava brojanja, koji su često ograničeni na mali broj lokacija ili kratkoročne periode implementacije, ovime se nudi gotovo kontinuirano praćenje kroz vrijeme i prostor sve dok korisnici aktivno koriste aplikaciju. Međutim, nepouzdanost u pogledu reprezentativnosti opće populacije i inherentnih pristranosti uzorkovanja mogu utjecati na točnost podataka. Osim toga, radi zaštite privatnosti korisnika, trećim stranama (korisnicima podataka) nisu pruženi demografski podaci o pojedincima ili specifične informacije o pojedinim putovanjima (aktivnostima).

MPP-i su skinuti na mjesečnoj i godišnjoj bazi za razdoblje od 2019. do 2023. godine te pohranjeni i pripremljeni za daljnju obradu u besplatnoj objektno-relacijskoj bazi otvorenog koda PostgreSQL. Ovisno o tome je li zabilježeno barem tri aktivnosti u pojedinoj godini na jednom linijskom segmentu prometne mreže, broj linijskih objekata (segmenata mreže) u bazi kreće se od 90 do 98 tisuća na godišnjoj razini. Numerička i statistička obrada podataka izvedena je u Microsoft Excel programskom paketu, a prostorna analiza i vizualizacija podataka upotrebom besplatnog geoinformacijskog sustava otvorenog koda QGIS 3.34.1.

U prvom koraku obrade MPP-a agregirani su podaci ukupne aktivnosti koji su dohvaćeni s pregledne podatkovne ploče (eng. dashboard) na web-stranici pružatelja podataka. Podaci su strukturirani na godišnjoj i mjesečnoj razini te podijeljeni prema ukupnom broju rekreativnih i utilitarnih vožnji. Potom su napravljeni grafički prikazi kako bi se analizirala sezonalnost biciklističke aktivnosti registrirana putem aplikacije. Izrađen je grafički prikaz ukupnog broja biciklističkih aktivnosti te omjera rekreativnih i utilitarnih aktivnosti MPP-a na godišnjoj razini u razdoblju od 2019. do 2023. (Slika 1), a potom i grafički prikaz ukupne biciklističke aktivnosti MPP-a prema mjesečnoj razdiobi u razdoblju od 2019. do 2023. (Slika 2). U drugom koraku dohvaćeni su podaci o broju korisnika aplikacije (u svrhu biciklističke aktivnosti) na mjesečnoj razini koji su važni kako bi se analiziralo povećanje broja korisnika aplikacije tokom godina i prema pojedinim mjesecima u godini te je izrađen grafički prikaz ukupnog broja korisnika aplikacije prema mjesečnoj razdiobi u razdoblju od 2019. do 2023. (Slika 3). U idućem koraku bilo je potrebno povezati atributne podatke i geometriju pojedinih linijskih segmenata kako bi bilo moguće vizualizirati podatke u QGIS-u, što je izvedeno upotrebom tzv. 'view'-a za pojedinu godinu promatranog razdoblja unutar baze podataka. Na taj način bilo je moguće u QGIS-u dodati geometriju i atribute pojedinog linijskog segmenta kao zaseban sloj za svaku godinu. Nakon što je izračunata srednja vrijednost (647,89) i standardno odstupanje (1448,08) ukupne aktivnosti svih linijskih segmenata za promatrano razdoblje od 2019. do 2023., definirana je klasifikacija podataka za vizualizaciju ukupne biciklističke aktivnosti prema po linijskim segmentima prometne mreže. Linij-

Tablica 1: Ukupni biciklistička aktivnost MPP-a na godišnjoj razini u razdoblju od 2019. do 2023.

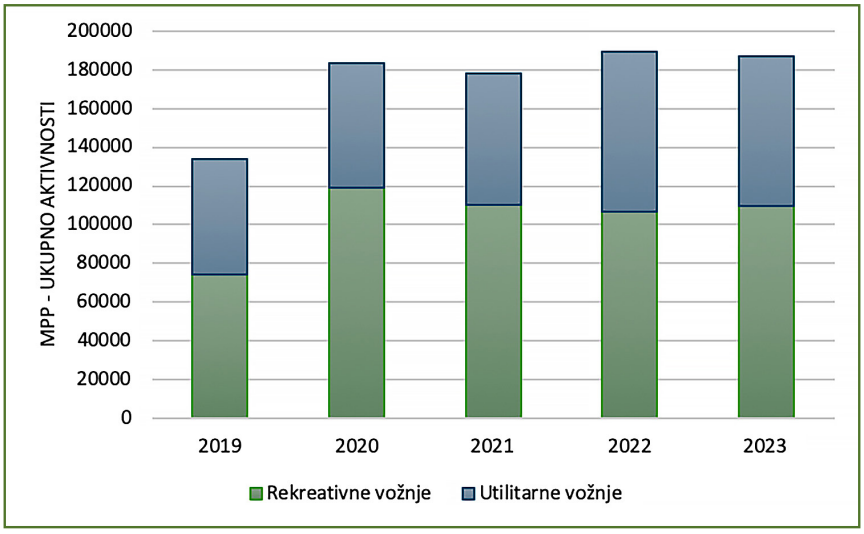
Godina	MPP ukupno	Rekreativne vožnje	%	Utilitarne vožnje	%
2019	133973	74021	55,25	59952	44,75
2020	183405	118940	64,85	64465	35,15
2021	178086	110464	62,03	67622	37,97
2022	189337	106636	56,32	82701	43,68
2023	186684	109458	58,63	77226	41,37

ski segmenti su podijeljeni na klase s niskim (0 - 650), srednjim (651 - 5000) i visokim (5001 i više) brojem aktivnosti na godišnjoj razini.

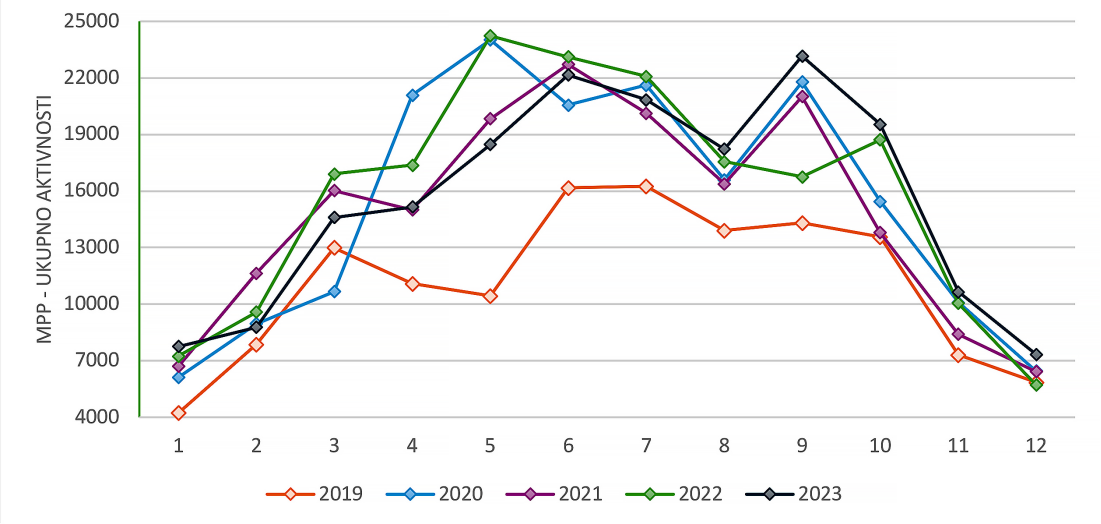
3. Rezultati

Ukupna količina biciklističke aktivnosti značajno raste u 2020., no nakon toga stagnira (Slika 1). Najveći broj rekreativnih vožnji zabilježen je upravo u 2020., kada dolazi do značajnog skoka rekreativnih vožnji u odnosu na utilitarne (Tablica 1). Prvenstveno se to može pripisati pandemiji koronavirusa (Francke, 2022). U 2022. zabilježen je najveći ukupni broj aktivnosti, no omjer rekreativnih i utilitarnih vožnji se vratio na gotovo isti omjer iz 2019. kada je okvirno iznosio 55 % naspram 45 %. U tablici je vidljivo kako broj utilitarnih vožnji iz godine u godinu raste, s iznimkom posljednje 2023. godine. Treba uzeti u obzir činjenicu da ove brojke predstavljaju samo dio aktivnosti te da je prema literaturi (Miah i dr., 2022) 1-10 % svih aktivnosti zabilježen putem Strava aplikacije. Iz vlastitog istraživanja znamo da se ta brojka u gradu Zagrebu kreće oko 1-3 % što znači da bi se stvarni broj biciklističkih aktivnosti na području grada Zagreba mogao kretati između 2 i 6 milijuna na godišnjoj razini.

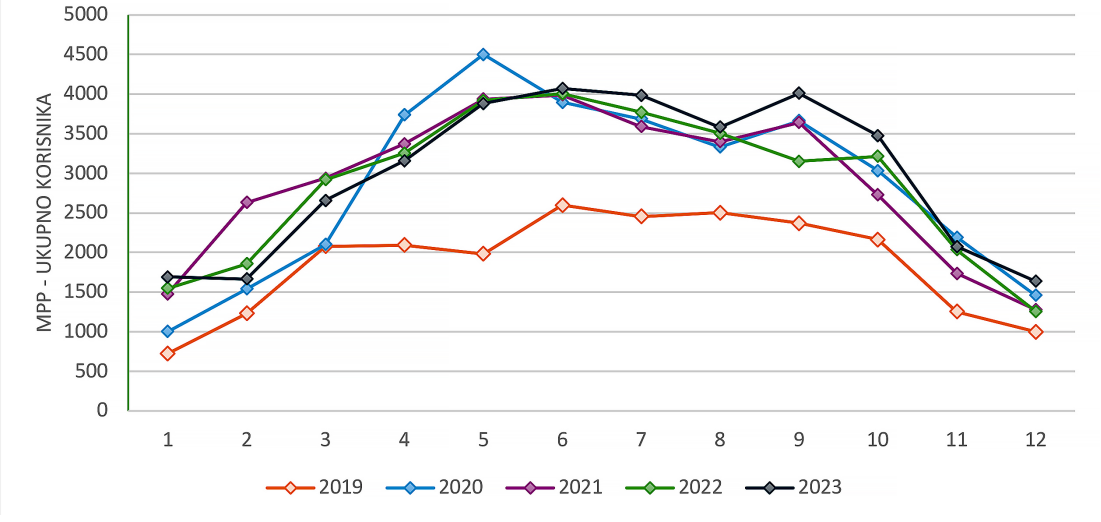
Slika 2 prikazuje vidljivu sezonalnost u biciklističkoj aktivnosti na području istraživanja. Osim što je očita krivulja rasta i pada aktivnosti ovisno o kretanju godišnjih doba, zanimljivo je utvrditi kako kolovoz pokazuje značajan pad ukupne aktivnosti. To ukazuje na vjerojatnost da dobar dio stanovništva tada uzima godišnji odmor i da meteorološki uvjeti, zbog velikih vrućina, nisu idealni za vanjske aktivnosti. Biciklistička aktivnost najveća je od 5. do 7. mjeseca, a najmanja od 11. do 2. Važno je promotriti plavu krivulju za razdoblje od ožujka do svibnja 2020., odnosno period u kojem je većina stanovništva bila zatvorena u svojim domovima zbog tzv. 'lockdowna' uslijed pandemije koronavirusa. Najveći skok u ukupnoj aktivnosti dogodio se upravo u tom periodu jer su korisnici aplikacije tada imali najviše slobodnog vremena i potrebe za kretanjem. U ožujku, kada je započeo tzv. 'lockdown', dobar dio populacije nije izlazio iz svojih domova, pa je sukladno tome u tom mjesecu zabilježen i najniži broj aktivnosti u odnosu na druge godine. Već idući mjesec zabilježen je najveći broj aktivnosti u odnosu na ostale godine promatranog razdoblja. S obzirom da na biciklističku aktivnost utječu različiti vanjski čimbenici, poput meteorološke situacije, ponekad je moguće da određeni mjesec nema uobičajenu razinu aktivnosti. Primjer toga je rujan 2022. Nažalost, detaljnija analiza koja bi uključivali veći broj čimbenika nije moguća u okviru ovog rada. Slika 3. prikazuje ukupan broj korisnika aplikacije prema mjesečnoj razdiobi iz čega se može vidjeti da je 2019. broj mjesečnih korisnika bio najmanji te da je, slično kao i sa ukupnom aktivnošću, u travnju 2020. naglo



Slika 1: Grafički prikaz ukupnog broja biciklističkih aktivnosti te omjera rekreativnih i utilitarnih aktivnosti MPP-a na godišnjoj razini u razdoblju od 2019. do 2023.



Slika 2: Grafički prikaz ukupne biciklističke aktivnosti MPP-a prema mjesečnoj razdiobi u razdoblju od 2019. do 2023.



Slika 3: Grafički prikaz ukupnog broja korisnika aplikacije prema mjesečnoj razdiobi u razdoblju od 2019. do 2023.

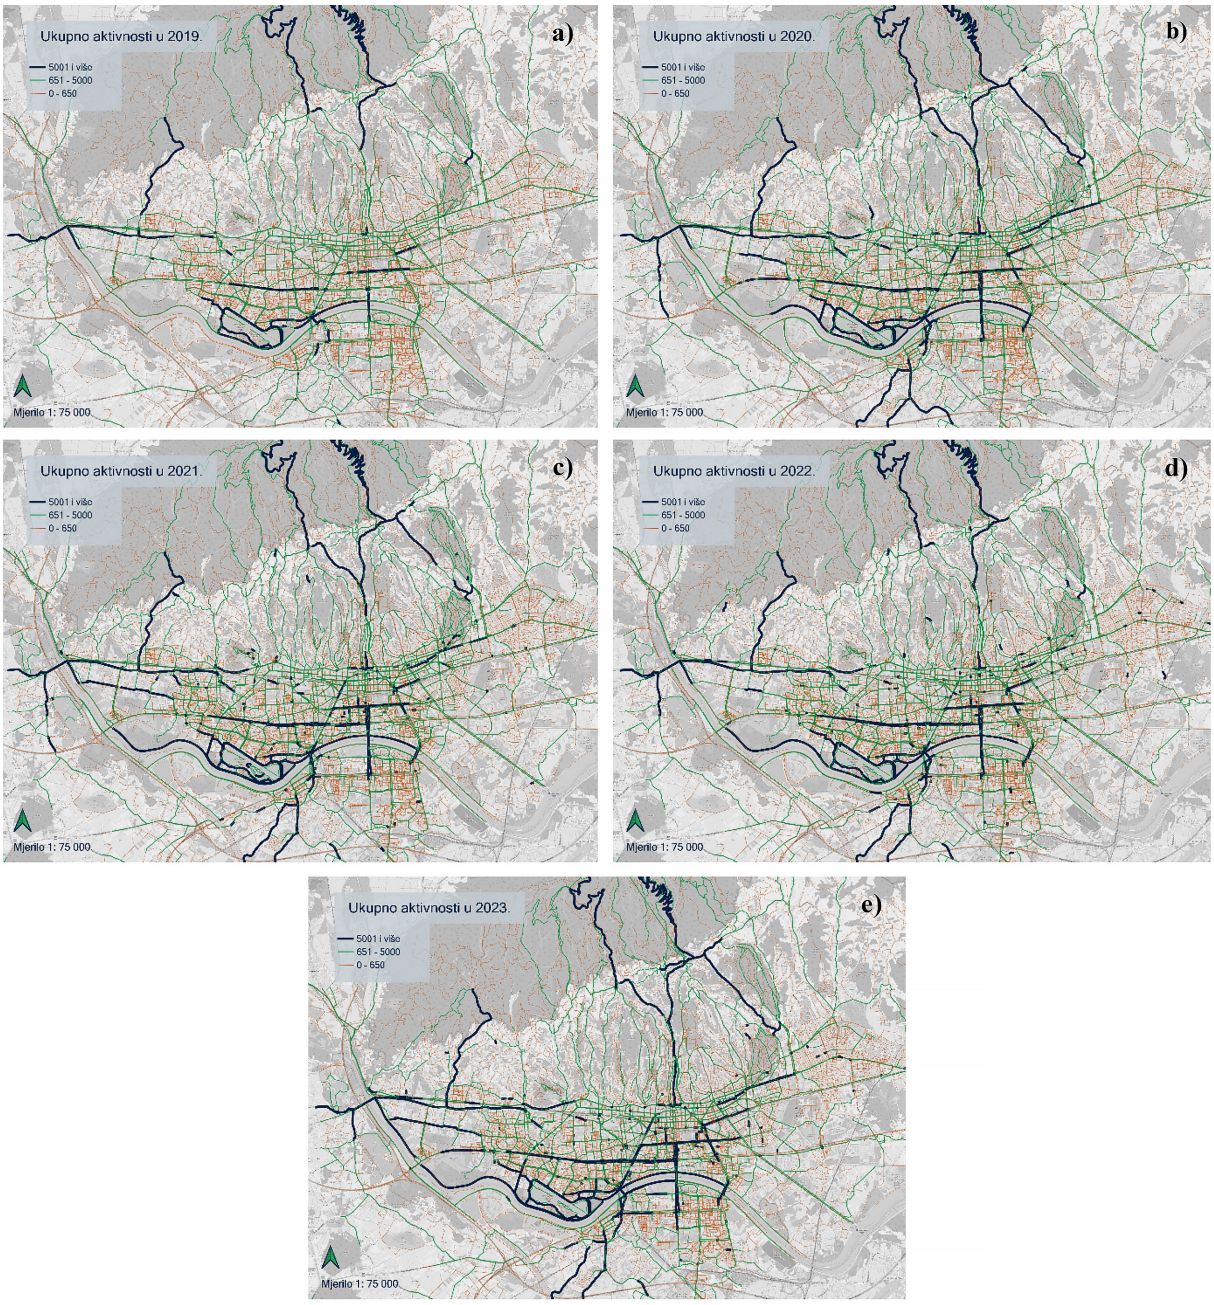
skočio, a u svibnju 2020. postigao maksimum promatranog razdoblja. To ukazuje na činjenicu da je tada veliki broj novih korisnika započeo bilježiti aktivnosti. Nakon toga vidljiv je sličan uzorak kao i kod ukupne aktivnosti, a broj mjesečnih korisnika aplikacije kreće se od 1500 u zimskim mjesecima do 4000 u ljetnim.

Kako bi se klasificirali i vizualizirali podaci ukupne biciklističke aktivnosti, izračunate su srednja vrijednost i standardna devijacija, s iznosima od 647,89 i 1448,08. Standardna devijacija je više nego dvostruko veća od srednje vrijednosti što ukazuje na činjenicu da je velik broj vrijednosti ukupnog broja vožnji po segmentima u promatranom periodu znatno udaljen od srednje vrijednosti skupa podataka. To je indikacija da su vrijednosti podataka ukupne aktivnosti visoko disperzirane. Visokoj raspršenosti unutar skupa podataka mogu pridonositi ekstremno visoke vrijednosti ili odstupanja. U našem slučaju znamo da je problem u velikom broju linijskih segmenata koji imaju izuzetno malu količinu ukupne aktivnosti u cjelokupnom promatranom razdoblju (<10). Podaci su klasificirani u tri klase prema ukupnoj aktivnosti na pojedinom linijskom segmentu prometne mreže: niska (0 - 650), srednja (651 - 5000) i visoka (5001 i više). Na izrađenim kartama (Slika 4) jasno su vidljiva područja visoke aktivnosti, a ona obuhvaćaju područje oko jezera Jarun, Sljemensku cestu, Samoborsku cestu, Savski nasip, Zelenu magistralu, ali i značajnije gradske prometne ulice poput Zagrebačke, Slavonske, Vukovarske, Ilice, Aleje grada Bolonje, Avenije Većeslava Holjevca, Maksimirske, Zvonimirove i Branimirove. To ukazuje na činjenicu da se veliki broj aktivnosti odvija na najznačajnijim prometnicama u gradu, ali i na najpopularnijim lokacijama za sportsku rekreaciju. U 2020. se, u odnosu na 2019., u gornjoj klasi pojavljuje veliki broj linijskih segmenata koji povezuju spomenute lokacije s ostalim dijelovima grada, poput Gračanske ceste, Mlinova, Jazbine, te južnih cesta koje vode prema izlazu iz grada. To pokazuje povećanje broja rekreativnih vožnji koje se očituje i iz podataka. Zbog mjerila karte nisu moguće detaljnije analize pojedinih lokacija, no očito je kako je protekom vremena mreža linijskih segmenata koji prelaze iz

srednje u visoku klasu sve gušća. Zanimljivo je kako se ti segmenti većinom naslanjaju na prethodne s visokom aktivnošću što znači da tamo gdje postoji velika aktivnost treba uzeti u obzir i okolno područje u kontekstu analize biciklističke aktivnosti.

4. Zaključak

Prostorno-vremenska analiza biciklističke aktivnosti u Zagrebu, temeljena na mnoštveno prikupljenim podacima aplikacije Strava, pokazala je značajan rast biciklističke aktivnosti u razdoblju od 2019. godine do 2023. Unatoč visokoj disperziji MPP biciklističke aktivnosti po linijskim segmentima mreže, analiza je omogućila prepoznavanje ključnih područja intenzivne biciklističke aktivnosti, uključujući popularne rekreativne lokacije i glavne gradske prometnice. Pandemija koronavirusa rezultirala je značajnim porastom rekreativnog biciklizma, što je dodatno proširilo mrežu segmenata s visokom aktivnošću. Ovi nalazi naglašavaju važnost kontinuiranog praćenja i prilagođavanja biciklističke infrastrukture kako bi se zadovoljile potrebe rastuće biciklističke populacije te unaprijedila sigurnost i kvaliteta prometne mreže. Podaci prikupljeni iz mnoštva pružaju vrijedne uvide za planiranje i razvoj urbane biciklističke infrastrukture, ali također ukazuju na potrebu za dodatnim istraživanjima kako bi se poboljšala reprezentativnost i preciznost ovakvih podataka. Za detaljniju analizu bilo bi potrebno obraditi pojedine lokacije od interesa te analizirati utjecaje pojedinih vanjskih



Slika 4: Karte ukupne biciklističke aktivnosti prema MPP-a po linijskim segmentima prometne mreže za: a) 2019., b) 2020., c) 2021., d) 2022., e) 2023.

čimbenika na ukupnu biciklističku aktivnost, kao što su meteorološki uvjeti, biciklistička infrastruktura i demografski podaci.

Literatura

Broach, J., Kothuri, S., Miah, M. M., McNeil, N., Hyun, K. K., Mattingly, S., Nordback, K., Proulx, F. (2023): „Evaluating the Potential of Crowdsourced Data to Estimate Network-Wide Bicycle Volumes", *Transportation Research Record*. SAGE Publications Ltd.

Büchel, B., Marra, A. D., Corman, F. (2022): „COVID-19 as a window of opportunity for cycling: Evidence from the first wave", *Transport Policy*. Elsevier Ltd, 116, str. 144–156.

Buehler, R., Pucher, J. (2022): „Cycling through the COVID-19 Pandemic to a More Sustainable Transport Future: Evidence from Case Studies of 14 Large Bicycle-Friendly Cities in Europe and North America", *Sustainability (Switzerland)*, 14(12).

Francke, A. (2022): „Cycling during and after the COVID-19 pandemic", u *Advances in Transport Policy and Planning*. Elsevier B.V., str. 265–290.

Jestico, B., Nelson, T., Winters, M. (2016): „Mapping ridership using crowdsourced cycling data", *Journal of Transport Geography*. Elsevier Ltd, 52, str. 90–97.

Lee, K., Sener, I. N. (2020): „Emerging data for pedestrian and bicycle monitoring: Sources and applications", *Transportation Research Interdisciplinary Perspectives*. Elsevier Ltd.

Lee, K., Sener, I. N. (2021): „Strava Metro data for bicycle monitoring: a literature review", *Transport Reviews*. Routledge, 41(1), str. 27–47.

Miah, M. M., Hyun, K. K., Mattingly, S., Broach, J., McNeil, N., Kothuri, S. (2022): „Challenges and Opportunities of Emerging Data Sources to Estimate Network-Wide Bike Counts", *Journal of Transportation Engineering, Part A: Systems*. American Society of Civil Engineers (ASCE), 148(3). doi: 10.1061/jtepbs.0000634.

Misra, A., Gooze, A., Watkins, K., Asad, M., Le Dantec, C. (2014): „Crowdsourcing and its application to transportation data collection and management", *Transportation Research Record*, (2414), str. 1–8.

Nordback, K., Marshall, W., Janson, B., Stolz, E. (2013): „Estimating annual average daily bicyclists", *Transportation Research Record*. National Research Council, (2339), str. 90–97.

URL 1: Zagreb - Wikipedija, https://hr.wikipedia.org/wiki/Zagreb, (20.6.2024.).

URL 2: Geoportal biciklističke staze - Skup podataka - Portal otvorenih podataka, https://data.zagreb.hr/dataset/geoportal-biciklisticke-staze (20.6.2024.).

URL 3: Strava, https://press.strava.com/about (20.6.2024.).

Spatiotemporal Analysis of Cycling Activity Using Crowdsourced Data

Abstract

Cycling represents a healthy, economical, and environmentally friendly alternative to motorized traffic. In urban areas, the number of cyclists has been increasing in recent years, partly due to the coronavirus pandemic. To enhance traffic safety and consequently increase the number of cyclists on the roads, city authorities are investing significant resources in planning and constructing cycling infrastructure. To justify financial investments and confirm successful improvements in traffic safety, it is necessary to have data on cycling volume. While there are various methods for collecting and analyzing traffic flow data for motorized traffic, data for cycling traffic is traditionally collected through manual counting during peak hours or automatic counters at specific points in the traffic network. This data collection method over larger areas is generally financially demanding, time-consuming, and spatial and temporal coverage is insufficient for modeling cycling traffic patterns. The use of mobile applications in tracking sports activities has contributed to a large amount of so-called crowdsourced spatial data. These applications enable data collection independently of space and time and continuously record an increasing number of users, representing an excellent opportunity for researching and analyzing cycling traffic. However, only a small percentage of the total cycling population uses mobile applications during cycling activities, which poses a challenge regarding their representativeness. This paper will conduct a spatiotemporal geovisual analysis of a set of crowdsourced data to understand cycling activity in the city of Zagreb.

Keywords: *crowdsourced data, cycling activity, cycling traffic, geovisual analysis, mobile application*

2.

NOVI PRISTUPI UREĐENJU ZEMLJIŠTA

Prijedlog preporučene cijene proizvodnog sata geodetskog stručnjaka

Stjepan Miletić[1], Filip Pavelić[1], Damir Delač[2]

[1] Zavod za fotogrametriju d.d., Borongajska cesta 71, Zagreb, Hrvatska, filip.pavelic@zzf.hr, stjepan.miletic@zzf.hr

[2] Geodetski zavod Rijeka, Ulica dr. Frana Kresnika 33, Rijeka, Hrvatska, Damir.D@gzr.hr

Sažetak

Vrijednost rada geodetskog stručnjaka definira stanje tržišta. Postoji niz usluga koje geodeti mogu isporučiti na tržište. Normiranje svih usluga bilo bi izuzetno zahtjevno i složeno. Postojali su načini da se to postigne, ali nisu našli svoju svakodnevnu i širu primjenu. Značajan tehnološki razvoj proširuje mogućnosti rada te ga istovremeno ubrzava, a u takvim okolnostima geodetskom stručnjaku postaje sve teže procijeniti u kojem iznosu naplatiti traženu uslugu. To dalje rezultira značajnim dampingom cijena geodetskih usluga na tržištu na čije povećanje utjecaj nema niti stopa inflacije. U ovom radu prikazat će se koliko otprilike efektivnih radnih sati ima geodetski stručnjak u jednoj kalendarskoj godini. Uzet će se u obzir godišnji troškovi koji su potrebni geodetskoj tvrtki kako bi nesmetano obavljala svoju djelatnost na tržištu. Povezivanjem navedenih podataka slijedi izračun i kategoriziranje efektivnog radnog sata. U konačnici dat će se prijedlog za definiranje preporučene vrijednosti proizvodnog radnog sata geodetskog stručnjaka.

Ključne riječi: *efektivni sat, geodezija, preporučeni cjenik, proizvodni sat, troškovi*

1. Uvod

Poznata nam je rečenica kako su nekada u selu bili najvažnije osobe: svećenik, liječnik, učitelj i geodet. Tako je čovjek imao skrb o duši, tijelu, znanju i zemlji. Danas još možemo razgovarati s kolegama koji su živjeli u vremenu kada se status i rad geodeta u društvu poštovao. Isto tako, danas imamo priliku biti svjedoci vremena kada status geodeta i vrijednost geodetskih usluga koje isporučujemo našim naručiteljima vrtoglavo pada. Zašto je to tako?

Naše su usluge veoma značajne iz razloga što se odnose na državne evidencije. Nažalost, nemamo službeni cjenik geodetskih usluga koji bi nam olakšao formiranje cijene prema naručitelju i možda na taj način održao vrijednost geodetske usluge u realnim okvirima.

Hrvatska komora ovlaštenih inženjera geodezije (u daljnjem tekstu: HKOIG) donijela je 22. veljače 2021. godine Standard geodetskih usluga (u daljnjem tekstu: Standard) kojemu je svrha pružiti informacije naručiteljima geodetskih usluga o vremenu koje je potrebno za obavljanje određenog posla. Standardom su propisane prosječne količine vremena i materijala potrebne za ekonomski najpovoljnije obavljanje geodetskog posla. Nadalje, prosječno vrijeme u sebi sadrži troškove za: sve naknade, plaće, licence za programsku opremu, amortizaciju, računala, najamnine, put, računovodstvo, knjigovodstvo, osiguranja te dobit i porez (HKOIG, 2021). Pomoću standarda moguće je izračunati utrošak vremena za radove iz članka 5. i 6. Zakona o obavljanju geodetske djelatnosti. Velika prednost Standarda je detaljan raspis svih geodetskih poslova prema fazama te koeficijentima svake faze ovisno o zahtjevnosti. Međutim, ta detaljnost iziskuje ulaganje puno vremena kako bi se izračunalo ukupno potrebno vrijeme za obavljanje geodetskog posla.

U ovom radu dat će se jednostavan prijedlog izračuna tržišne vrijednosti efektivnog/proizvodnog bruto sata geodetskog stručnjaka koji bi bio nadopuna Standardu i koji bi omogućio precizniji izračun cijene geodetskog posla što bi za cilj imalo značajno smanjenje subjektivnog utjecaja na cijenu od strane onoga tko je formira – naručitelj i geodetski izvoditelj.

2. Troškovi tvrtke

Za potrebe ovoga rad uzet ćemo geodetsku tvrtku koju čine dva iskusna geodetska stručnjaka: *ovlašteni inženjer geodezije i geodetski tehničar.* Troškove koje tvrtka ima na godišnjoj razini podijelit ćemo u četiri kategorije:

- troškovi zaposlenika
- troškovi ureda
- troškovi terena
- ostali troškovi

Amortizacija za računala, printer, skener i alat (mjerene vrpce, čekić, kosir, …) definirana je na 3 godine, a za automobile, GNSS uređaje i mjerne stanice na 7 godina.

Troškovi zaposlenika. U ovu kategoriju spadaju svi oni troškovi koji su vezani za zaposlenike, a to su:

- bruto plaće,
- putni troškovi,
- nagrade (Božić, Uskrs, sv. Nikola, radni rezultati, regres, …),
- radna odjeća,
- HKOIG (članarina, osiguranje),
- edukacije (simpoziji, kongresi, tečajevi, …),
- druženja u organizaciji tvrtke (*teambuilding*),
- članstvo u Hrvatskom geodetskom društvu.

Za prosječnu mjesečnu plaću iskusnog ovlaštenog inženjera geodezije definiran je bruto iznos od 2.125,00 €, a iskusnog geodetskog tehničara 1.517,00 €. Ovo su podaci iz istraživanja koje je provedeno među milenijalcima 2022. godine (Miletić i Friščić, 2022). Međutim, uzeta je u obzir stopa inflacije za period od lipnja 2022. godine do lipnja 2024. godine koja iznosi 10.2 (URL 1). Tako da bi danas iznosi tih plaća bili 2.340,00 € i 1.670,00 €.

Ukupan prosječni godišnji trošak zaposlenika iznosi oko 55.000,00 €.

Troškovi ureda. Za uredsko obavljanje posla potrebno je imati osnovnu opremu. U ovu kategoriju spadaju:

- računala s operativnim sustavom,
- CAD softver,
- printer,
- skener,
- uredski materijal (papir, toneri),
- pošta,
- web stranica.

Ukupan prosječni godišnji trošak ureda na godišnjoj razini iznosi oko 11.000,00 €.

Troškovi terena. Za kategoriju terena potrebno je da tvrtka ima osigurano:

- GNSS uređaj,
- mjernu stanicu,
- automobil i održavanje automobila,
- gorivo i cestarine,
- međne oznake, sprejevi, bolcne,
- alati.

Što se tiče geodetskog instrumentarija i automobila, u obzir su uzeti prosječni cjenovni razredi – niti najskuplje, niti najjeftinije. Ukupan prosječni godišnji trošak za kategoriju terena iznosi oko 10.000,00 €.

Ostali troškovi. U kategoriju ostalih troškova ulaze svi oni troškovi koje zapravo podržavaju prve tri kategorije, odnosno njihovo funkcioniranje, a to su:

- knjigovodstvo,
- internet,
- telefon,
- najam prostora,
- banka (vođenje računa),
- troškovi reklame (kalendari, olovke, kišobrani, …),
- troškovi reprezentacije.

Ukupan prosječni godišnji trošak za kategoriju ostalih troškova iznosi oko 17.000,00 €.

Za napomenuti je da su svi prije navedeni troškovi realnost. Možda postoje tvrtke koje određene troškove nemaju, posebno iz prve kategorije za koju možemo reći da je zapravo najvažnija jer to je ulaganje u ljude.

Zbrojimo li sve kategorije vidjet ćemo kako nam je za funkcioniranje ovakve jedne tvrtke na godišnjoj razini potrebno gotovo 93.000,00 €. Ovaj iznos je potreban samo da bi tvrtka „preživljavala" - bez dobiti.

3. Efektivni sat

Nakon što smo izračunali prosječan godišnji trošak geodetske tvrtke, slijedi izračun ukupnog broja efektivnih/proizvodnih radnih sati u jednoj kalendarskoj godini.

Za potrebe ovoga rada uzet će se 2024. godina koja bez subota i nedjelja ima ukupno 2096 radnih sati. U nastavku ćemo navesti sve one neproizvodne sate koji se dogode ili se mogu dogoditi u jednoj kalendarskoj godini.

Blagdani, svetkovine i praznici. U cijeloj 2024. godini imamo ukupno 10 dana koji se ne poklapaju s vikendom. To su dani kada ne radimo, ali za njih primimo plaću. Ove godine imali smo još jedan takav dan – srijeda, 17. travnja kada su bili održani Parlamentarni izbori u Hrvatskoj. Broj ovih dana razlikuje se od godine do godine, a najviše ih u jednoj godini može biti 11. S obzirom da se parlamentarni izbori ne održavaju svake godine, uzet ćemo da u 2024. godini na blagdane, svetkovine i praznike otpada ukupno 10 dana – 80 sati.

Godišnji odmor. Sukladno Zakonu o radu (u daljnjem tekstu: Zakon) zaposlenik ima pravo na godišnji odmor u trajanju od najmanje četiri tjedna za svaku kalendarsku godinu. Kako je prije navedeno da se analiza radi za tvrtku u kojoj rade dvoje iskusnih geodetskih stručnjaka, uzeli smo da oni imaju pravo na 26 dana godišnjeg odmora – 208 sati.

Plaćeni dopust. Za važne osobne potrebe (sklapanje braka, rođenje djeteta, darivanje krvi, teža bolest, smrt člana uže obitelji, obrazovanje, usavršavanje i sl.) zaposlenik ima pravo na plaćeni dopust u ukupnom trajanju od 7 dana – 56 sati.

Bolovanje. Prema podacima Hrvatskog zavoda za zdravstveno osiguranje, prosječan broj privremene nesposobnosti za rad u 2023. godini iznosio je 11,49 dana što je manje u odnosu na 2022. godinu kada je on iznosio 12,92 dana (HZZO, 2024). U izračunu za ovaj rad, prosječan broj dana za bolovanja, odnosno privremenu nesposobnost za rad, zaokružen je na 11 dana – 88 sati.

Dnevni odmor. Prema Zakonu (NN 64/23) zaposlenik ima pravo na odmor u trajanju od 30 minuta. Ako od ukupnog broja sati oduzmemo do sada navedene stavke (godišnji odmor, plaćeni dopust i bolovanje), dobijemo ukupno 1664 sata što odgovara 208 radnih dana. U svakom od tih dana zaposlenik ima pravo koristiti stanku koja je također neproizvodno vrijeme što za navedeni broj iznosi 13 dana – 104 sata.

Tablica 1: Broj efektivnih/proizvodnih radnih sati

Kategorija	Broj dana	Broj sati	Broj efektivnih sati kad se oduzmu neproizvodni sati
Ukupno na početku godine	261	2088	2088
Blagdani, svetkovine, praznici	-10	-80	2008
Godišnji odmor	-26	-208	1800
Plaćeni dopust	-7	-56	1744
Bolovanje	-11	-88	1656
Dnevni odmor	-13	-104	1552
Režijski troškovi	-31	-248	1304
Utjecaj više sile	-10	-80	1224
Tehnologija	-26	-208	1016
Ostalo	-26	-208	808
Ukupno	**101**	**808**	

U nastavku ćemo navesti sve one neproizvodne sate koji nisu zakonski definirani, ali su dio svakodnevnog života.

Režijski troškovi. U kategoriju režijskih troškova mogu se uvrstiti sljedeće aktivnosti: sastanci, edukacije, poslovni pozivi i sl. U manjim tvrtkama najčešće računovodstvene poslove obavlja sam direktor (troši vrijeme) ili te usluge plati nekoj vanjskoj tvrtki (troši novac). U velikim tvrtkama prosječno 15% zaposlenika čini režijsko osoblje – zaposlenici koji ne rade izravno na proizvodu (direktor, voditelji, administrativno osoblje, …). Ako taj postotak primijenimo na 208 radnih dana, dobijemo da na režijske troškove otpadne 31,2 radna dana, zaokružit ćemo na 31 radni dan – 248 sati.

Utjecaj više sile. Dogodit će se na poslu situacije na koje ne možemo utjecati, a značajno će poremetiti planirano obavljanje posla. Vremenske neprilike, nedostatak materijal, kašnjenje isporuke materijala, prekid opskrbe električnom energijom, samo su neke od situacija koje nas mogu zateći. Utjecaj više sile prosječno oduzima oko 5% radnih sati što je u našem slučaju 10,4 radnih dana, zaokružit ćemo na 10 radnih dana – 80 sati.

Tehnologija. Utjecaj tehnologije na poslu obuhvaća korištenje pametnih mobitela, pregledavanje („skrolanje"), „surfanje" i sl. Procjenjuje se da zaposlenik na ovo utroši prosječno 56 minuta dnevno (URL 2). Zbog korištenja tehnologije događaju se ometanja i prekidi u poslu, a da bismo se vratili na razinu koncentracije koju smo imali prije prekida, potrebno je 23 minute i 15 sekundi (Mark i ostali, 2008). Zaposlenik će u danu napraviti gotovo 1200 prebacivanja između aplikacija i web stranica i prosječno primiti oko 63 obavijesti (mail i drugi kanali komunikacije) (URL 3). To bi značilo sljedeće: ako se prilikom obavljanja posla u kojem smo visoko koncentrirani dogode tri prekida, izgubit ćemo najmanje 1 efektivni sat. Uzet ćemo da na kategoriju tehnologije otpadne na godišnjoj razini ukupno 26 dana – 208 sati.

Ostalo. U ovu kategoriju možemo ubrojiti sve ono što će se na poslu sigurno dogoditi, a može ili ne mora biti predviđeno. Neki od najčešćih takvih događaja su: usputni razgovori s kolegama, kuhanje jutarnje kave, privatni pozivi, proslava rođendana, odlazak ranije s posla zbog privatnih obaveza (djeca, stomatolog, liječnik, tehnički pregled i registracija automobila, …) i sl. Nadalje, svakako se može ubrojiti i ogovaranje na poslu. Prema istraživanju na ogovaranje se potroši oko 40 minuta tjedno. Najviše vremena na ogovaranje troše generacija milenijalaca (81%), zatim generacija Z (70%) i baby boomeri (58%) (URL 3). Nadalje, postoje još situacija u kojima se gubi efektivni sat: traženje alata/aplikacija za rješavanje zadataka, prekid drugih, činjenje pogrešaka zbog prekida i ometanja i sl. (URL 2).

S obzirom da je sve ove događaje teško mjeriti, odlučili smo kako ćemo odrediti vrijeme potrošeno na sve to. Kako je navedeno prije, u godini imamo 208 radnih dana nakon što se oduzmu svi zakonski propisani dani kada ne radimo. Ako prosječno na sve navedene aktivnosti u ovoj kategoriji dnevno potrošimo 60 minuta, dolazimo do zaključka da to na godišnjoj razini iznosi 26 dana – 208 sati.

Sve neproizvodne sate koji se dogode u kategorijama tehnologija i ostalo, poslodavac po zakonu mora platiti jer je to dio sati od ukupno 2096 za koje se isplati plaća.

Kada smo naveli sve neproizvodne sate koji se mogu dogoditi u jednoj kalendarskoj godini, sada možemo izračunati prosječan broj efektivnih radnih sati i on iznosi 101 dan – 808 sati (Tablica 1).

4. Izračun cijene proizvodnog sata i rasprava

Izračun cijene proizvodnog sata na našem primjeru dobit ćemo omjerom ukupnog godišnjeg troška potrebnog za funkcioniranje jedne geodetske tvrtke i ukupnog broja efektivnih sati oba zaposlenika.

Za funkcioniranje jedne geodetske tvrtke sa zaposlena dva geodetska stručnjaka (ovlašteni inženjer geodezije i geodetski tehničar) na godišnjoj razini potrebno je 93.000,00 €.

Ukupan prosječan broj efektivnih radnih sati dva geodetska stručnjaka na godišnjoj razini iznosi 1616 sati.

Cijena proizvodnog radnog sata iskusnog geodetskog stručnjaka u ovome primjeru iznosila bi 57,55 €.

Rasprava. Kako je navedeno prije, za definiranje troškova u ovome radu uzete su prosječne vrijednosti. Jasno je kako najam prostora u različitim dijelovima Hrvatske ima različitu cijenu ili možda netko ima vlastiti poslovni prostor. Možda netko ne kupuje novi automobil svakih 7 godina i vozi isti već 30 godina (ljubav prema *oldtimerima* ?), ali opet, održavanje takvog automobila više košta. Isto tako, kod izračuna efektivnih radnih sati, jasno je da imamo kolega koji nemaju niti dana bolovanja, ali oni onda zarađuju za potrebe tvrtke i zbog toga su u prilici da imaju veću plaću. Nadalje, imamo kolega koji ne iskoriste niti dana plaćenog dopusta u jednoj godini, ali zato možda oni više vremena troše u kategoriji tehnologije i ostaloga. Međutim, bitno je napomenuti kako sve te stavke i sati veoma malo utječu na promjenu cijene prodajnog radnog sata. Najveći utjecaj na cijenu prodajnog radnog sata ima – plaća. U ukupnom godišnjem trošku plaće u prije opisanom primjeru imaju udio od cca. 50%. Kad se te plaće definiraju minimalnim vrijednostima, taj udio iznosi cca. 30%. Ako oba zaposlenika na primjeru koji smo koristili imaju minimalnu plaću, onda ukupni godišnji troškovi tvrtke padaju na 63.944,00 €, a vrijednost proizvodnog radnog sata pada sa 57,55 € na samo 39,57 €. Možemo li iz ovoga zaključiti kako smo za pad vrijednosti rada geodetskog stručnjaka možda sami krivi? Možemo li očekivati uvažen status u društvu ako sami sebe podcjenjujemo? Kolika je možebitna prisutnost sive ekonomije u poslovanju geodetskih tvrtki u Republici Hrvatskoj?

Nakon što procijenimo koliko nam je vremena potrebno za obavljanje određene geodetske usluge, jednostavno je definirati cijenu. U ovoj fazi treba biti svjestan jedne važne činjenice. Svaku osobu kao stručnjaka određuju znanje, vještine i talenti. Zamislimo sljedeću situaciju koja je prisutna u gotovo svim tvrtkama: Imamo dva zaposlenika koji su sposobni odraditi traženu geodetsku uslugu, ali postoji razlika. Prvi bi uslugu odradio za 20 sati, a drugi za 15 sati. U tom slučaju, moramo biti svjesni kako je pravedno da druga soba, koja – zahvaljujući svojim znanjima, vještinama i talentima – posao odradi za 15 sati, mora biti više plaćena. Vremenski normativ za određenu geodetsku uslugu mora biti prosječna vrijednost. Dakle, nije pravedno normu definirati po osobi koja najbrže obavlja posao, niti po osobi koja najsporije obavlja posao.

5. Prijedlog preporučene cijene

Osim Standarda, u Hrvatskoj nemamo niti jedan drugi dokument koji bi dodatno pomogao geodetskom stručnjaku prilikom formiranja cijene geodetskih usluga. Dobar primjer iz prakse može se vidjeti kod naših kolega u Sloveniji. Inženirska Zbornica Slovenije izdala je dokument pod nazivom *Priporočena cena efektivne ure storitve pooblaščenega in nadzornega inženirja* (URL 4). Ovaj dokument dobra je smjernica naručitelju, ovlaštenom i nadzornom inženjeru kako bi definirali vrijednost posla koji treba obaviti. Cijena efektivnog sata podijeljena je u četiri kategorije ovisno o zahtjevnosti posla koji je potrebno obaviti i dužnosti koju osoba ima u cijelom projektu. Na temelju provedene ankete odredili su koliko je otprilike sati potrebno za određenu uslugu. Uz to, u obzir su uzeli i prosječne mjesečne plaće geodetskih stručnjaka te u konačnici definirali preporučeni cjenik i njegove kategorije. Vrijednost cijene sata kreće se od 55,00 € pa do čak 140,00 €. Za napomenuti je kako preporučena cijena u sebi ne sadrži troškove geodetskog instrumentarija, automobila, najma, dobit i sl. Cilj im je bio da cjenik, osim geodetima, prvenstveno bude od pomoći velikim naručiteljima (općine, gradovi, državne institucije, velike tvrtke). Zanimljivo je kako su kolege iz Slovenije od travnja 2021. godine čak dva puta izmijenili preporučeni cjenik i na taj način pokazali da su „držali" korak s vremenom posebice u pogledu inflacije.

Ovaj rad ima za cilj dati preporučene cijene proizvodnog radnog sata geodetskog stručnjaka u Hrvatskoj. Po uzoru na kolege iz Slovenije definirane su četiri kategorije kako je to prikazana u tablici 2. Kategorije su definirane uzimajući u obzir Standard, članke 5. (stručni geodetski poslovi koji utječu na kvalitetu državnih evidencija) i 6. (stručni geodetski poslovi za tehničke i druge svrhe) Zakona o obavljanju geodetske djelatnosti te utjecaj inflacija s obzirom da će proći gotovo četiri mjeseca od trenutka pisanja rada do njegove objave. Jasno je kako za određene poslove moramo posjedovati određena znanja i potrebnu opremu kako bismo ih izvršili kvalitetno (npr. fotogrametrijske stanice za izradu DOF5, precizne mjerne stanice za praćenje pomaka i deformacija, bespilotne letjelice za fotogrametrijsko snimanje). Preporučene cijene definirane su uzevši u obzir i količinu vremena koju je potrebno utrošiti prema Standardu.

Preporučene cijene proizvodnog radnog sata iskazane u tablici 2 trebale bi biti dobar putokaz, najprije svim geodetskim stručnjacima u Republici Hrvatskoj koji definiraju vrijednost geodetskog posla. Na taj način bio bi spriječen damping cijena geodetskih usluga i istovremeno podignut status geodetskog stručnjaka, kako u društvu, tako i među ostalim inženjerskim strukama. Nadalje, on bi trebao biti jedan od glavnih dokumenata HKOIG-a kojeg bi trebalo predstaviti svim velikim naručiteljima (jedinicama lokalne samouprave, državnim institucijama, velikim tvrtkama, itd.). To bi naručiteljima u procesima sastavljanja javnih natječaja znatno olakšalo definiranje procijenjene vrijednosti. Ovaj preporučeni cjenik je dokument koji treba biti u „koraku" s vremenom – moramo biti spremni cijelo vrijeme ga usavršavati kako bi bio odr-

Tablica 2: Preporučena cijena proizvodnog radnog sata geodetskog stručnjaka

Vrsta posla	Preporučena cijena proizvodnog sata (bez dobiti i PDV-a)
• izrada parcelacijskih i drugih geodetskih elaborata • katastar infrastrukture • podloge za projektiranje	60,00 €/sat
• katastarske izmjere • komasacije	70,00 €/sat
• izrada ortofotokarata • izrada topografskih karata • fotogrametrija	80,00 €/sat
• inženjerska geodezija • hidrografija	100,00 €/sat

živ na tržištu. Posljedica ovakvog načina definiranja vrijednosti geodetskih radova zasigurno će biti i podizanje njihove kvalitete. Na taj način bi se smanjilo, ponekad prisutno, nezadovoljstvo kvalitetom obavljenog posla od strane naručitelja ili nas kolega, a što bi rezultiralo podizanjem statusa u društvu.

Na preporučene vrijednosti proizvodnog sata geodetskog stručnjaka potrebno je uračunati dobit koja se očekuje te porez ukoliko je tvrtka u sustavu poreza.

6. Zaključak

Danas svjedočimo situaciji kada status geodetskog stručnjaka i vrijednost njegovog rada u društvu nije na razini kako je to nekada bilo. Cilj ovog rada je dati prijedlog preporučene cijene proizvodnog radnog sata geodetskog stručnjaka.

Na temelju izračuna prosječnih godišnjih troškova za jednu manju geodetsku tvrtku i definiranja prosječnog broja efektivnih radnih sati u jednoj kalendarskoj godini, dobivena je cijena proizvodnog radnog sata geodetskog stručnjaka od – 57,55 €. Prilikom analiza, primijećeno je kako najveći utjecaj na promjenu cijene proizvodnog radnog sata imaju plaće. U slučaju isplate minimalnih plaća, prosječni godišnji troškovi geodetske tvrtke padaju za 30%. U konačnici, dan je prijedlog preporučene cijene proizvodnog sata tako što su definirane četiri kategorije poslova ovisno o zahtjevnosti i specifičnostima. Preporučena cijena proizvodnog sata kreće se od 60,00 € do 100,00 €.

Prijedlog preporučene cijene proizvodnog radnog sata može biti od velike pomoći geodetskom stručnjaku prilikom formiranja cijene geodetske usluge te naručiteljima u procesima definiranja procijenjene vrijednosti javnih natječaja. Nakon što se ovaj dokument donese, preporuka je da bude revidiran od strane HKOIG-a svakih šest mjeseci kako bi bio usklađen s dinamikom tržišta i parametrima inflacije. Neka ovo bude početak dobrog razdoblja geodezije u Hrvatskoj, odnosno povratak korijenima zbog kojih je Komora osnovana, a to je – štititi tri najvažnija počela: cijenu (koja štiti izvoditelja), kvalitetu (koja štiti naručitelja) i etiku (koja štiti međusobne odnose).

Literatura

Hrvatska komora ovlaštenih inženjera geodezije (2021.): Standard geodetskih usluga, HKOIG.

Hrvatski zavod za zdravstveno osiguranje (2024): Izvješće o poslovanju Hrvatskog zavoda za zdravstveno osiguranje za 2023. godinu, Hrvatski zavod za zdravstveno osiguranje.

Mark, G., Gudith, D., Klocke, U. (2008): The cost of interrupted work: More speed and stress, Conference: Proceedings of the 2008 Conference on Human Factors in Computing Systems, Florence, Italy.

Miletić, S., Friščić, M. (2022): Izazovi geodeta milenijalaca, 15. Simpozij ovlaštenih inženjera geodezije, Opatija.

Narodne novine (2023): Zakon o radu, NN 64/23

URL 1: https://web.dzs.hr/calcinfl.htm (14.06.2024.).

URL 2: https://workjoy.co/blog/scientific-research-notifications-and-interruptions-negatively-affect-work#it-takes-an-average-of-23-minutes-and-15-seconds-to-refocus-after-being-distracted-at-work (14.06.2024.).

URL 3: https://jobera.com/wasting-time-at-work-statistics/#sources (14.06.2024.).

URL 4: https://www.izs.si/assets/media/izsnovo/2023/Priporo%C4%8Dena-cena-efektivne-ure-storitve-PI-in-NI-november-2023-www.pdf (14.06.2024.).

Proposal of the Recommended Value of Production Hour for Geodetic Experts

Abstract

The value of labour for a surveyer/geodetic expert is defined by the state of the market. There are number of products and services that surveyers/geodetic experts deliver to the market. Standardizing all products and services would be extremely demanding and complex. There were ways of achieving this standardization, but they did not find their daily use or wider application. Significant technological development expands possibilities and at the same time accelerates work labour. In such circumstances it becomes increasingly difficult for a geodetic expert to estimate the amount in which to charge for the requested product or service. This results in a significant dumping of prices for geodetic products and services on the market, the rise of which is not influenced even by the inflation rate. This paper will approximately show the amount of effective working hours of a geodetic expert in one calendar year. The annual costs will be taken into account, a necessity for smooth activities and operations on the market for the surveying company. The calculation and categorization of the effective working hour follows. A proposal will be made to define the recommended value of geodetic experts production working hour.

Keywords: *geodesy, effective hour, production hour, costs, recommended rates*

Posebni režimi i njihova interakcija s ostalim zemljištem prilikom izrade geodetskih elaborata

Josip Vejmelka[1]

[1] Hrvatska komora ovlaštenih inženjera geodezije, Ulica Grada Vukovara 271/II, Zagreb, Hrvatska, josip.vejmelka@hkoig.hr

Sažetak

Geodetski elaborat tehnička je osnova za provođenje promjena u službenim državnim evidencijama katastra i zemljišne knjige. Prilikom izrade geodetskih elaborata na katastarskim česticama koje graniče sa zemljištima cesta, komunalne infrastrukture, željeznica, pomorskim dobrom i drugim sličnim vlasničkim režimima, javlja se različita praksa postupanja kako ovlaštenih inženjera geodezije tako i nadležnih katastarskih ureda. Cilj je ovoga rada ukazati na kompleksan posao i probleme u postupanju ovlaštenih inženjera geodezije pri izradi geodetskih elaborata te podići svijest o njihovoj važnosti. Ovakve probleme u praksi mogu uspješno rješavati te interese sudionika pomiriti samo ovlašteni inženjeri geodezije koji su u potpunosti savladali ovu problematiku. Iako se u osnovi ne radi o usvajanju novih vještina, kako bi se osigurao položaj geodetske struke kao regulirane profesije u budućnosti potrebno je osnažiti postojeću ulogu ovlaštenog inženjera geodezije kroz kvalitetu njegova rada. S time u vidu, potrebno je zadržati i unaprijediti postojeće vještine i znanja ovlaštenih inženjera geodezije u polju u kojem su i do sada bili neprikosnoveni – rada sa službenim državnim evidencijama.

Ključne riječi: *evidentiranje stvarnog stanja, geodetski elaborati, ovlašteni inženjer geodezije, posebni režimi*

1. Uvod

Obavljanje geodetske profesije u Republici Hrvatskoj uvelike se poistovjećuje s obavljanjem stručnih geodetskih poslova koji utječu na kvalitetu službenih državnih evidencija u prostoru i koji služe za vođenje i održavanje katastra zemljišta i katastra nekretnina. Ovu tezu naime donekle potvrđuje i činjenica da od trenutno 1220 ovlaštenih inženjera (URL 1) geodezije, njih preko 1100 ima suglasnost Državne geodetske uprave (URL 2) za obavljanje poslova iz članka 5. stavka 4., 5., i 6. Zakona o obavljanju geodetske djelatnosti (Narodne novine 25/2018, dalje: Zakon, URL 3). Naravno da osim navedene „grane" ove djelatnosti, postoji čitav niz drugih stručnih geodetskih poslova za razne potrebe, međutim veliki broj ovlaštenih inženjera geodezije u Republici Hrvatskoj većinu svojeg poslovnog vremena provodi baveći se upravo navedenim stručnim geodetskim poslovima. S time u vidu, izrazito je važno ovdje uvodno naglasiti kako je pristup geodetskoj profesiji strogo zakonom ograničen na ovlaštene inženjere geodezije te njihove suradnike. Uvjeti za obavljanje stručnih geodetskih poslova koji utječu na kvalitetu službenih državnih evidencija u prostoru i koji služe za vođenje i održavanje katastra zemljišta i katastra nekretnina osim što su zakonom ograničeni na već navedene osobe, dodatno su postroženi na način da je kao uvjet za obavljanje takvih poslova u svojstvu odgovornih osoba, odnosno trgovačkih društava u smislu Zakona propisana obveza pribavljanja suglasnosti Državne geodetske uprave. Uvjet za dobivanje takve suglasnosti za fizičke osobe ovlaštene inženjere geodezije su status ovlaštenog inženjera geodezije, zaposlenje u trgovačkom društvu registriranom za obavljanje geodetske djelatnosti ili uredu ovlaštenog inženjera geodezije odnosno zajedničkom geodetskom uredu, iskustvo u obavljanju stručnih geodetskih poslova u trajanju od najmanje tri godine te dokaz o obavljenom stručnom usavršavanju osoba koje obavljaju stručne geodetske poslove. Dakle, iako je geodezija regulirana profesija, za obavljanje stručnih geodetskih poslova kojima se utječe na kvalitetu službenih državnih evidencija potrebno je ispuniti navedene posebne uvjete, odnosno ishoditi već spomenutu suglasnost Državne geodetske uprave.

Iz svega navedenog proizlazi da se radi o poslovima koji su strogo ograničeni na izrazito mali broj stručnih osoba te osoba koje kontinuirano moraju usavršavati svoje znanje i vještine. Ova činjenica često se zaboravlja, odnosno zaboravljaju je prije svega ovlašteni inženjeri geodezije. Potrebno je stalno naglašavati da se radi o posebnoj ovlasti utemeljenoj na zakonu, koja se stječe pod iznimno striktnim uvjetima. Takva zakonom utemeljena zaštita određene djelatnosti, odnosno segmenta djelatnosti, rijetkost je u današnjem tržišno orijentiranom gospodarstvu, i važno je istaknuti da će se pitanja opravdanosti takve zakonske zaštite sigurno ciklički propitkivati. Opstojnost takve

zakonske zaštite prema tome ovisi o percepciji potrebe za njezinom primjenom. Iz perspektive teme ovogodišnjeg Simpozija ovlaštenih inženjera geodezije, potrebno je više nego ikada kontinuiranim razvojem osobnog znanja i vještina držati korak sa zahtjevnim pravnim normama koje utječu na obavljanje stručnih geodetskih poslova. Na taj način potrebno je osigurati dugotrajan položaj geodetske struke kao struke od najvećeg državnog povjerenja, odnosno kao jedine ovlaštene za obavljanje stručnih geodetskih poslova.

2. Održavanje službenih evidencija provedbom geodetskih elaborata

Jedan od načina održavanja katastarskog operata je provedbom geodetskih elaborata kao tehničke osnove za provedbu promjena u službenim državnim evidencijama. Formalno gledano, sve promjene u katastarskom operatu provode se na temelju zahtjeva stranke ili po službenoj dužnosti. Iako se promjene provode formalno temeljem zahtjeva stranke, u geodetskim elaboratima sadržane su informacije o samim promjenama. Da bi se geodetski elaborati mogli upotrebljavati u svrhu i za potrebe za koju su izrađeni, moraju biti pregledani i potvrđeni od strane nadležnog katastarskog ureda. Ovakvim načinom provođenja promjena osigurano je da se svaka promjena u katastarskom operatu provodi na temelju zahtjeva stranke (vlasnika, ovlaštenika i dr.), da se takvim zahtjevima priloži geodetski elaborat kao tehnička osnova izrađena isključivo od ovlaštene stručne osobe te da valjanost izrađenih elaborata utvrđuje nadležni katastarski ured. Dakle, prilikom postupanja po svakom zahtjevu za provođenje promjena u katastarskom operatu, a čija je tehnička osnova geodetski elaborat, sudjeluju navedena tri tijela. Svaki od tih tijela ima svoju jasnu zakonsku ulogu i svrhu i bez sudjelovanja bilo kojeg od navedenih tijela promjene u službenim evidencijama nije moguće provesti.

Za promjene u službenim evidencijama potreban je interes podnositelja zahtjeva koji u pravilu (iako nije nužno) ima vlasnički odnos na predmetnoj nekretnini ili kakva druga stvarna prava. Podnositelji zahtjeva zahtijevaju promjene i ažuriranje službenih evidencija kako bi temeljem ažuriranih evidencija ostvarivali svoja prava. U praksi, stanje službenih evidencija nije stvar prestiža već interesa. Osobe svoje evidencije drže ažurnima upravo onoliko koliko za to imaju interesa. Upravo iz nedostatka konkretnog interesa, na području Republike Hrvatske postoji veliki broj nekretnina koje nemaju ažurne službene evidencije. Praksa također pokazuje da, onoga trenutka kada se taj interes pojavi, osobe evidencije o vlastitim nekretninama ažuriraju.

Uloga ovlaštenih inženjera geodezije je da kao neovisni stručnjaci izrade geodetski elaborat kao tehničku osnovu za provođenje zahtijevanih promjena. Sam pojam tehničke osnove podrazumijeva da se u suštini radi dokumentu kojim se predlaže realizacija neke tražene promjene. Dakle geodetski elaborat sadrži sve one (tehničke) parametre potrebne kako bi se zahtijevana promjena provela u službenim evidencijama. Naručitelj u pravilu ne zna točno kakav geodetski elaborat treba izraditi, samo kakav treba biti konačan rezultat. Iz tog razloga izrazito je bitno da ovlašteni inženjer geodezije naručitelja zna uputiti na odgovarajući način za rješenje njegova zahtjeva. Same tehničke parametre iskazane geodetskim elaboratom naručitelj kao laik naravno ne zna niti ih može znati, a niti bi ga u konačnici trebali zanimati.

Podnositelj zahtjeva najčešće vodi računa isključivo o svome interesu, iz kojeg razloga je neovisnost ovlaštenog inženjera geodezije ovdje od ključne važnosti. Prilikom provođenja promjena u službenim evidencijama ovlašteni inženjer geodezije mora voditi računa o interesu trećih osoba kao i o općem interesu. Izrazito je bitno naglasiti da ovlašteni inženjer geodezije prilikom izrade geodetskih elaborata nije zastupnik naručitelja. Naravno, ovlašteni inženjeri geodezije putem geodetskih elaborata predlažu promjene na zahtjev naručitelja, pa je sasvim logično da takvi elaborati sadržajno predlažu promjene u interesu naručitelja, međutim položaj ovlaštenog inženjera geodezije je tu da u prvome redu osigura da tehnička osnova bude izrađena na način da se poštuje opći interes i zaštiti interes trećih osoba te da zadovolji tehničke kriterije. Takav položaj ovlaštenih inženjera geodezije u obavljanju stručnih geodetskih poslova proizlazi iz odredbi Kodeksa strukovne etike u obavljanju stručnih geodetskih poslova ovlaštenih inženjera geodezije (Narodne novine 80/2021, URL 4).

Jednako kao i prethodne dvije, i uloga katastarskog ureda koji potvrđuje geodetski elaborat je jasna i sasvim određena. Naime, upravo je upravljanje i održavanje službenih državnih evidencija od iznimnog značaja za državu. Obzirom na takav izniman značaj, država želi osigurati da su takve evidencije pod njezinom kontrolom, odnosno želi propisima, ali i provedbom propisa osigurati da se evidencije vode i održavaju na način na koji je to predviđeno. Iz navedenog razloga, država putem nadležnih katastarskih ureda utvrđuje tehničku ispravnost geodetskih elaborata. Iako je pregledan i potvrđen geodetski elaborat u suštini tehnička osnova za provedbu promjena u službenim državnim evidencijama, ne radi se naime samo o pregledu tehničke osnove. Prilikom pregleda i potvrđivanja geodetskog elaborata nadležni katastarski ured u suštini treba utvrditi da li geodetski elaborat zadovoljava sve zahtjeve za njegovu provedbu, a ne samo tehničke. Naime, sukladno članku 82. Pravilnika o geodetskim elaboratima (Narodne novine 59/2018, dalje u tekstu: PoGE, URL 5), nadležni katastarski ured praktički provjerava da li je geodetski elaborat kao takav provediv. Tek u određenim slučajevima za provedbu geodetskog elaborata, osim zahtjeva, potrebno je priložiti dodatne isprave. Postupkom postavljenim na ovaj način, u kojemu u proces izrade geodetskih elaborata te provedbe promjena u službenim evidencijama sudjeluju navedene tri sastavnice te kojim se promjene predlažu putem geodetskih elaborata osigurava se kvaliteta službenih evidencija te maksimalna zaštita općeg interesa te prava stranaka u postupcima. Razumijevanje ovako definirane procesne uloge ovlaštenog inženjera geodezije, ali ništa manje ni ostalih aktera, nužno je

kako bi geodetska profesija zadržala svoj status regulirane profesije te kako bi se zadržalo dobiveno povjerenje države.

3. Zemljišta posebnih režima upravljanja i njihova evidencija

Pod zemljištima posebnih režima upravljanja u smislu ovoga rada podrazumijevaju se zemljišta javnih i nerazvrstanih cesta, vodnih građevina i stvarnog stanja korita prirodnih površinskih voda, pomorskog dobra, željezničke infrastrukture te komunalne infrastrukture izgrađena do stupanja na snagu predmetnih zakona. Ovdje je naglašeno „izgrađena do stupanja na snagu predmetnih zakona" zato jer za zemljišta koja su izgrađena do stupanja na snagu tih zakona vrijede posebna pravila za njihovu evidenciju. Pomorsko dobro ovdje je u nešto drugačijem položaju zato što (u najvećoj mjeri) ono ne nastaje izgradnjom kakvih građevina (za razliku od cesta, groblja ili vodnih građevina primjerice), međutim evidencija pomorskog dobra ipak se provodi sukladno odredbama posebnog zakona. Zajedničko svim ovim zemljištima je da su propisani posebni postupci u kojima se takva zemljišta evidentiraju u službenim državnim evidencijama odnosno u kojima se evidentira njihovo stvarno stanje.

Ono što je ovim zemljištima također zajedničko jest činjenica da je stvar njihove evidencije samo deklaratornog karaktera. Naime, iz posebnih propisa kojima su uređena navedena područja proizlazi da se cestovnim zemljištem, zemljištem vodnih građevina i stvarnih stanja korita prirodnih površinskih voda, pomorskim dobrom, željezničkom infrastrukturom te komunalnom infrastrukturom (izgrađenim do trenutka stupanja na snagu tih posebnih zakona) smatraju sva ona zemljišta koja su takva temeljem samog zakona (*ex lege*), bez obzira bila ona evidentirana na takav način u službenim evidencijama u prostoru ili ne. Prema tome, radi se o evidenciji zemljišta obuhvaćenog posebnim režimom, čiji je vlasnički odnos reguliran stupanjem na snagu posebnog zakona. Drugim riječima, u službenim evidencijama se evidentira izvedeno (stvarno) stanje takvih posebnih režima, dok je pravno gledano do promjene vlasništva došlo samim stupanjem na snagu zakona, odnosno izgradnjom građevina (cesta, groblja, nasipa i sl.). Upravo iz tog razloga, takav zakonodavni okvir se naziva deklaratornim, jer se provedbom takvog propisa u službenim evidencijama samo proglašava odnosno deklarira postojanje takvoga posebnog režima. Zbog ovakva shvaćanja i pravnog gledišta ovih posebnih režima došlo je do mnogo prijepora, a primjerice kod cestovnog zemljišta rezultiralo je i brojnim zahtjevima za ocjenu ustavnosti mjerodavnog Zakona o cestama (Narodne novine 84/2011, 22/2013, 54/2013, 148/2013, 92/2014, 110/2019, 144/2021, 114/2022, 114/2022, 04/2023, 133/2023, dalje ZoC, URL 6). Ustavni sud donio je o tome posebno rješenje (URL 7) objavljeno u Narodnim novinama br. 23/2017, kojim je odbio mnogobrojne zahtjeve za ocjenu ustavnosti ovoga zakona, tako potvrđujući da se radi o zakonu koji je usklađen s Ustavom Republike Hrvatske. Iako se rješenje Ustavnog suda odnosi na ZoC, slične pravne norme po pitanju evidencije takvog zemljišta postoje i u Zakonu o vodama, Zakonu o komunalnom gospodarstvu kao i u Zakonu o željeznici, a u nešto drugačijoj mjeri i u Zakonu o pomorskom dobru i morskim lukama.

Treba istaknuti, da je (između ostalog) u citiranom rješenju Ustavnog suda navedeno kako javnopravni subjekti, kao stjecatelji po samom zakonu nemaju „obvezu" uknjižiti svoje pravo vlasništva, odnosno da izostanak uknjižbe ne znači da vlasništvo nisu stekli. Kod ostalih oblika stjecanja prava vlasništva vrijedi suprotno. Namjera zakonodavca prilikom propisivanja načina evidencije ovih posebnih režima bila je sasvim jasna, omogućiti evidentiranje posebnih režima te otkloniti moguće zapreke prilikom evidentiranja uzrokovane nesređenim zemljišnoknjižnim i katastarskim stanjem bez obzira na postojeće upise u službenim evidencijama. Isto se primjerice može uočiti u vijesti (URL 8) koju je povodom usvajanja izmjena Zakona o izmjeni i dopuni Zakona o cestama navelo Ministarstvo pomorstva, prometa i infrastrukture. Treba također izdvojiti i kako se u navedenoj vijesti navodi da se pravna sigurnost (ovako provedenom evidencijom) i dalje osigurava budući da se ceste evidentiraju temeljem pregledanog i potvrđenog geodetskog elaborata. Upravo se ovom novelom ZoC iz 2014. godine (Narodne novine 92/2014, URL 9) izmijenio način evidencije cesta na način da je predviđeno da se prijavni list prvo provodi u zemljišnoj knjizi, a potom u katarskom operatu. Ovakav postupak potom je implementiran i u ostale ovdje navedene zakone. Činjenica da je ministarstvo istaknulo upravo provedbu putem geodetskih elaborata kao dodatan element kojim se osigurava pravna sigurnost još je jedan dokaz povjerenja države u provođenje promjena temeljem pregledanih i potvrđenih geodetskih elaborata kao osnova pravne sigurnosti provedbe promjena u službenim državnim evidencijama.

Bez obzira što je posebnim propisima propisan način provedbe geodetskih elaborata za evidenciju posebnih režima, kako bi se isto napravilo i dalje je potrebno načelno poštovati proceduru za izradu geodetskih elaborata. Navedeno je propisano Zakonom o državnoj izmjeri i katastru nekretnina (Narodne novine 112/2018, 39/2022, dalje: ZDIKN, URL 10) te PoGE. S time u vidu, u PoGE-u su propisane svrha i procedura za izradu geodetskog elaborata izvedenog stanja ceste te geodetskog elaborata za evidentiranje pomorskog i vodnog dobra. Svrhe izrade geodetskog elaborata za potrebe evidentiranja izvedenog stanja komunalne infrastrukture (u koju u određenim slučajevima spadaju i izvedena stanja cesta) te željezničke infrastrukture nisu opisane u PoGE-u, međutim opisane su Dodatkom 5 tehničkih specifikacija za geodetske elaborate kojima je opisan postupak izrade geodetskih elaborata izvedenog stanja. Ono što je zajedničko svim ovim režimima prilikom izrade geodetskih elaborata za upis izvedenih stanja prema posebnim propisima, jest da je predviđeno da se posebni režimi upisuju u zasebne novoosnovane katastarske čestice te da se na takvim česticama upisuje pravo vlasništva sukladno tim posebnim propisima. Najčešće, tu se radi o Republici Hrvatskoj ili jedinici lokalne samouprave, uz naznaku da se radi o javnom dobru

u općoj uporabi ili primjerice pomorskom dobru. Također, za određena zemljišta navodi se i upravitelj. Upravitelji su najčešće jedinice lokalne samouprave ili trgovačka društva u vlasništvu Republike Hrvatske. U slučaju pomorskog dobra, navodi se samo pomorsko dobro. Pravno gledano, pomorsko dobro nešto je drugačijeg režima budući se radi o izvan vlasničkom režimu na kojem se ne može steći pravo vlasništva ni druga stvarna prava po bilo kojoj osnovi. Radi jednostavnosti, u nastavku ovoga teksta sve osobe nadležne za upravljanje zemljištima takvoga posebnog režima nazvane su upraviteljima. Sam titular koji se navodi kao vlasnik u izlaznom stanju geodetskog elaborata odnosno prijavnog lista u smislu geodetske struke nije (u smislu ovoga rada) od ključne važnosti, ono što je mnogo važnije je da je takav titular predviđen posebnim zakonima i propisima i sukladno tome uživa u smislu navedenih zakona poseban položaj u odnosu na ostale vlasnike i nositelje stvarnih prava.

4. Izrada geodetskih elaborata na zemljištima koja graniče sa zemljištima posebnih režima

Problem je u načelu sasvim jednostavan. U slučaju da naručitelj odnosno zainteresirana stranka naruči geodetski elaborat, a predmetna nekretnina graniči s nekim od posebnih režima može li se takav geodetski elaborat uopće izraditi, ukoliko može u kojim slučajevima te na koji način takav elaborat izraditi.

Prije svega, potrebno je poteći od osnovne svrhe izrade tih geodetskih elaborata. Naime, predmet rada geodetskih elaborata je određena nekretnina koja se sastoji od jedne ili više katastarskih čestica ili dijelova čestica. U slučaju da su zemljišta posebnih režima već evidentirana u zasebnim postupcima (putem geodetskih elaborata), tada izbora praktički nema – treba zadržati granicu određenu takvim elaboratom. Kako međutim postupati kada u posebnom postupku nije evidentiran poseban režim. Obzirom da ga ne može konzumirati kao svoje pravo, naručitelj želi takvo zemljište formalno izdvojiti iz svoje čestice. Osim toga, treba voditi računa da naručitelja u prvome redu zanima dio čestice koji je i dalje u njegovom vlasništvu, a ne dio koji je konzumiran u posebnom režimu. Ovdje treba istaknuti činjenicu da posebne režime nije moguće evidentirati mimo posebnih postupaka namijenjenim isključivo za njihovu evidenciju. Razlozi za takvu restrikciju najviše su praktične naravi – ukoliko bi isto bilo dopušteno to bi u praksi značilo da se takvi posebni režimi točkasto evidentiraju u prostoru provedbom svakog pojedinog geodetskog elaborata, što bi s obzirom na broj geodetskih elaborata koji su u „dodiru“ s neevidentiranim zemljištima posebnih režima iziskivalo nevjerojatan angažman upravitelja takvih režima. Upravitelji posebnih režima naime sudjeluju u određivanju granice takvog režima prilikom obavljanja terenskih mjerenja. Osim toga, primjerice za evidentiranje pomorskog dobra potrebna je i formalna odluka o utvrđivanju pomorskog dobra. Prema tome postoje sasvim opravdani razlozi zašto to nije moguće. Naručitelj međutim ima mogućnost izrade geodetskih elaborata kojima bi zatražio diobu čestice na način da se područje pod posebnim režimom odvoji u drugu česticu. U svakom slučaju, osnovno pitanje ovdje i dalje stoji, a to je da li izradom geodetskog elaborata kojim se zemljište posebnog režima odvaja u zasebnu česticu stvaramo dodatnu pravnu sigurnost za sve zainteresirane osobe. Dakako, odgovor je potvrdan, međutim ovim postupcima i dalje ostaje otvoreno pitanje definiranja granice između zemljišta posebnih režima i redovnih vlasničkih režima.

5. Problemi u praksi

U praksi, kao jedan od ključnih problema možemo izdvojiti problem opsega posebnog režima. Iako bi on (opseg) trebao proizlaziti iz samog zakona, često nije takav slučaj. Primjerice, ZoC je propisao kako javnu cestu čine, između ostalog, i zemljišni pojas s obiju strana ceste potreban za nesmetano održavanje ceste širine prema projektu ceste, a najmanje jedan metar računajući od crte koja spaja krajnje točke poprečnog presjeka ceste. Obzirom da je prema citiranome predviđen minimum širine zemljišnog pojasa, a maksimum nije propisan, sasvim je jasno da se do evidencije takvog zemljišta u službenim državnim evidencijama u za to predviđenom postupku ne može sa sigurnošću utvrditi opseg takvog režima. Drugi prethodno navedeni zakoni također ništa podrobnije nisu odredili samu granicu takvih režima. Postoje i određene iznimke. Primjerice za određivanje obuhvata vodnih građevina i određivanje granice vodnog dobra postoje Smjernice izrađene od Hrvatskih voda (URL 11). Iako nisu unutar samog zakona, svakako predstavljaju barem grubi orijentir prilikom određivanja opsega takvih režima. Pomorsko dobro također je u određenoj mjeri iznimka, budući se evidentira na temelju rješenja u kojem su sadržane koordinate granica pomorskog dobra čime se otklanja bilo kakva procjena takvog obuhvata. Međutim prije nego je takvo rješenje doneseno u odgovarajućem postupku, opseg pomorskog dobra je bio predmet utvrđivanja posebnog povjerenstva. Također, treba imati na umu da se izvedeno stanje posebnih režima evidentira samo uzimajući u obzir stanje tog režima na datum stupanja na snagu zakona, uz određene iznimke pomorskog i vodnog dobra. Takvo izvedeno stanje na određeni datum, u smislu izgrađenih građevina koje su se moguće i mijenjale u odnosu na datum stupanja na snagu zakona, je katkada izrazito teško odnosno nemoguće za procijeniti.

Nadalje, kao jedan od problema ističe se i slabi odaziv upravitelja posebnih režima na pozive ovlaštenih inženjera geodezije prilikom izrade geodetskih elaborata kojima svrha nije evidentiranje posebnog režima. Upravitelji se u velikom broju slučajeva na poziv ovlaštenih inženjera geodezije da prisustvuju prilikom obavljanja terenskih mjerenja ili predočavanju geodetskih elaborata ogluše na dostavljene pozive. Razloge treba prvenstveno tražiti u sposobnosti tih upravitelja da u dovoljnoj mjeri obrade sve pristigle pozive i na kvalitetan način pristupe rješavanju problema. Problem je dakle količine takvih poziva kojih

nesumnjivo ima veliki broj odnosno radi se o značajnoj količini posla za upravitelje. U slučajevima kada se odazovu na takve pozive međutim, postavlja se pitanje uloge njihova sudjelovanja. Naime, posebnim postupcima za evidenciju ovih režima upraviteljima je dano isključivo pravo u smislu određivanja položaja njihovih granica (opsega). Predviđeno je da takve granice upravitelji posebnih režima određuju jednostrano te da vlasnici graničnih čestica to samo primaju na znanje. Ovaj odnos naime proizlazi iz činjenice da su granice takvih režima određene sukladno zakonu (barem načelno), iz kojeg razloga nije ni razmjerno da stranke koje nisu upravitelji takvih režima predlažu položaj granice. Pravno gledano (*de iure*), pri samom određivanju granice ne bi trebali sudjelovati ni upravitelji, budući bi isto trebalo proizlaziti iz samog zakona. Treba li se prema tome ovakav „odnos snaga" prenijeti i u izradu geodetskih elaborata koji nisu naručeni od strane upravitelja posebnih režima? Prije svega, ovdje se radi o mogućnosti da stranke aktivno sudjeluju u postupku određivanja takve granice, predlažu položaj iste i štite svoja prava kakvim pravnim lijekovima. Naime, vrlo je upitno može li međa između posebnog režima i privatnog zemljišta uopće biti predmetom spora. U prilog razmišljanju da ista ne može biti predmetom takvog spora ide zaključak o pravnom shvaćanju sa sjednice imovinsko-pravnog odjela Visokog upravnog suda 6 Su-93/2023-22 (URL 12). U navedenom pravnom shvaćanju, Visoki upravni sud zauzeo je stajalište da se međa između posebnog režima i drugih režima vlasništva u novoj izmjeri ne može označiti spornom. Obzirom na sve navedeno, izbor da stranke koji su vlasnici zemljišta uz posebne režime sudjeluju u određivanju granice takvih režima praktično ni ne postoji. Naime, ako određena granica ne može biti predmet spora pred sudom, odnosno ako o položaju takve granice sud ne može odlučivati, sasvim je logično da o takvom položaju ne može sudjelovati ni vlasnik susjednog zemljišta. Upravitelj posebnog režima, neovisno o rezultatima postupka provedbe bilo kojeg geodetskog elaborata (osim onog čija je zadaća evidentiranje posebnog režima), može u bilo kojem trenutku pokrenuti izradu geodetskog elaborata za evidentiranje takvog režima te i formalno steći uvjete za jednostrano određivanje granice.

Prilikom provedbe geodetskih elaborata za evidentiranje posebnih režima kao jedan od najčešćih problema javlja se u slučajevima kada se takvim elaboratima zadire u čestice katastra nekretnina. Naime, katastarski uredi ne dopuštaju da se takvim elaboratima „konzumiraju" dijelovi čestica koje su prethodno već utvrđene geodetskim elaboratima (takozvane čestice „mjerila 1", odnosno čestice katastra nekretnina). Takav stav najčešće obrazlažu činjenicom da se evidentiranje posebnih režima u smislu provedbe u katastarskom operatu provodi temeljem dostavljenog Z rješenja nadležnoga zemljišnoknjižnog odjela suda, na temelju kojeg katastarski ured promjene provodi bez provedbe upravnog postupka. Čestice katastra nekretnina sukladno ZDIKN-u osnivaju se na temelju pravomoćnog rješenja donesenog u upravnom postupku. Međutim, ovdje valja naglasiti da su posebnim propisima (zakonima) temeljem kojih se i evidentiraju posebni režimi predviđene odredbe koje derogiraju odredbe drugih zakona i propisa koji nisu u skladu s tim propisima. Primjerice, člankom 125. i člankom 133. ZoC je izričito propisano kako se na evidentiranje u katastru i upis u zemljišne knjige javnih i nerazvrstanih cesta ne primjenjuju odredbe zakona kojim se uređuje prostorno uređenje i gradnja, a kojima je propisana parcelacija građevinskog zemljišta i evidentiranje građevina u katastru, ni odredbe zakona kojim se uređuje katastar nekretnina te odredbe drugih zakona i propisa koje su protivne odredbama ZoC-a, koje propisuju način evidencije cesta. Sasvim sigurno, takve odredbe obuhvaćaju i gore navedene, odnosno trebali bi po svemu navedenome derogirati i odredbe ZDIKN-a (načelo *lex speciali derogat lex generali*). Osim u ZoC-u, takve pravne norme postoje i u drugim predmetnim propisima, primjerice članak 132. Zakona o komunalnom gospodarstvu (Narodne novine 68/2018, 110/2018, 32/2020, URL 13), članak 233. Zakona o vodama (Narodne novine 66/2019, 84/2021, 47/2023, URL 14), članak 85. Zakona o željeznici (Narodne novine 32/2019, 20/2021, 114/2022, URL 15) te članak 34. Zakona o pomorskom dobru i morskim lukama (Narodne novine 83/2023, URL 16).

U svim navedenim slučajevima, ključan je odnos ovlaštenog inženjera geodezije prema naručitelju takvog elaborata i drugim strankama u postupku. Bez obzira što u određenom postupku određivanja granica predmetne nekretnine moguće (aktivno) ne sudjeluje upravitelj posebnog režima, potrebno je naručitelju (kao laiku u ovome procesu) objasniti kakva su njegova prava i kakva je (pravna) narav zemljišta s kojim graniči. Posebice, to se odnosi na činjenicu da se takvo zemljište na zahtjev upravitelja može u bilo kojem trenutku evidentirati u svome punom opsegu temeljem odgovarajućeg geodetskog elaborata, ne mareći pritom za postojeće upise ni druge propise koji su u suprotnosti za posebnim propisima te da u takvome postupku naručitelj neće imati pravo (aktivnog) sudjelovanja u određivanju granice. Osim toga, potrebno je naglasiti i kako se naručitelj neće moći pozvati na povjerenje u zemljišne knjige iskoristi li dio zemljišta u određenim daljnjim postupcima (primjerice u sastav građevne čestice). Ovakvi argumenti sasvim bi sigurno trebali kod naručitelja potaknuti interes da se položaj granice utvrdi na najispravniji mogući način i bez sudjelovanja upravitelja posebnog režima. Kako međutim postupati kada naručitelji odbiju takav prijedlog i inzistiraju da se granica evidentira prema oznakama koje su sami postavili moguće i unutar obuhvata posebnog režima, ili primjerice inzistiraju da im ovlašteni inženjer geodezije u sklopu pružanja stručne pomoći pokaže položaj granice prema katastarskom operatu koja granica opet nesumnjivo „zadire" u posebni režim. Srećom, ovlašteni inženjer geodezije na raspolaganju ima mehanizam kojega može upotrijebiti. Nema posebne osnove da ovlašteni inženjer geodezije takve prijedloge naručitelja odbije. Međutim, ovlašteni inženjeri geodezije dužni su u geodetskom elaboratu iskazati načine uporabe zemljišta. Samim time, ukoliko se nesumnjivo radi o zemljištima posebnih režima koji se i koriste (rabe) na poseban način, nema zapreke da se takvo zemljište istakne kao poseban način uporabe – primjerice cesta, groblje ili željeznička pruga. Ovakva praksa međutim trebala bi ostati kao slučaj krajnje

nužnosti, a u svim drugim slučajevima ovlašteni inženjeri geodezije trebali bi u najvećoj mjeri pokušati naručitelja argumentima navesti na prije navedeni način – diobu.

Međutim nisu isključivo naručitelji geodetskih elaborata ti koji svojih zakonite ovlasti rastežu do granice normalnih okvira. Često se u praksi naime događa i da upravitelji posebnih režima prema ovlaštenim inženjerima geodezije imaju posebne zahtjeve, svjesni svojeg povlaštenog zakonskog položaja. Naime, često od ovlaštenih inženjera geodezije traže obavljanje terenskih radnji u vremenu koji nisu predviđeni pozivom, ili primjerice više puta uzastopno. Takve zahtjeve upravitelja ovlašteni inženjer trebao bi predočiti naručitelju. Naime, treba poći od pretpostavke da je u interesu naručitelja da u ovim postupcima sudjeluju upravitelji posebnih režima. Obvezu odazvati se odnosno udovoljiti takvim izvanrednim zahtjevima naručitelja ovlašteni inženjer geodezije nema, ukoliko na tome ne inzistira naručitelj. Treba istaknuti da praktično nema stručnih razloga da se ne udovolji zahtjevima upravitelja, već da se ovdje radi o „ekonomskim" razlozima. Ekonomskim jer isti utječu na poslovanje trgovačkog društva ili ureda ovlaštenog inženjera geodezije, a ne konkretno na stručni rad. Međutim čak i kada se radi o takvim „ekonomskim" razlozima, a ne stručnim, treba naručitelju jasno dati do znanja da se radi o njegovoj odluci te ga upozoriti na moguće posljedice.

Nadalje, u određenim slučajevima posebni režim već je evidentiran u zasebnom postupku (elaboratu), ali postoji nesklad takve evidencije sa stanjem u naravi. Ovdje prvenstveno treba razlučiti dvije situacije. U prvoj, radi se o činjenici da je upravitelj posebnog režima odredio granicu takvog režima i ona je evidentirana u službenoj evidenciji te se takva granica ne podudara s prirodnim ili izgrađenim objektima što je sasvim moguće i realno. Naime, odredbe propisa takvo što omogućuju te tako određenu granicu posebnog režima treba poštivati. U drugoj varijanti, radi se o pogrešnoj evidenciji jasno definirane granice (dakle krivo određenim koordinatama), kada je takva granica određena po granicama kakvih prirodnih ili izgrađenih objekata. Takvo što može biti vidljivo iz skice izmjere. Praksa daljnjih postupanja u takvim slučajevima, s ciljem usklađivanja stanja u službenim evidencijama nije ujednačena. Formalno gledano, postoji samo jedno moguće rješenje. Potrebno je da upravitelj posebnog režima izradi novi geodetski elaborat kojim bi se evidentirao posebni režim u pravom opsegu te zemljište izdvojilo u zasebnu katastarsku česticu. Nakon toga, upravitelj posebnog režima (u određenim slučajevima i vlada RH) treba za takvu česticu donijeti odluku kojom se ona (novoformirana čestica) briše s popisa javnog dobra u općoj uporabi čime joj se ukida status javnog dobra te takvu promjenu provesti u zemljišnoj knjizi čime navedena katastarska čestica postaje čestica u vlasništvu Republike Hrvatske, jedinice lokalne samouprave ili pravnih osoba za upravljanje infrastrukturom. Naravno da obzirom na priloženo nije ni čudno da u praksi postoji čitav niz različitih postupanja u ovim slučajevima. Ovakva procedura prije svega izrazito je vremenski dugotrajna. Treba imati na umu da upravitelji u pravilu (s pravom) nisu skloni naručivanju izrade takvih geodetskih elaborata. Takve elaborate su prethodno već naručili, i očito im nisu isporučeni. Osim toga, odluke kojom se određene čestice brišu s popisa javnog dobra donose predstavnička tijela lokalne vlasti – primjerice gradovi i općine, nadležna ministarstva ili u nekim slučajevima čak vlada Republike Hrvatske. U konačnici, takve čestice su i dalje u vlasništvu Republike Hrvatske ili jedinica lokalne samouprave te nakon završenog opisanog postupka tek predstoji pravna borba da se takva čestica vrati u prijašnji vlasnički režim. Ovakvi slučajevi direktno utječu na povjerenje koje geodetska struka ima pred naručiteljima izrade geodetskih elaborata, upraviteljima posebnih režima te najbitnije prema državi. Sasvim je sigurno da će se, ukoliko takvo povjerenje bude iznevjereno, pronaći novi načini evidencije posebnih režima koji će moguće obuhvaćati i osobe drugih struka, a ne isključivo ovlaštene inženjere geodezije.

6. Zaključak

Stručni geodetski poslovi evidencije granica posebnih režima su, uvažavajući položaj upravitelja posebnih režima, trivijalni. Potrebno je naime evidentirati, odnosno geodetskim metodama snimiti s odgovarajućom točnosti sve lomne točke granice posebnog režima koje odredi upravitelj (uz određene iznimke, primjerice pomorskog dobra) te iste evidentirati u službenim evidencijama putem geodetskog elaborata. U praksi međutim, evidencija posebnih režima često dolazi uz velike kontroverze i sumnje, u dobrom dijelu potkrijepljena činjenicom da ovlašteni inženjeri geodezije zainteresiranim strankama u postupku jasno ne predoče sve bitne činjenice. Takve uzroke prije svega treba tražiti u kompleksnom pravnom normativu, kao i kompliciranim i neizvjesnim pravnim lijekovima. Bez obzira na navedeno, pri obavljanju tih stručnih geodetskih poslova izrazito je bitno svim strankama u postupku jasno predočiti ulogu ovlaštenog inženjera geodezije, njegov položaj i obveze. Ovim radom prema tome ne predlažu se novi pristupi ni konkretna problemska rješenja, već se postojeće pravne forme razlažu putem konkretnih problema u praksi. Iako se tema ovogodišnjeg Simpozija ovlaštenih inženjera geodezije fokusirala na praktična znanja i vještine budućnosti, sigurno je da će osnovna uloga ovlaštenih inženjera geodezije kao stručnih osoba koje održavaju službene državne evidencije i dalje ostati jezgra obavljanja geodetske djelatnosti, barem na području Republike Hrvatske.

Položaj geodezije kao regulirane profesije egzistira isključivo zbog segmenta struke koji provodi interakciju sa službenim državnim evidencijama te s time u vidu, ukoliko zaista ima interesa da se takva praksa i nastavi, potrebno je osigurati standard usluge i proizvoda.

Literatura

URL 1: Imenik ovlaštenih inženjera geodezije, https://www.hkoig.hr/evidencije-hgoig/imenik-ovlastenih-inzenjera-geodezije, (22.5.2024.).

URL 2: Geodetski izvoditelji, https://dgu.gov.hr/pretraga-oig/5026, (22.5.2024.).

URL 3: Zakon o obavljanju geodetske djelatnosti, https://narodne-novine.nn.hr/clanci/sluzbeni/2018_03_25_475.html, (22.5.2024.).

URL 4: Kodeks strukovne etike u obavljanju stručnih geodetskih poslova ovlaštenih inženjera geodezije, https://narodne-novine.nn.hr/clanci/sluzbeni/2021_07_80_1497.html, (22.5.2024.).

URL 5: Pravilnik o geodetskim elaboratima, https://narodne-novine.nn.hr/clanci/sluzbeni/2018_07_59_1237.html, (22.5.2024.).

URL 6: Zakon o cestama, https://www.zakon.hr/z/244/Zakon-o-cestama, (22.5.2024.).

URL 7: Rješenje ustavnog suda, Narodne novine 23/2017, https://narodne-novine.nn.hr/clanci/sluzbeni/2017_03_23_538.html, (22.5.2024.).

URL 8: Vijest o usvojenom Zakonu o izmjenama i dopuni Zakona o cestama s Nacrtom konačnog prijedloga zakona, https://mmpi.gov.hr/vijesti-8/vlada-usvojen-zakon-o-izmjenama-i-dopuni-zakona-o-cestama-s-nacrtom-konacnog-prijedloga-zakona/6587, (22.5.2024.).

URL 9: Zakon o cestama, https://narodne-novine.nn.hr/clanci/sluzbeni/2014_07_92_1843.html, (22.5.2024.).

URL 10: Zakon o državnoj izmjeri i katastru nekretnina, https://www.zakon.hr/z/156/Zakon-o-dr%C5%BEavnoj-izmjeri-i-katastru-nekretnina, (22.5.2024.).

URL 11: Smjernice za definiranje obuhvata vodnih građevina i kriterija za određivanje granica vodnog dobra, https://voda.hr/sites/default/files/dokumenti/propisi-i-obrasci/smjernice_za_definiranje_obuhvata_vodnih_gradevina_i_kriterija_za_odredivanje_granica_vodnog_dobra.pdf, (22.5.2024.).

URL 12: Zaključak o pravnom shvaćanju sa sjednice imovinsko-pravnog odjela Visokog upravnog suda, https://sudovi.hr/sites/default/files/dokumenti/2023-11/Zaklju%C4%8Dak_sa_sjednice_2._11._2023._imovinsko_pravni_odjel.pdf, (22.5.2024.).

URL 13: Zakon o komunalnom gospodarstvu, https://www.zakon.hr/z/319/Zakon-o-komunalnom-gospodarstvu, (22.5.2024.).

URL 14: Zakon o vodama, https://www.zakon.hr/z/124/Zakon-o-vodama, (22.5.2024.).

URL 15: Zakon o željeznici, https://www.zakon.hr/z/661/Zakon-o-%C5%BEeljeznici, (22.5.2024.).

URL 16: Zakon o pomorskom dobru i morskim lukama, https://narodne-novine.nn.hr/clanci/sluzbeni/2023_07_83_1293.html, (22.5.2024.).

Special Land Regimes and their Interaction with Regular Land Regimes within Geodetic Elaborates

Abstract

Geodetic elaborates are used as a technical basis to register changes in the official state registers of Cadaster and Land registry. In cases where parcels of interest of geodetic elaborates are neighboring parcels that are considered special regimes such as roads, communal infrastructure, railroads, maritime property and other similar regimes the uniform practice of Chartered geodetic engineers and cadastral offices does not exist. The main goal of this study is to highlight the complexity of the issue and to point out the problems that Chartered geodetic engineers encounter while working on such geodetic elaborates. Such issues can be resolved only by Chartered geodetic engineers that understand all aspects of these issues. This study does not provide any new skills for the future, however, to secure the position of the geodetic profession as regulated profession in the future, it is necessary to strengthen the existing role of Chartered geodetic engineer through the quality of his work. Therefore, it is necessary to improve the existing skills and knowledge of Chartered geodetic engineers in areas where they have always excelled – working with official state registers.

Keywords: *Chartered Geodetic Engineer, derived state recording, Geodetic elaborates, special regimes*

Prijava na Javni poziv za komasaciju poljoprivrednog zemljišta – iskustva iz prakse

Filip Pavelić[1], Stjepan Miletić[1], Zdenko Potlaček[2]

[1] Zavod za fotogrametriju d.d., Borongajska cesta 71, Zagreb, Hrvatska, filip.pavelic@zzf.hr, stjepan.miletic@zzf.hr

[2] umirovljenik – bivši djelatnik Zavoda za fotogrametriju d.d., Zagreb, Hrvatska, zdenko.potlacek@gmail.com

Sažetak

Prošlo je i više od 40 godina od kada su se provodili radovi u postupcima komasacija na području Republike Hrvatske. Ministarstvo poljoprivrede Republike Hrvatske objavilo je Javni poziv 2022. godine za odabir određenog područja jedinice lokalne samouprave za provođenje komasacije u skladu s Programom komasacije poljoprivrednog zemljišta do 2026. godine. U periodu od dvije godine pristigle su tek četiri prijave jedinica lokalne samouprave od mogućih više od pet stotina koliko ih je u Republici Hrvatskoj. U ovom radu prikazat će se koji su to izazovi koje je potrebno savladati kako bi se Program komasacije pokrenuo temeljem važećih zakonskih propisa. Proći će se kroz aktivnosti koje prethode realizaciji samog projekta komasacije. Naposljetku, usporedit će se rezultat aktivnosti odrađenih na terenu s uvjetima koji su definirani u Javnom pozivu i novom Zakonu o komasaciji poljoprivrednog zemljišta koji je na snazi od 23. travnja 2022. godine.

Ključne riječi: *komasacija, Ministarstvo poljoprivrede, poljoprivredno zemljište*

1. Uvod

„Komasacija je skup administrativnih i tehničkih postupaka kojima se poljoprivredno zemljište na području jedne ili više katastarskih općina, rascjepkano na katastarske čestice male površine i nepravilna oblika, okrupnjava odnosno grupira u veće katastarske čestice, osnivaju se katastarske čestice pravilnijeg oblika, uređuju putne i kanalske mreže te nesređeni vlasnički, drugi stvarno pravni i ostali odnosi na zemljištu.“ (NN 46/22)

U Republici Hrvatskoj vrijednost poljoprivredne proizvodnje u 2022. godini iznosila je 3,2 milijarde eura. Otprilike 166 400 upisanih poljoprivrednika koristi oko 1,16 milijuna hektara poljoprivrednog zemljišta (Ministarstvo poljoprivrede, 2023). Prema podacima Agencije za plaćanje u poljoprivredi, ribarstvu i ruralnom razvoju na dan 24. svibnja 2024. godine evidentirano je 1.352.935 ARKOD parcela, a njihova medijalna površina iznosi 0.32 ha (upit putem email-a, 24.5.2024 i 1.7.2024.).

Već su dobro poznate prednosti komasacije: grupiranje zemljišta u veće i pravilne čestice, ekonomično iskorištavanje zemljišta, stvaranje povoljnijih uvjeta za razvitak poljoprivrednih naselja i obiteljskih poljoprivrednih gospodarstva, osnivanje i izgradnja poljoprivrednih putova i drugih prometnica, kanalska mreža, pravilno oblikovanje postojećih potkućnica, osnivanje novih gradilišta i to sve u svrhu stvaranja povoljnijih uvjeta za iskorištavanje poljoprivrednog zemljišta. U konačnici, najveća vrijednost koju dobiva vlasnik zemljišta je *vrijeme za sebe i obitelj* – značajno se smanjuje putovanje od parcele do parcele. Slično je napisao u svome radu i Smilaj (1942) prije 84 godine: *„Seljak time lakše i brže dospieva obraditi cio posjed, bolje ga obradi, manje umara sebe i stoku, manje oštećuje kola i gospodarsko oruđe, u posjed uložen novac nosi mu više koristi“*.

2. Program, Javni poziv, Prijedlog idejnog rješenja i uvjeti

Prema članku 2. Zakona o komasaciji poljoprivrednog zemljišta (u daljnjem tekstu: Zakon) svi postupci za potrebe komasacije su hitni postupci. Nositelj komasacije može biti jedinica lokalne samouprave (u daljnjem tekstu: JLS), Grad Zagreb ili Ministarstvo poljoprivrede (u daljnjem tekstu: Ministarstvo). Od važnih dionika u postupku komasacije su svakako stranke (vlasnici, posjednici i osobe koje imaju druga stvarna prava) i sudionici (vlasnici, nositelji prava građenja, osobe koje su ostvarile pravo na dodjelu zemljišta).

Prošlo je gotovo 40 godina od provedbi zadnjih komasacija. Jedna od posljednjih komasacija završena je 1988. godine na području Grada Jastrebarsko u k.o. Kupinec. Godine 2016. Agencija za poljoprivredno zemljište pripremila je četiri pilot projekta kojima se po prvi puta nakon osamostaljenja države trebao započeti postupak komasacije. Općine kandidati bile su: Udbina, Cerovlje, Podturen i Zdenci. Tada su bila osigurana sredstva u iznosu od 44 milijuna kuna. Za sve lokacije izrađen je Prijedlog idejnog rješenja, odrađen skup sudionika komasacije, ali kasnije su radovi na tom projektu obustavljeni (URL 1). U 2021.

godini ponovno su započete aktivnosti na pokretanju i provođenju komasacija na prostoru Republike Hrvatske.

2.1. Program komasacije 2021-2026

Ministarstvo je donijelo Program komasacije poljoprivrednog zemljišta za razdoblje od 2021. godine do 2026. godine (u daljnjem tekstu: Program). Cilj je smanjiti broj zemljišnih parcela po jednom vlasniku/korisniku te povećati površinu pojedine parcele. Programom je predviđena gradnja javne mreže poljskih puteva i javne mreže kanala za potrebe melioracije. Plan je da se komasacijom obuhvati najmanje 18.000 ha poljoprivrednog zemljišta za što su osigurana financijska sredstva u iznosu od 39.816.842 eura. (NN 140/22)

2.2. Javni poziv

Javni poziv za prijavu na Program objavljuje Ministarstvo kojim poziva jedinice lokalne samouprave, odnosno Grad Zagreb, da prijave poljoprivredna područja za provođenje komasacije. Na Program mogu biti prijavljena i područja na kojima je postupak komasacije započet, a nije dovršen te dokumentacija nije dostupna zbog proteka vremena ili Domovinskog rata, sukladno članku 55. Zakona. U takvim područjima, građevinski radovi komasacije su izvršeni ili su u završnoj fazi izvršavanja (NN 46/22). Prvi Javni poziv od strane Ministarstva objavljen je 23. prosinca 2022. godine u kojemu je propisano koje sve podatke je potrebno priložiti uz prijavu. Prema Zakonu, nositelj komasacije može biti jedinica lokalne samouprave ili Grad Zagreb odnosno Ministarstvo. Drugi poziv objavljen je 19. prosinca 2023. godine.

2.3. Prijedlog idejnog rješenja komasacije

Prikupljene i analizirane podatke potrebno je objediniti u dokument pod nazivom Prijedlog idejnog rješenja (PIR). U PIR-u se prikazuju: podaci o komasacijskom području i komasacijskoj gromadi, podaci o osobama koje su vlasnici zemljišta, pregledne karte, procjena predviđenih radova, podaci o izvorima financiranja troškova komasacije. S obzirom na količinu podataka koji su sadržani u PIR-u, preglednost bi značajno olakšalo njegovo formiranje u obliku digitalne baze podataka, a grafički prilozi u shp zapisima.

U postupku izrade PIR-a potrebno je obaviti niz aktivnosti. Od nadležnog upravnog tijela JLS-a i područne (regionalne samouprave) potrebno je prikupiti sljedeće: uvjerenje nalaze li se k.č. izvan granica građevinskog područja, očitovanje je li za k.č. u vlasništvu Republike Hrvatske podnesen zahtjev za povrat imovine, uvjerenje da k.č. nisu dane u neki oblik raspolaganja državnim poljoprivrednim zemljištem. Posebne uvjete za zaštitu prirode daje državno upravno tijelo za poslove zaštite prirode. Sukladno propisima kojima se uređuje zaštita prirode potrebno je ishoditi akt i prihvatljivosti zahvata komasacije za ekološku mrežu. Nadalje, u Javnom pozivu navedeno je za što sve očitovanja moraju dati: Ministarstvo unutarnjih poslova, Hrvatske vode, Hrvatske šume, Hrvatske autoceste, HŽ Infrastruktura. Posljednja aktivnost koja je navedena u Javnom pozivu odnosi se na prikupljanje suglasnosti vlasnika poljoprivrednog zemljišta za provedbu komasacije. S obzirom da je to vrlo zahtjevna aktivnost, bit će detaljnije opisan postupak njene provedbe i uvjeti. (Ministarstvo poljoprivrede, 2022)

Vlasnici zemljišta davanjem suglasnosti na PIR iskazuju interes za provođenje komasacije (NN 46/22). Kako bi suglasnost vlasnika zemljišta bila važeća, nužno je ispuniti dva uvjeta (NN 46/22):

1. potrebna je suglasnost *50 % + 1 vlasnika* za provođenje komasacije,
2. koji u svome vlasništvu imaju *67 % ukupne površine* poljoprivrednog zemljišta s područja na kojem se planira provoditi komasacija.

Ovi uvjeti po prvi puta se pojavljuju u novom Zakonu o komasaciji. S obzirom na povijest hrvatskog katastra i zemljišne knjige te njihovog održavanja, za pretpostaviti je kako će ovo bit jedna od zahtjevnijih aktivnosti u postupku izrade PIR-a. U slučaju da se PIR izrađuje za područje koje zadovoljava uvjete prema članku 55. Zakona, tada nije potrebno prikupljanje suglasnosti vlasnika zemljišta jer se postupak smatra započetim.

Prema Zakonu (NN 46/22), Svoju suglasnost vlasnici zemljišta mogu dostaviti Nositelju komasacije u roku 15 dana od dana održavanja sastanka. Na sastanku s vlasnicima potrebno je izabrati jednog od članova Povjerenstva iz redova vlasnika, a čije zemljište ulazi u površinski kriterij. Prisutnost samo jednog člana u Povjerenstvu iz redova vlasnika možda nije najbolje rješenje s obzirom na kompleksnost projekta. Osim toga, prilikom odabira osobe potrebno je obratiti pozornost na neke stvari koje nisu eksplicitno propisane. Bilo bi dobro da ta osoba bude dostupna cijelo vrijeme tijekom provedbe projekta komasacije i da dobro poznaje predmetno područje. Zakon o komasaciji iz 1987. godine propisao je obavezu sastavljanja Odbora učesnika koji je mogao imati od 5 do 11 članova iz redova vlasnika (NN 5/87). Odbor učesnika komasacije bio je savjetodavni organ povjerenstva za komasaciju i izvođača geodetsko-tehničkih radova. Članovi odbora učesnika sudjelovali su u svim raspravama povjerenstva. Također, birao se i član koji je sudjelovao u procjeni zemljišta kao ispomoć u postupku procjene tržne vrijednosti zemljišta u komasaciji.

Iako se na sastancima vlasnika navode velike prednosti od provođenja komasacije, moguće je da će manjina sudionika komasacije pružiti otpor – često zavedeni neutemeljenim mišljenjem kako neće ništa dobiti, nego da će samo izgubiti. Takvi primjeri dogodili su se u Hrvatskoj na području Koprivnice i Đurđevca (Boban, T. 2012).

2.4. Rezultati javnog poziva iz 2023. godine

Potrebnu dokumentaciju, sukladno Javnom pozivu u 2023. godini, uspjelo je prikupiti i iskazati interes ukupno četiri jedinice lokalne samouprave – *Grad Novska, Općina Mali Bukovec, Općina Konavle i Općina Levanjska Varoš*. S obzirom da u Hrvatskoj ima ukupno 556 JLS-ova, ovaj podatak bi možda trebalo istražiti u dva smjera: ili je slaba zainteresiranost JLS-

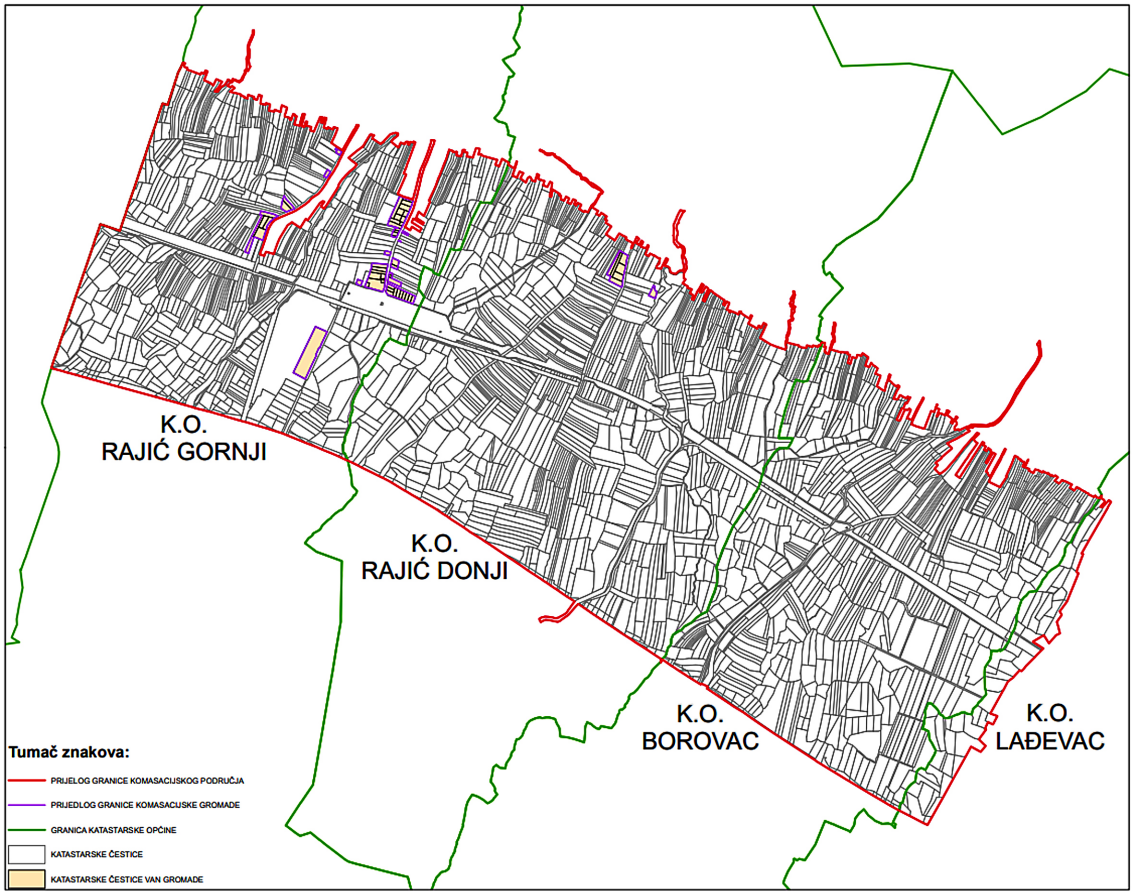
Tablica 1: Katastarske općine, površine i očekivani troškovi za komasacije

Jedinica lokalne samouprave	Naziv k.o.	Površina	Procijenjena vrijednost javnog natječaja
Grad Novska	Borovac, Lađevac, Rajić Donji, Rajić Gornji	8.963.000 m^2	1.254.820,00 €
Općina Konavle	Komaji, Pridvorje, Lovorno, Popovići, Gruda, Mihanići, Radovčići	4.766.000 m^2	951.173,61 €
Općina Mali Bukovec	Sveti Petar, Lunjkovec	2.192.186 m^2	190.000,00 €

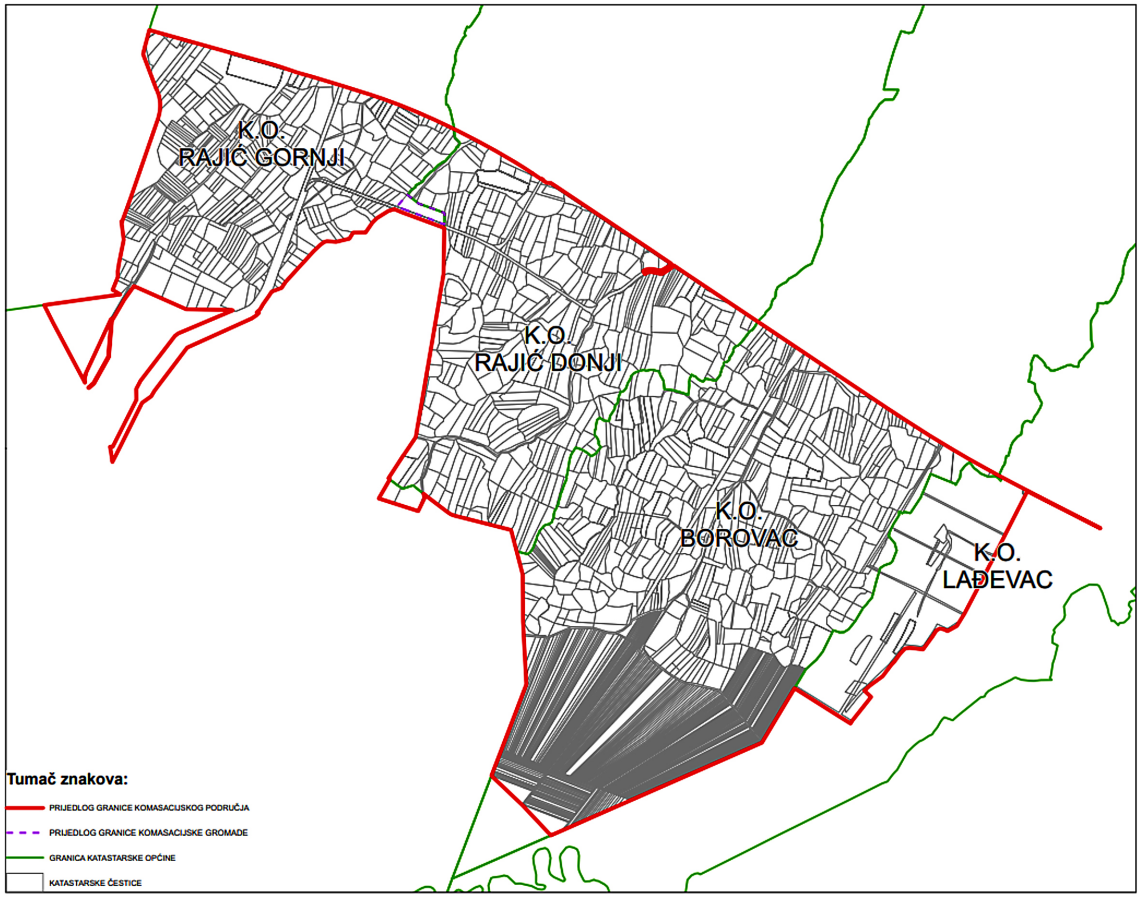
ova, ili zahtjevno prikupljanje i izrada same dokumentacije. Bez obzira što je uzrokovalo ovakve rezultate, svakako je potrebno još više poraditi na informiranju čelnih ljudi JLS-ova o mogućnostima provedbe komasacije i dobrobitima koje dobiva lokalno stanovništvo, a u konačnici i sam JLS. Ministarstvo je za tri prijave donijelo Odluke za pokretanje postupka izrade prijedloga projekta komasacije (URL 2). Sastavni dio Odluka je i imenovanje Povjerenstva za komasaciju koje se sastoji od sedam članova i njihovih zamjena. U tablici 1 prikazan je popis katastarskih općina i površine koje bi trebale biti obuhvaćene komasacijom te procijenjene vrijednosti javnog natječaja izrade i provedbe projekta komasacije (URL 3).

3. Postupak izrade PIR-a na primjeru Grada Novske

Za potrebe ovog rada, opisat će se postupak izrade PIR-a kroz sve faze za katastarske općine na području Grada Novske te spomenuti proživljena iskustva i dati prijedloge koji bi možda osigurali još veću kvalitetu provođenja aktivnosti koje prethode izradi projekta komasacije. Grad Novska je izradio PIR za predloženo područje komasacije koje zahvaća četiri katastarske općine. Na cijelom području nalazi se dio na kojem je moguće provesti završetak započete komasacije sukladno članku 55. Zakona. Uz odobrenje Ministar-



Slika 1: Pregledna karta s granicom komasacijskog područja i zemljišta za komasacijsku gromadu (Zavod za fotogrametriju d.d., Zagreb)



Slika 2: Pregledna karta s granicom komasacijskog područja (prema čl. 55. Zakona) (Zavod za fotogrametriju d.d., Zagreb)

stva i Grada Novske pokrenuta je izrada dva PIR-a. U nastavku će detaljnije biti opisan postupak izrade PIR-a za dio koji ne podliježe članku 55. Zakona koji se odnosi na područja na kojima su građevinski radovi komasacije izvršeni ili su u završnoj fazi izvršavanja, ali sve je prekinuto zbog proteka vremena ili Domovinskog rata. Za napomenuti je kako su u izradi PIR-a aktivnosti identične u oba slučaja (bilo po članku 55., bilo da se kreće od početka). Razlika je samo u aktivnosti prikupljanja suglasnosti suvlasnika koja je obavezna u slučaju da se prijavljuje područje na kojem je potrebno provesti komasaciju od početka.

Kako je prije navedeno, PIR sadržava određene sastavne dijelove, odnosno obaveznu dokumentaciju koju je potrebno priložiti uz prijavu na Javni poziv. Iako su propisani sastavni dijelovi PIR-a, bilo bi dobro da su propisane i tehničke specifikacije koje bi detaljnije definirale njegov sadržaj i izgled i na taj način omogućili međusobnu usklađenost u pogledu standarda.

Prva aktivnost koju je potrebno obaviti u cilju izrade PIR-a je preuzimanje službenih podataka katastra i zemljišne knjige. Nakon toga slijedi definiranje granice komasacijskog područja (Slika 1) koje se može sastojati od više komasacijskih gromada što se prikazuje na preglednoj karti. Slika 2 prikazuje prijedlog komasacijskog područja za koje se komasacija provodi na temelju čl. 55 Zakona.

Osim pregledne karte s granicom komasacijskog područja i zemljišta za komasacijsku gromadu, potrebno je još izraditi:

- preglednu kartu s prikazom postojeće putne i kanalske mreže,
- preglednu kartu s prikazom položaja zemljišta prema karakterističnom vlasništvu,
- preglednu kartu s prikazom položaja voćnjaka i vinograda.

Komasacijska gromada grada Novske u površini od 1017,8 ha (podatak iz grafike katastarskog operata) zahvaća četiri katastarske općine. Na predmetnom području upisano je ukupno 1150 vlasnika (4237 udjela) na ukupno 2835 katastarskih čestica. Usporedbom površina sadržanih u katastarskom operatu i zemljišnoj knjizi, utvrđena je razlika u iznosu od 5,2 ha. U PIR-u je potrebno posebno navesti katastarske čestice s određenom kulturom. Tako u komasacijskoj gromadi postoji 67 k.č. koje su evidentirane kao voćnjaci, vinogradi, odnosno na kojima postoji jednostavna i druga građevina. Nadalje, komasacijsko područje i komasacijsku gromadu potrebno je opisati s obzirom na administrativne nadležnosti.

U tablici 2 prikazana je struktura komasacijske gromade s obzirom na vrstu vlasništva i površinu koja pripada svakome od njih. Vidljivo je kako najveći udio u komasacijskoj gromadi imaju fizičke osobe (81 %).

Tablica 2: Katastarske općine, površine i očekivani troškovi za komasacije

Vrsta vlasnika	Površina	Prosječna veličina (udjela) k.č.	Udio u komasacijskom području
Republika Hrvatska	145.8 ha	0.39 ha	14.4 %
Fizičke i pravne osobe	820.4 ha	0.22 ha	81.0 %
Javno dobro (RH)	46.4 ha	0.68 ha	4.6 %

S obzirom da je jedna osoba (pravna ili fizička) jedan vlasnik, najvećom površinom raspolaže Republika Hrvatska, i to sa 145.8 ha. Prosječna veličina katastarske čestice, odnosno udjela u komasacijskoj gromadi, iznosi 0.22 ha

Nakon izrade PIR-a, isti se dostavlja na mišljenje i suglasnost ministarstvu nadležnom za poslove pravosuđa i Državnoj geodetskoj upravi koji u roku od 30 dana moraju dostaviti svoja mišljenja (NN 46/22).

U postupku izrade PIR-a, a nakon prikupljenih suglasnosti, potrebno je napraviti sastanak s vlasnicima zemljišta koji je ujedno i najzahtjevnija aktivnost. Na tom sastanku vlasnici zemljišta imaju priliku svojim potpisom dati suglasnost na PIR te na taj način iskazati interes za provođenje komasacije. Sastanak s vlasnicima zemljišta najprikladnije je napraviti na području na kojem se planira provoditi komasacija i to u dovoljno velikoj prostoriji (društveni dom, sportska dvorana). Iako je prema službenim podacima bilo evidentirano 1150 upisanih vlasnika, na skup se odazvalo znatno manje. U ovom trenutku uočava se prva velika prepreka u ostvarenju zakonskih preduvjeta: za komasaciju potrebna je suglasnost od 50 %+1 vlasnika koji u svom vlasništvu imaju 67 % površine područja na kojem se planira komasacija. Možda bi prikupljanje bilo olakšano kada bi se morao zadovoljiti samo površinski kriterij pa čak i da je veći, primjerice 75 %. Osim značajnog pojednostavljenja u prikupljanju potpisa, objektivno gledajući, možda bi površinski kriterij bio pravedniji. Naime, komasaciju uglavnom žele poljoprivrednici koji obrađuju velike površine te im je cilj uživati dobrobiti komasacije. Sagledavajući kriterij vlasništva, u praksi je, na primjer, moguć sljedeći scenarij: 45 % poljoprivrednika koji su za komasaciju obrađuju 75% površine, a u skupini preostalih 65 % nalaze se oni koji su pokojni, odselili, ne mogu obrađivati zemlju, ne žele obrađivati zemlju i slično. Tako da u teoriji uvjet vlasništva može onemogućiti provedbu komasacije unatoč dobroj volji velikih poljoprivrednika. Druga mogućnost koja bi se mogla primijeniti je usklađenje zemljišnoknjižnih i katastarskih podataka sastavljanjem prijedloga ZK uložaka kao u postupku provođenja Višegodišnjeg programa katastarskih izmjera. U slučaju neispunjavanja uvjeta za provedbu komasacije, podaci se, uz verifikaciju nadležnog općinskog suda, uvijek mogu iskoristiti za ažuriranje postojećih podataka glede upisanih osoba u evidencijama katastra i zemljišne knjige. Prije samog prikupljanja potpisa, uvede se posebna aktivnost u kojoj bi se formirali prijedlozi zemljišnoknjižnih uložaka uz pomoć pravnih stručnjaka. Na taj način bi se evidencije „pročistile" od upisanih pokojnih osoba. Treća, možda i najbrža, mogućnost koja bi se mogla primijeniti je da glavni pokretač komasacije bude Republika Hrvatska, odnosno Ministarstvo poljoprivrede u suradnji s jedinicom lokalne samouprave. Javni skup je najbolja prilika za skupiti što veći broj potpisa u najkraćem roku od strane vlasnik i isto tako najbolji način odgovoriti na sva njihova pitanja. Kako bi vlasnici shvatili dobrobiti postupka komasacije, jako je bitno da glavni govornici na skupu (Nositelj komasacije, izvoditelj koji radi PIR, predstavnik Ministarstva) izvrsno ovladavaju tematikom te na jednostavan i primjeren način znaju verbalizirati odgovore. S obzirom na stanje upisanih vlasnika u službenim evidencijama te njihovu ažurnost glede promjena, do određenih vlasnika je nemoguće doći (pokojni), a do određenih izuzetno zahtjevno (odselio, promijenio adresu). Rok od 15 dana za prikupljanje potpisa u ovakvim slučajevima postaje prekratak. Ono iziskuje puno fizičkih aktivnosti (putovanja do vlasnika ili vlasnika do JLS-a, skeniranja, ishođenje punomoći, …) koje troše mnogo vremena. Iz tog razloga, bilo bi dobro ako bi rok za prikupljanje potpisa bio duži od 15 dana. U ovom dijelu, od velike pomoći u pronalasku određenih vlasnika, može biti JLS (djelatnici) i žitelji na predmetnom području. U pogledu izbora samo jednog predstavnika iz redova vlasnika zemljišta, preporuka bi bila da se odaberu tri predstavnika i to u postupku izrade projekta komasacije.

Nakon što su prikupljene prethodno opisane potrebne suglasnosti, PIR se dostavlja rješavatelju (izvršno tijelo JLS-a ili Grada Zagreba odnosno Ministarstvo) koji donosi odluku o pokretanju komasacije. Tim činom PIR ujedno postaje idejno rješenje komasacije i njezin sastavni dio (NN 46/22). U konačnici, uspješno su provedene sve aktivnosti u izradi PIR-a za područje koje podliježe članku 55. Zakona, a za koje je u postupku javni natječaj za izradu projekta komasacije. Iz tehničkih specifikacija natječajne dokumentacije za izradu projekt komasacije propisano je niz aktivnosti (ukupno 21 točka) koje mora obaviti stručna osoba za geodetske poslove. Opseg posla i rok od šest mjeseci u kojem je potrebno izraditi prijedlog projekta komasacije bit će veliki izazov za geodetsku struku. Prenošenje rezultata, iskustava i prijedloga u fazi izrade projekta komasacije bilo bi od velikog značaja u pogledu približavanja ove tematike geodetski stručnjacima u Republici Hrvatskoj.

**Svi podaci i iskustva navedeni u ovome poglavlju korišteni su iz PIR-a koji je izradio Zavod za fotogrametriju d.d. za prijavu na Javni poziv Grada Novske*

4. Zaključak

Po drugi put nakon osamostaljenja Hrvatske pokrenule su se aktivnosti u svrhu pripremnih radova za realizaciju komasacija. Ministarstvo je osiguralo financijska sredstva te upućivanjem javnog poziva dalo mogućnost zainteresiranim JLS-ovima da se prijave. U 2023. godini odluka je donesena za njih tri. To govori kako je izrađena dokumentacija od strane Zavoda za fotogrametriju d.d. sukladna svim uvjetima iz Javnog poziva što se da iščitati iz provedenog javnog natječaja za izradu projekta komasacije.

Na temelju primjera iz prakse u ovome radu su opisane aktivnosti koje je potrebno provesti kako bi se realizirala prijava na Javni poziv, odnosno izradio PIR. Preglednost PIR-a bila bi pojednostavljena kada bi se on formirao u obliku digitalne baze podataka, a grafički prilozi u shp zapisima.

Nužno je ispuniti dva uvjeta kako bi se moglo krenuti u realizaciju komasacije - potrebna je suglasnost 50 % + 1 vlasnika za provođenje komasacije, koji u svome vlasništvu imaju 67 % ukupne površine poljoprivrednog zemljišta s područja na kojem se planira provoditi komasacija. Ispunjenje samo površinskog uvjeta, pa čak i ako bi on bio veći (npr. 75 %), bilo bi znatno jednostavnije i pravednije. Komasaciju uglavnom potiču poljoprivrednici koji obrađuju velike površine. Zbog trenutnog stanja u službenim evidencijama, možda bi trebalo uvesti aktivnost zemljišnoknjižnog ispravnog postupka kako je primijenjeno u provedbi katastarskih izmjera. Na taj način iz evidencija bi se obrisali pokojni i bivši vlasnici.

Nadalje, rok od 15 dana za prikupljanje potpisa od dana kada je održan sastanak vlasnika svakako bi trebalo produžiti jer potrebno je stupiti u kontakt s velikim brojem ljudi što iziskuje puno vremena. Uz to, zbog zahtjevnosti cijelog projekta, svakako bi bilo dobro imati barem tri člana povjerenstva iz redova vlasnika koji su neophodna pomoć izvoditelju geodetsko-tehničkih radova.

Postupak komasacije zasigurno je za realizaciju jedan od najzahtjevnijih projekata u kojem značajan udio ima više struka kao što su pravo, geodezija, agronomija. Cijelo vrijeme od početka postupka provođenja komasacije treba graditi povjerenje između nositelja komasacije, izvođača geodetsko-tehničkih radova, povjerenstva i stvarnih vlasnika, posjednika zemljišta. Na taj način može se realizirati zahtjevan projekt komasacije poljoprivrednog zemljišta, a da sudionici komasacije u konačnici budu zadovoljni.

Iz primjera koji je obrađen u ovome radu, jasno je kako su geodetski stručnjaci oni koji mogu donijeti značajan doprinos u fazi izrade PIR-a, a isto tako značajan doprinos imat će i u fazi izrade projekta komasacije. S obzirom da komasacije nisu aktivirane već 40-ak godina na prostorima Republike Hrvatske, potrebno je prikupiti sva iskustva u fazi izrade projekata komasacije za ove 4 uspješne prijave. Zatim na temelju prikupljenih iskustava, ako je potrebno proširiti zakonsku regulativu, tako da se u najvećoj mjeri postupak komasacije pojednostavi, te u najvećoj mjeri poveća njegova kvaliteta.

Pokrenuti postupci izrade projekata i provedbe komasacija na području Novske, Konavla i Malog Bukovca od strateškog su značaja za Republiku Hrvatsku i geodetsku struku, stoga je izuzetno važno da se uspješno privedu kraju. Danas smo svjedoci vremena kada imamo priliku započeti pisati jednu novu povijest komasacija – želimo li propustiti tu priliku?

Literatura

Boban, T. (2012): Značenje primjene komasacije u prošlosti i sadašnjosti uz vrednovanje nekoliko specifičnih lokacija u Požeško-slavonskoj županiji, Radovi Zavoda za znanstveni i umjetnički rad u Požegi, 1, 273-291.

Ministarstvo poljoprivrede (2023): Godišnje izvješće o stanju poljoprivrede u 2022. godini

Ministarstvo poljoprivrede (2022): Javni poziv za odabir određenog područja za provođenje komasacije u skladu s programom komasacije poljoprivrednog zemljišta do 2026. godine

Narodne novine (1987): Zakon o komasaciji, NN 5/87.

Narodne novine (2022): Odluka o donošenju Programa komasacije poljoprivrednog zemljišta za razdoblje do 2026. godine, NN 140/2022.

Narodne novine (2022): Zakon o komasaciji poljoprivrednog zemljišta, NN 46/2022.

Smilaj, I. (1942): Komasacija i šumsko gospodarstvo, Hrvatski šumarski list, 4, 98-114.

Žeželj, R., Beuk, K. (2023.): Prijedlog idejnog rješenja komasacije za k.o. Rajić Donji, k.o. Rajić Gornji, k.o. Borovac, k.o. Lađevac, Zavod za fotogrametriju d.d., osobna arhiva.

URL 1: https://www.poslovni.hr/hrvatska/gotovo-je-s-induciranom-komom-krece-komasacija-303213

URL 2: https://euractiv.hr/poljoprivreda/a6271/Nakon-40-godina-u-Hrvatskoj-konacno-krece-okrupnjavanje-poljoprivrednog-zemljista.html (23.5.2024.)

URL 3: https://poljoprivreda.gov.hr/istaknute-teme/poljoprivreda-173/poljoprivredno-zemljiste/komasacija-poljoprivrednog-zemljista/odluke-o-odabiru-podrucja-na-kojem-ce-se-provoditi-komasacija/6444 (23.5.2024.)

Application to the Public Call for Agricultural Land Consolidation – Practical Experiences

Abstract

More than 40 years has passed from last actions in land consolidation procedures in the territory of the Republic of Croatia. The Ministry of Agriculture of the Republic of Croatia has made a Public Call in 2022 for the selection of specific areas of local self-government units for the implementation of land consolidation, in accordance with the Program for the Consolidation of Agricultural Land until 2026. Only four applications were received in a period of two years, out of more than five hundred local self-government units in the Republic of Croatia. This paper will show some of the challenges that need to be overcome in order to achieve the Land Consolidation Program and will list the activities that precede the realization of the Land Consolidation Project. This paper compares results of the field activities with the conditions defined in the Public Call and the new Law on Agricultural Land Consolidation, which has been in force since April 23, 2022.

Keywords: *land consolidation, Ministry of Agriculture, agricultural land*

Interoperabilnost zemljišnih podataka kao čimbenik postupka digitalne transformacije javne uprave

Josipa Budić[1], Damir Robić[1], Marinko Požega[1]

[1] Ericsson Nikola Tesla d.d., Krapinska 45, Zagreb, Hrvatska, josipa.budic@ericssonnikolatesla.com, damir.robic@ericssonnikolatesla.com, marinko.pozega@ericssonnikolatesla.com

Sažetak

Digitalna transformacija javne uprave strateško je opredjeljenje Republike Hrvatske. Stvaranjem javnih registara u digitalnom obliku stvaraju se preduvjeti za povezivanje i međusobnu razmjenu podataka u svrhu povećanja efikasnosti i kvalitete pružanja javnih usluga. Međusobna razmjena podataka čini interoperabilnost kao ključni čimbenik za ostvarenje digitalne transformacije. Temeljni registar podataka katastra i zemljišnih knjiga pohranjen je i održava se kroz Zajednički informacijski sustav zemljišnih knjiga i katastra (ZIS). Putem državne informacijske infrastrukture, podaci katastra i zemljišnih knjiga dostupni su svim tijelima javne uprave u svrhu obavljanje poslova iz njihova djelokruga. U katalogu ZIS usluga nalazi se preko 120 različitih servisa iz domene zemljišnih podataka namijenjenih različitim skupinama korisnika. U ovom trenutku, 58 servisa objavljeno je putem državne sabirnice (engl. Government Service Bus – GSB). Na ovaj način javnopravna tijela te jedinice lokalne i regionalne samouprave izravno u svoje sustave mogu dobiti podatke katastra i zemljišnih knjiga (npr. podaci o katastarskoj čestici i upisanim osobama, zemljišnoknjižni izvadak i slično). ZIS kao jedan od najznačajnijih nacionalnih sustava integriran je s preko 20 različitih sustava. To su sustavi državne informacijske infrastrukture, poslovni sustavi drugih tijela javne uprave, ali i sustavi različitih stručnih tijela, a sve u svrhu efikasnosti provođenja postupaka i upravljanja podacima katastra i zemljišne knjige.

Ključne riječi: *digitalna transformacija, GSB – državna sabirnica, interoperabilnost, temeljni registri, ZIS*

1. Uvod

Digitalna transformacija je proces integracije digitalnih tehnologija u poslovne procese u svrhu optimizacije, povećanja efikasnosti i kreiranja inovativnih proizvoda i usluga. U javnoj upravi se kroz digitalnu transformaciju moderniziraju javne usluge i administracija što olakšava i ubrzava interakciju građana s državnim institucijama.

U digitalnoj transformaciji koriste se raspoložive napredne tehnologije: računarstvo u oblaku, analiza velike količine podataka, internet stvari, umjetna inteligencija, strojno učenje, elektronički potpisi i certifikati, mobilne tehnologije, geografski informacijski sustavi, blockchain itd. Neke tehnologije već su dulje vrijeme dostupne, ali primjena novih tehnologija u procese javne uprave često je bila spora. Pandemija je donijela velike promjene jer su digitalne javne usluge postale neophodne i cijeli postupak digitalizacije znatno se ubrzao. Trenutno, promjene koje se događaju kroz digitalnu transformaciju nikada nisu bile brže i zahtijevaju prioritetne prilagodbe.

Digitalna transformacija javne uprave provodi se na različitim razinama – na razinama različitih javnopravnih tijela, ali i na razini cijele države. Digitalna transformacija na razini države uvodi standardizirane i centralizirane zajedničke funkcionalnosti dok su javnopravna tijela bila fokusirana na digitalizaciju vlastitih poslovnih procesa. U ovom trenutku, razina digitalizacije došla je na razinu kada se sve više pojavljuje potreba za automatiziranim interakcijama između različitih sustava, tj. potreba za interoperabilnosti.

Interoperabilnost u javnoj upravi odnosi se na sposobnost različitih sustava, organizacija i službi unutar javnog sektora da efikasno i nesmetano razmjenjuju informacije i međusobno komuniciraju. Ključni aspekti interoperabilnosti su Tehnički (standardizirana tehnička rješenja za prijenos podataka), Semantički (identična interpretacija podataka), Organizacijski (usklađivanje poslovnih procesa) i Pravni (zakonski i regulatorni okviri).

Interoperabilnost omogućuje bržu i lakšu razmjenu informacija, smanjuje dupliranje podataka, ubrzava donošenje odluka, garantira sigurnost i privatnost, povećava transparentnost, a sve s konačnom svrhom – učinkovitija i kvalitetnija javna usluga.

2. Servisi zemljišnih podataka

U sklopu kontinuiranih napora za poboljšanje upravljanja državnim prostorom i imovinom, Vlada Republike Hrvatske donijela je niz važnih odluka koje

definiraju katastar nekretnina i zemljišnu knjigu kao temeljne registre za prostor Republike Hrvatske.

Na temelju zaključka Vlade Republike Hrvatske iz 2013. godine, katastar nekretnina i zemljišna knjiga definirani su kao dio temeljnog registra za prostor Republike Hrvatske (URL 1). Ovaj zaključak osigurao je daljnji korak usmjeren u razvoju sustava i prikupljanju podataka o nekretninama na državnom teritoriju. Kao dio temeljnih registra, katastar nekretnina i zemljišne knjige prate odredbe Zakona o državnoj informacijskoj infrastrukturi (Narodne novine 2014), koji navodi da je svrha temeljnih registara osigurati dostupnost prikupljenih autentičnih podataka svim tijelima javnog sektora koji su im potrebni za obavljanje poslova iz svog djelokruga.

Najnovija odluka Vlade, donesena 22. veljače 2024. godine, potvrdila je zaključak iz 2013. godine da su katastarski operat i zemljišne knjige, kao javni registri, dio temeljnih registra Republike Hrvatske (Narodne novine 2024).

Podaci temeljnih registara čuvaju se i održavaju u ZIS-u, koji se sastoji od privatnog dijela, namijenjenog djelatnicima zemljišnoknjižnih odjela i katastarskih ureda te javnog dijela, dostupnog svim zainteresiranim strankama putem interneta kroz platformu One Stop Shop (OSS).

Prateći Zakon o državnoj informacijskoj infrastrukturi od 2016. do kraja 2021. godine, na OSS-u je razvijeno ukupno 38 servisa. Većina ovih servisa razvijena je za potrebe integracija s različitim sustavima državne uprave i poslovnih subjekata, a s namjerom poticanja digitalnog postupanja i olakšavanja pristupa informacijama.

Tijekom tog razdoblja razvijeni su: Servisi za autentifikaciju i autorizaciju, Servisi za dohvat šifrarnika, Servisi za pretraživanje podataka (katastarske čestice, ZK ulošci), Servisi za dohvat podataka službenih evidencija (neslužbeni i službeni izvaci iz zemljišne knjige, prijepisi posjedovnih listova, WMS i WFS servisi digitalnog katastarskog plana – DKP itd.) i Servisi za podnošenje zahtjeva i prijedloga (prijedlozi za upis u zemljišnu knjigu, zahtjev za pregled i potvrđivanje te dopunu digitalnog geodetskog elaborata, rezervaciju brojeva katastarskih čestica i sl.).

U razdoblju od 2017. do 2021. godine, statistika korištenja razvijenih servisa pokazala je značajan trend rasta u broju poziva. U 2017. godini zabilježeno je 500 tisuća poziva, a u 2021. godini broj poziva porastao je na 45 milijuna. Očekivano, s većim stupnjem prihvaćanja novih tehnologija i širenjem digitalne povezanosti, broj poziva nastavlja rasti.

Najviše korišteni servisi, prema broju poziva, su WFS i WMS servisi za dohvaćanje prostornih podataka ZIS-a (DKP). Veliki broj poziva je očekivan za ove servise jer su neophodni za integraciju digitalnog katastarskog plana u interne poslovne procese drugih sustava. Kroz tu integraciju, postiže se optimizacija poslovnih procesa te olakšava pristup bitnim prostornim informacijama.

Do 2021. godine, zabilježen je i značajan porast u korištenju servisa za dohvat zemljišnoknjižnih podataka, izlaznih pismena, provjeru statusa predmeta te podnošenje prijedloga za upis u Zemljišne knjige. Ovaj porast se može pripisati promjenama propisa tijekom 2019. godine, koji su uspostavili pravni temelj za elektroničko poslovanje u području zemljišnih knjiga. Javnim bilježnicima kao ovlaštenim korisnicima omogućeno je servisno podnošenje prijedloga za upis u zemljišne knjige te izdavanje isprava elektroničkim putem.

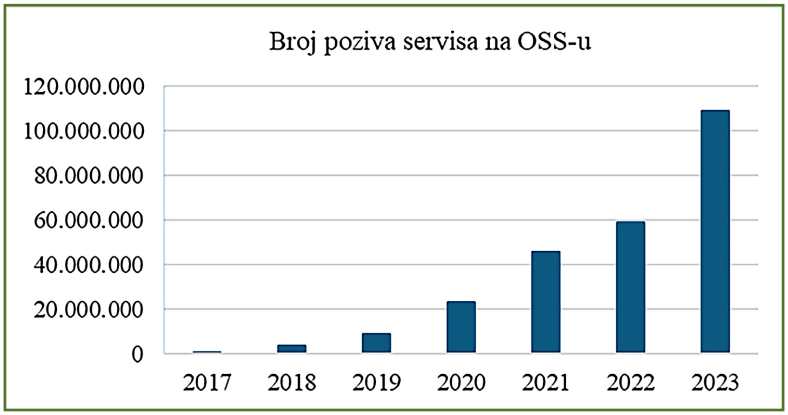
2.1. Potreba za novim servisima

Servisi razvijeni do 2021. godine imali su različite prioritete i koristili su različite tehnološke implementacije. Iako su drugi sustavi mogli pristupiti velikoj količini zemljišnih podataka putem tih servisa, još uvijek nisu bile u potpunosti zadovoljene sve potrebe za podacima koji se vode i održavaju u ZIS-u.

Iz tog razloga su tijekom 2021. i 2022. godine implementirana 43 nova servisa u svrhu osiguranja učinkovite razmjene zemljišnih podataka između javnopravnih tijela. Za učinkovito upravljanje zemljišnim podacima razvijen je skup servisa s ciljem potpune pokrivenosti potreba za zemljišnim podacima. Svi servisi su izrađeni u skladu s pravilima servisno-orijentirane arhitekture (engl. SOA) i implementirani u sustav za razmjenu podataka.

U nastavku se nalazi popis kategorija razvijenih servisa prema funkcionalnostima koje pružaju:

- Servisi za dohvat pomoćnih podataka (K i Z identifikacije, šifrarnici zemljišnih podataka).
- Servisi za dohvat podataka službenih evidencija (informacije o katastarskim općinama, glavnim knjigama i knjigama položenih ugovora, podaci zemljišnoknjižnog uloška, poduloška knjige položenih ugovora, katastarske čestice, posjedovnog lista, zbirke rješenja, zbirke isprava, zbirke elaborata, pisanog i grafičkog dijela katastarskog operata).
- Servisi za dohvat promjena službenih evidencija (promjene zemljišnoknjižnog uloška i KPU poduloška, informacije o podbrojevima katastarskih čestica).
- Servisi za pretragu podataka službenih evidencija (KPU, zbirka rješenja, zbirka isprava, zbirka elaborata).
- Servisi za dohvat poslovnih podataka (informacije o statusu i sadržaju zemljišnoknjižnog i katastarskog predmeta).
- Servisi pogodni za filtriranje podataka službenih evidencija (filtriranje po digitalnom katastarskom planu (WFS) – dohvat popisa katastarskih čestica, zgrada i drugih građevina, osoba upisanih u katastarskom operatu, područja posebnih pravnih režima, točaka u službenoj evidenciji, dohvat upisanih osoba u zemljišnim knjigama).
- Servisi za dohvat promjena podataka službenih evidencija (servisi za notifikacije – promjene na zemljišnoknjižnim ulošcima, katastarskim česticama, zemljišnoknjižnim predmetima, katastarskim predmetima, katastarskim upravnim predmetima).



Slika 1: Broj poziva servisa na OSS tijekom godina

- INSPIRE servisi (WMS/WFS servis za sloj zgrada i načine uporabe uz postojeći servis za katastarske čestice i općine).

Na javnom dijelu OSS-a dostupan je katalog usluga koji uključuje popis svih dostupnih servisa s detaljnim informacijama o svakom pojedinom servisu. Katalog usluga dostupan je na stranici OSS (URL 2). Uspostavom kataloga usluga osigurana je transparentnost svih usluga i servisa od strane naručitelja sustava te korisnici mogu bolje razumjeti što se nudi i kako mogu iskoristiti dostupne usluge ili servise.

2.2. Uporaba servisa

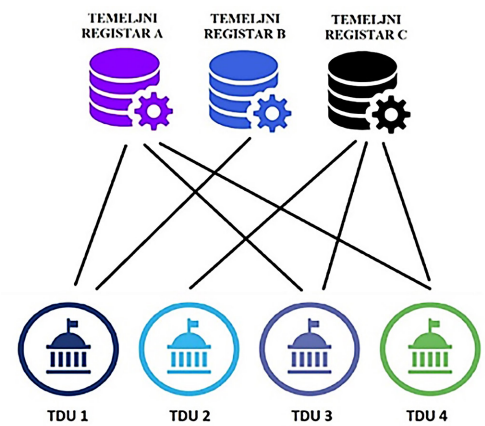
Krajem 2022. godine u produkcijski rad puštena su 43 nova servisa, čime je ukupan broj servisa porastao na 81. Ovi servisi su u potpunosti pokrili potrebu za zemljišnim podacima, što je rezultiralo povećanim interesom različitih grupa korisnika.

Statistika broja poziva servisa (Slika 1) pokazuje značajan rast kroz posljednje tri godine. U 2021. godini zabilježeno je 45 milijuna poziva, dok je u 2022. godini taj broj porastao na 59 milijuna. Krajem 2022. godine razvijeni su novi servisi, što je doprinijelo značajnom skoku broja poziva u 2023. godini, kada je taj broj dosegnuo 109 milijuna. U prvoj polovici 2024. godine broj poziva već je dosegnuo 81 milijun, što ukazuje na nastavak rasta i sve veći interes korisnika za servisima. Ovi podaci potvrđuju prepoznatu potrebu i uspješnost u implementaciji novih servisa.

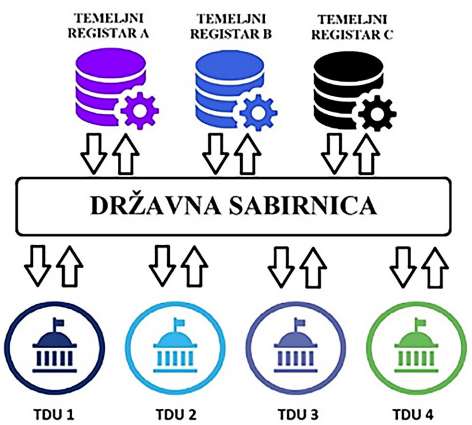
2.3. Interoperabilnost kroz Državnu sabirnicu (GSB)

Tijela javne uprave već dugi niz godina međusobno razmjenjuju podatke. Međutim, većina današnjih informatičkih veza uspostavljena je na bilateralnoj osnovi, između samo dva tijela koja dijele informacije (Slika 2). Ova praksa rezultirala je stotinama pojedinačnih veza koje su tijekom vremena tijela državne uprave izgradila kako bi ostvarila međusobnu razmjenu podataka (URL 3).

Prema Zakonu o državnoj informacijskoj infrastrukturi (Narodne novine 2014), tijela javne uprave obvezna su pribavljati podatke iz javnih registara po službenoj dužnosti. Kako bi se poboljšala učinkovitost i sigurnost razmjene podataka, uveden je novi pristup. Umjesto da svako tijelo zasebno traži podatke od drugih tijela, podaci se centralizirano pribavljaju putem državne informacijske infrastrukture. Ovaj novi pristup omogućuje sigurnu razmjenu podataka putem sustava državne sabirnice (Government Service Bus – GSB), štedeći vrijeme i resurse tijelima javne uprave.



Slika 2: Bilateralna razmjena podataka između temeljnih registra i tijela državne uprave (TDU)



Slika 3: Razmjena podataka između temeljnih registra i tijela državne uprave (TDU) preko GSB-a

Uspostavom GSB-a kao centralnog mjesta za sigurnu razmjenu podataka, kreirana je jedinstvena tehnička platforma koja omogućava tijelima da se jednom konekcijom spoje na GSB. Kroz tu jedinstvenu konekciju, tijela mogu dohvaćati podatke iz različitih autentičnih izvora (javnih registara) u skladu s poslovnim procesima koje moraju provoditi i skupom podataka potrebnim za dovršetak tih procesa (Slika 3).

Interoperabilnost, kao sposobnost dva ili više sustava da djeluju jedinstveno, postiže se međusobnom razmjenom podataka. Ova karakteristika je ključna za digitalnu transformaciju. Korištenjem GSB-a kao platforme za razmjenu podataka, omogućava se značajna ušteda na tehničkom održavanju konekcija i izradi komunikacijskih alata. Istovremeno, tijela koja koriste podatke ne moraju poznavati koji je autentični izvor podataka, što dodatno pojednostavljuje i ubrzava njihove poslovne procese (URL 4).

Proces integracije na GSB provodi se putem dva različita procesa (URL 4): Objava/Izlaganje registra na GSB-u i Pristup/Razmjena podataka putem GSB-a.

Tijelo državne uprave koje želi pristupiti postojećem servisu na GSB-u popunjava zahtjev s informacijama o servisu kojem želi pristupiti. Nakon odobrenja vlasnika servisa omogućava se pristup tehničkoj dokumentaciji, testnoj i produkcijskoj okolini GSB-a. Ovakav postupak osigurava sigurnu razmjenu podataka iz javnih registara putem GSB, uz aktivnu ulogu relevantnih institucija.

Od ukupno 81 servisa dostupnih unutar sustava ZIS/OSS, trenutno je na GSB-u objavljeno 58 servisa. Ove servise kroz GSB koriste jedinice lokalne samouprave (gradovi i općine), jedinice područne (regionalne) samouprave (županije), državne agencije, ministarstva i druga državna tijela. U 2023. godini, korisnici su putem GSB-a uputili oko 11 milijuna poziva prema ZIS/OSS servisima.

Najčešća potreba za pristup ZIS/OSS servisima je u svrhu integracije podataka u geografski informacijski sustav (GIS), brži i efikasniji pristup ključnim podacima, vođenje evidencije imovine, potvrđivanje vjerodostojnosti podataka o vlasništvu i slično.

3. Interoperabilnost ZIS-a

ZIS nije samo baza podataka u kojoj su pohranjeni podaci temeljnih javnih registara zemljišne knjige i katastarskog operata, već je to sustav čija je namjena podržati katastarske i zemljišnoknjižne poslovne procese koji se provode u svrhu održavanja zemljišnih podataka. Svakodnevno preko 2000 djelatnika katastarskih ureda i zemljišnoknjižnih odjela u sklopu redovitih postupaka održavaju i ažuriraju zemljišne podatke. Takvi postupci, između ostalog, uključuju repetitivne radnje koje su idealne za promjenu u procesu digitalne transformacije. U tu svrhu, ZIS je unatrag osam godina postepeno uvodio integraciju s drugim sustavima javne uprave i stručnih tijela s ciljem automatizacije postupaka, smanjenja troškova i povećanja učinkovitosti.

U vrijeme kada je ZIS pušten u produkcijski rad, postojao je vrlo ograničen broj vanjskih sustava s kojima se ZIS mogao integrirati, a koji bi doprinijeli unaprjeđenju rada u ZIS-u. Tako su se zahtjevi i prijedlozi zaprimali u papirnatom obliku, a potom su se podaci iz prijedloga ručno prepisivali u ZIS. Analogni geodetski elaborati su zaprimani u fizičkom obliku. Pismena su se ispisivala na papir, a potom su se u uredima ubacivala u omotnice na koje su se na razne načine (nerijetko ručno) ispisivali podaci o primatelju. Ovjerene isprave izdavale su se isključivo u fizičkom obliku, a naplata i evidencija naplaćenih pristojbi vodila se lijepljenjem biljega i spremanjem fizičkih uplatnica.

Danas je ZIS putem servisa spojen s 20-ak sustava čije se usluge svakodnevno koriste u poslovanju ZIS-a, odnosno u katastarskim uredima i zemljišnoknjižnim odjelima. Sustavi s uslugama koje pružaju znatno su podigli učinkovitost te u većem broju slučajeva skratili vrijeme trajanja postupka.

Većina postupaka u ZIS-u započinje elektroničkom predajom zahtjeva. Geodetski elaborat se na pregled, potvrđivanje i provedbu servisno u ZIS predaje iz Sustava digitalnog geodetskog elaborata (SDGE), a prijedlozi za upis u zemljišne knjige iz sustava za javne bilježnike (eNotar).

Aktivnosti dostave pismena u ZIS-u izmijenjene su u procesu digitalne transformacije s ciljem da se dostava maksimalno automatizira i digitalizira te da se smanje troškovi dostave. Korištenjem usluga informatičkog sustava Hrvatske pošte (ePošta) omogućeno je da se sadržaj pošiljke (pismena i ostali dokumenti) u elektroničkom obliku pošalje iz ZIS-a u sustav ePošta. Tamo se pošiljka ispisuje, sprema u omotnicu i adresira te se ista dostavlja primatelju. Digitalna povratnica se nakon uručenja primatelju dostavlja u ZIS kao dokaz da je preporučena dostava izvršena. Ovime su djelatnici katastarskih ureda i sudova rasterećeni poslova otpremanja pismena i evidencije dostavnica te svoje vrijeme mogu posvetiti svojim stručnim poslovima.

Troškovi dostave dodatno su smanjeni integracijom s informatičkim sustavom Porezne uprave (uskoro i s informatičkim sustavom Državnog odvjetništva Republike Hrvatske – DORH) tako da se rješenja iz ZIS-a u elektroničkom obliku šalju direktno u drugi sustav bez posredovanja poštanske ili dostavne službe. Rješenja će se, poštujući zakonski okvir, dostavljati fizičkim i pravnim osobama u elektroničkom obliku. Da bi se tako nešto postiglo, bilo je potrebno integrirati se s Nacionalnim identifikacijskim i autentifikacijskim sustavom (NIAS) i uslugama e-Ovlaštenja te Korisničkim pretincem (KP) portala e-Građani.

Kada se katastarski ili zemljišnoknjižni postupak prebaci na odlučivanje na viši stupanj, radi transparentnosti, tj. boljeg uvida u statuse rješavanja predmeta, ZIS je integriran sa sustavom za rješavanje drugostupanjskih upravnih katastarskih predmeta (e-Case) i sustavom za rad na sudskim predmetima (eSpis).

Nakon što se geodetski elaborat provede u ZIS-u, automatski se sprema u Sustav digitalnog arhiva (SDA) Državne geodetske uprave. Arhivski podaci kasnije su dostupni na korištenje prilikom rješavanja raznih

predmeta. Izdavanje digitalno ovjerenih izvadaka skeniranih ručno vođenih knjiga putem ZIS-a, dostupno je nakon integracije sa sustavom Digitalne arhive zemljišnih knjiga (DAZK).

Integracija sa sustavom za upravljanje Registrom prostornih jedinica (RPJ) kao temeljnim registrom omogućila je dohvat strukturiranih podataka o nazivima gradova, naselja, ulica i trgova te kućnih brojeva.

U određenim postupcima u katastru, stranka je dužna podmiriti troškove postupka te jednako tako u zemljišnoknjižnim postupcima stranka plaća sudsku pristojbu. S obzirom na to da se zahtjevi u katastru mogu, a zemljišnoknjižni prijedlozi moraju predati elektronički (putem servisa ili OSS-a), logično je da se plaćanje pristojbi također vrši elektronički. Zato je ZIS integriran sa sustavom e-Pristojbe, putem kojeg se pristojbe plaćaju kartično ili putem uplatnice.

Tendencija je da se podaci o osobi (ime, prezime, naziv i adresa) ne upisuje ručno u formu elektroničkog zahtjeva, već da se podaci o osobi dohvate iz sustava za održavanje evidencije OIB. Osim dohvata podataka, integracija s OIB čvorom iskorištena je za automatizirano ažuriranje upisanih osoba u katastarski operat i zemljišnu knjigu kada dođe do promjene osobnih podataka, smanjujući time priljev zahtjeva za promjenom upisanih osobnih podataka od strane stranaka.

4. Zaključak

Razvoj modernih tehnologija, njihova rasprostranjenost i mogućnost primjene utječu na tradicionalni način funkcioniranja društva do te mjere da ga iz temelja mijenjaju. Kroz digitalnu transformaciju ne uvodi se samo tehnologija u postojeći način rada javne uprave, nego se zahtijeva prilagodba ili potpuna promjena funkcioniranja javne uprave. U pravilu, ove promjene stvaraju potrebu za prilagodbom zakonske regulative, a često su promjene takve da se cijela zakonska regulativa mora temeljiti na doprinosu koji digitalna transformacija donosi.

U prvoj fazi digitalizacije stvarali su se samostalni informacijski sustavi. Sada se ti sustavi međusobno povezuju prema načelima interoperabilnosti na razini državne infrastrukture ili pojedinačnih sustava. Tako interoperabilnost zaokružuje cjelinu koju digitalna transformacija donosi.

Zemljišni podaci uvijek su bili predmet interesa u različitim aspektima društva. Kroz uspostavu ZIS-a i temeljnog registra katastarskih i zemljišnoknjižnih podataka stvorili su se preduvjeti za dostupnost podataka zainteresiranim dionicima. Zemljišni podaci dostupni preko državne sabirnice odmah su postali predmet interesa različitih javnopravnih tijela, a ZIS je prepoznat kao jedan od ključnih registara na državnoj sabirnici (URL 4).

ZIS kao jedan od najznačajnijih nacionalnih sustava, integriran je s preko 20 različitih sustava i čini jednog od predvodnika interoperabilnosti u Republici Hrvatskoj. Poslovni procesi u zemljišnoj administraciji do te mjere su digitalizirani da je prijašnji, tradicionalni način postupanja postao iznimka u sustavu.

Na ovaj način zemljišni podaci i digitalizirani postupci u zemljišnoj administraciji čine predvodnika digitalne transformacije javne uprave u Republici Hrvatskoj, a sve u svrhu učinkovitije i kvalitetnije javne usluge.

Literatura

Narodne novine (2014): Zakon o državnoj informacijskoj infrastrukturi, Narodne novine, br. 92/2014, Zagreb.

Narodne novine (2024): Odluka o određivanju temeljnih registara, Narodne novine, br. 21/2024, Zagreb.

URL 1: Središnji državni ured za razvoj digitalnog društva, https://rdd.gov.hr/UserDocsImages//MURH_migracija%20s%20weba/Arhiva%20projekata//Zaklju%C4%8Dak%20VRH%20o%20temeljnim%20registrima-28022013.pdf, (10.6.2024.).

URL 2: OSS (One-Stop-Shop) – Katalog usluga, https://oss.uredjenazemlja.hr/ckan, (10.6.2024.).

URL 3: Središnji državni ured za razvoj digitalnog društva, https://rdd.gov.hr/istaknute-teme/interoperabilnost-sustava-javne-uprave-drzavna-sabirnica-gsb/1873, (10.6.2024.).

URL 4: Dokumentacija Centra dijeljenih usluga (CDU), https://wiki.cdu.gov.hr/hr/usluge/interoperability/gsb, (10.6.2024.).

Interoperability of Land Data as a Factor in the Digital Transformation Process of Public Administration

Abstract

The digital transformation of public administration is a strategic commitment of the Republic of Croatia. By creating public registers in digital form, prerequisites are established for the connection and mutual exchange of data to increase the efficiency and quality of public services. The mutual exchange of data makes interoperability a key factor for achieving digital transformation. The fundamental register of cadastral and land registry data is stored and maintained through the Joint Information System for Land Registry and Cadastre (ZIS). Through the state information infrastructure, cadastral and land registry data are available to all public administration bodies for the purpose of performing their duties. The ZIS service catalog contains over 120 different services related to land data intended for various groups of users. At this moment, 56 services are published through the Government Service Bus (GSB). In this way, public authorities and units of local and regional self-government can directly receive cadastral and land registry data into their systems (e.g., data on cadastral parcels and registered persons, land registry extracts, etc.). ZIS, as one of the most significant national systems, is integrated with over 20 different systems. These include state information infrastructure systems, business systems of other public administration bodies, and systems of various professional bodies, all with the aim of efficiently conducting procedures and managing cadastral and land registry data.

Keywords: *digital transformation, fundamental registries, GSB – Government Service Bus, interoperability, ZIS*

Izvlaštenje i procjena nekretnina radi izgradnje energetske infrastrukture

Franjo Ambroš[1], Vedran Stojnović[1], Vladimir Slivac[1], Dario Tot[2], Zoran Kovač[3], Damir Jelošek[4] Tihomir Zec[5]

[1] GEOprem d.o.o, Osijek, Hrvatska, franjo.ambros@geoprem.hr

[2] GEOPREM projekt d.o.o., Osijek, Hrvatska, dario.tot@gprojekt.hr

[3] Hrvatski operator prijenosnog sustava d.d.,. Zagreb, Hrvatska, zoran.kovac@hops.hr

[4] Corteva Agriscience d.o.o.,. Zagreb, Hrvatska, damirj2811@gmail.com

[5] Odvjetničko društvo Zec i partneri d.o.o., Osijek, Hrvatska, tihomir@odvjetnikzec.hr

Sažetak

Rješavanje imovinsko pravnih odnosa investitora u infrastrukturu i vlasnika nekretnina na kojima se ta infrastruktura gradi zahtjevan je tehnički, upravni i pravni postupak. Uređenje vlasničkih odnosa pri izgradnji infrastrukture od interesa za Republiku Hrvatsku (RH) provodi se sukladno Zakonu o izvlaštenju i određivanju naknade. Energetska infrastruktura za svoju izgradnju koristi nekretnine pravnih i fizičkih osoba u raznim pravnim režimima i planiranoj namjeni prostora. Izgradnjom predmetne infrastrukture vlasnik se nepotpuno izvlašćuje, upisom služnosti u zemljišnoj knjizi kao stvarnog tereta. Infrastruktura se gradi na katastarskim česticama pa postupak počinje prikazom trase infrastrukture na katastarskom planu. Okrnjenost pojedine nekretnine je specifična za svaku katastarsku česticu. Izgradnjom infrastrukture se katastarska čestica u manjoj ili većoj mjeri degradira za temeljnu namjenu definiranu prostornim planom pa vlasniku pripada naknada kao obeštećenje. Postupak obuhvaća izradu elaborata izvlaštenja, procjenu nekretnina, osiguravanje budžeta za naknadu, pokušaj nagodbe s pojedinim vlasnikom. U slučaju da sporazum nije postignut provodi se procjena nekretnine po drugom procjenitelju na temelju koje nadležno tijelo županije ili Grada Zagreba donosi rješenje o izvlaštenju i završava uknjižbom služnosti u zemljišnoj knjizi. Vlasnik nezadovoljan naknadom upućuje se na sud radi odmjeravanje pravične naknade za korištenje njegove nekretnine. U radu je opisan slučaj s opisom uloge sudionika raznih struka. Ukazuje se na složenost i dugotrajnost postupka pri provođenju postupka i sugerira kako postupak ubrzati. Ujedno se ukazuje na mogućnost kontrole svake faze postupka i uvid u stanje predmeta preko web aplikacije temeljene na GIS-u.

Ključne riječi: *elaborat izvlaštenja, multidisciplinarni postupak, procjembeni elaborat, upis služnosti*

1. Uvod

O terminu infrastruktura više u radu Ambroš i dr. (2016), U periodu 1973-2018. godine uobičajeni termin u geodetskoj struci za ovaj tip infrastrukturu je bio vodovi. Područje je bilo regulirano s više verzija zakona o katastru vodova, a postupanje pravilnicima. Ovo treba naglasiti, jer je infrastruktura o kojoj je riječ građena u periodima primjene oba termina. U Hrvatskoj je javna energetska infrastruktura podijeljena u više energetskih razina, u pretežnom vlasništvu državnih tvrtki. Najviša elektroenergetska razina u isključivoj je nadležnosti Hrvatskog operatora prijenosnog sustava d.d. (dalje HOPS) čiji je osnivač Republika Hrvatska.

Izgradnji elektroenergetske infrastrukture prethodi zahtjevan prostorno planerski, projektantski, inženjerski i imovinsko pravni postupak. Rad je fokusiran na postupak provođenja izvlaštenja za potrebe dobivanja građevinske dozvole kao zadnje faze koja prethodi izgradnji. Postupkom izvlaštenja investitor stječe stvarno pravo služnosti na nekretnini na kojoj gradi infrastrukturu, a vlasnik nekretnine pravičnu naknadu kao obeštećenje za okrnjenost njegove nekretnine. Izvlaštenje se provodi sukladno Zakonu o izvlaštenju i određivanju naknade NN (2014). Postupku prethodi nekoliko kumulativnih uvjeta: a/ utvrđen viši interes (zakon ili odluka Vlade RH); b/ infrastruktura mora biti u prostornom planu (pravomoćna lokacijska dozvola); c/dokaz da je investitor s vlasnikom pokušao nagodbu d/ elaborat izvlaštenja s podacima o nekretnini, vlasnicima, posjednicima o površini koja je predmet izvlaštenja; e/ izrađen procjembeni elaborat po ovlaštenom procjenitelju (ne stariji od dvije godine); f/ dokaz da je investitor osigurao sredstva za postupak (naknada za izvlaštenje u novcu ili zamjenskoj nekretnini te novac za trošak postupka).

Iz duha zakona proizlazi da nagodba s vlasnikom nekretnine ima prioritet. Ta nagodba ima formu ugovora pogodnog za zemljišnoknjižni upis služnosti (u ovom slučaju vlasnik ostaje u vlasništvu nekretnine).

Iznos naknade investitor može procijeniti samostalno ili naručiti izradu procjembenog elaborata na kojem će temeljiti financijsku konstrukciju investicije.

Ovlaštenje za sklapanje ugovora ima investitor za sebe ili sklapanje ugovora mora povjeriti odvjetničkoj tvrtki, koja će s vlasnikom provoditi pregovore i na kraju sklopa ugovor. Po prirodi stvari služnost opterećuje cijelu nekretninu pa je uputno ugovoru priložiti kopiju katastarskog plana s ucrtanom trasom infrastrukture.

Ako investitor i vlasnik ne sklope ugovor o služnosti pokreće se postupak izvlaštenja. Postupak provodi upravno tijelo županije ili grada Zagreba po principu mjesne nadležnosti. Iznimka je ako je opći interes proglasila Vlada RH, u tom slučaju nadležno tijelo je Ministarstvo pravosuđa. Odluka nadležnog tijela osnova je za uknjižbu služnosti.

Postupak izvlaštenja iznijet u Zakonu o izvlaštenju i određivanju naknade, u slučaju da se investitor i vlasnik nisu nagodili pun je potencijalnih zamki, sumnja u naknadu, sumnja u objektivnost procjenitelja koji se negativno odražavaju na vrijeme potrebno za rješavanje imovinsko pravnih odnosa.

Zakon o uređivanju imovinskopravnih odnosa u svrhu izgradnje infrastrukturnih građevina NN (2011) predviđa osnivanje stvarnih prava za tvrtke u pretežnom državnom vlasništvu ili vlasništvu jedinica lokalne samouprave (JLS) i regionalne samouprave (RS) na nekretninama u vlasništvu RH, regionalne i lokalne samouprave bez naknade. U praksi postoje osporavanja odredbi tog zakona.

Pretežni dio trase elektroenergetskog voda će se graditi na poljoprivrednom zemljištu, pa se nametnulo rješenje da se procijeni i proizvodni potencijal nekretnina, za koje nije sklopljena nagodba, kako vlasnik nekretnine ne bi bio zakinut. Ovaj zadatak je povjeren stalnom sudskom vještaku poljoprivredne struke. Pokazivanje granica katastarskih čestica na terenu obavio je stalni sudski vještak geodetske struke.

Rad je baziran na primjeru elektroenergetskog voda trase 30 km, koji prolazi kroz deset katastarskih općina, odnosno 671 katastarskih čestica, koje se vode kao građevinsko, poljoprivredno, prometno i drugo zemljište. Katastarske čestice su u raznim pravnim režimima.

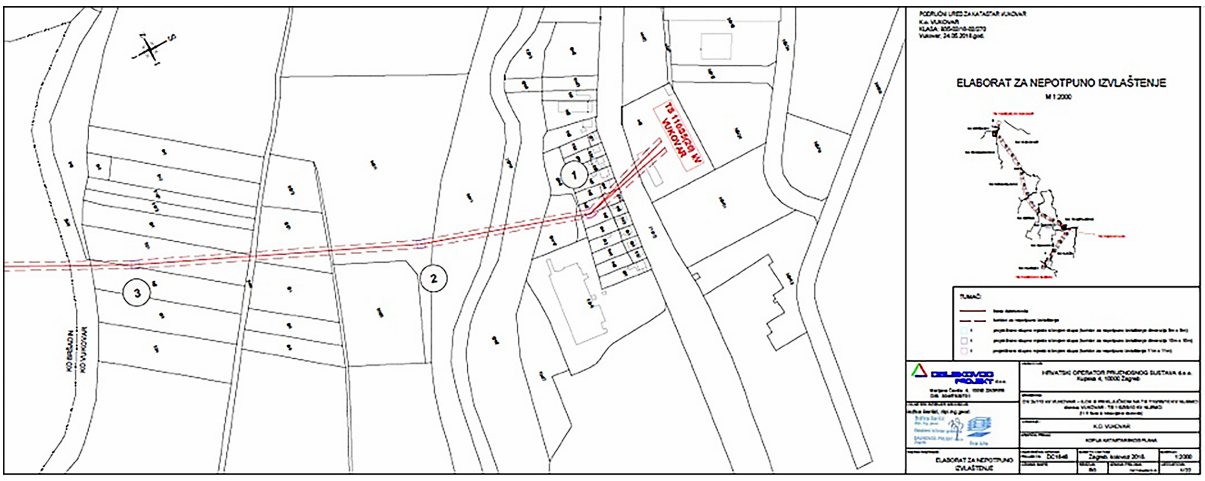
Praćenje procesa preko GIS web aplikacije nametnulo se kao logično rješenje, preko kojeg ovlaštene osobe investitora, procjenitelja, odvjetničkog ureda imaju 24/7/365 uvid.

2. Elaborat izvlaštenja

Izvlaštenje je postupak kojim se investitoru omogućava da uz volju vlasnika ili bez volje vlasnika može izgraditi svoju infrastrukturu. Rezultat postupka je uknjižba služnosti, kao stvarnog tereta na katastarskoj česti. Ova činjenica investitoru daje određena prava a vlasniku nalaže trpljenje uknjižene služnosti kao tereta na svojoj nekretnini.

Izvlaštenje se provodi radi ograničenja prava vlasništva. Naknada po toj osnovi ne podrazumijeva naknadu za eventualnu štetu koju investitor može prouzročiti bilo redovnim održavanjem ili hitnom intervencijom. Ovu štetu procjenjuje stalni sudski vještak odgovarajuće struke i ona se nadoknađuje pri svakoj šteti. Zbog toga nije uputno ustanovljavati služnost kolnog prolaza, jer će tako kretanje po parceli biti strogo definirano. Pri održavanju ili hitnoj intervenciji za očekivati je da će se uništenje usjeva ili degradacija površine izbjegavati, jer bi na taj način troškovi održavanja bili veći.

Osnova za pokretanje izvlaštenja za potrebe izgradnje infrastrukture je elaborat izvlaštenja. Elaborat izvlaštenja je geodetski elaborat, koji se izrađuje pod nadzorom ovlaštenog inženjera geodezije i sadrži grafički dio (kopija katastarskog plana s trasom infrastrukture) i tabelarni prikaz o nekretnini (katastarska općina, broj katastarske čestice, način uporabe) te podatke o knjižnom stanju (vlasnik/posjednik, OIB, adresa, tereti), te površini planiranoj za izgradnju infrastrukture (površina stupa i/ili površina koridora)



Slika 1: Grafički dio elaborata izvlaštenja (Dalekovod projekt d.o.o.)

K.O. VUKOVAR, PUK VUKOVAR										K.O. VUKOVAR, Općinski sud u Vukovaru, ZK ODJEL VUKOVAR					
Redni broj		Broj katastarske čestice	Kultura	Površina parcele		Naziv parcele	Broj posjed. lista	POSJEDNIK Prezime, ime i ime oca posjednika, mjesto stanovanja i kućni broj		Broj Z.K. uloška	VLASNIK Prezime, ime i ime oca vlasnika mjesto stanovanja i kućni broj		Površina za nepotpuno izvlaštenje		
				Ha	m^2								br.stupa	m^2	zrak /m^2
1		2	3	4		5	6	7		8	9		10		
1		400	2 ZGRADE EK.DVOR		619 9061	PRILJEVO	9758	1/1	HRVATSKI OPERATOR PRIJENOSNOG SUSTAVA D.O.O., KUPSKA 8, ZAGREB (VLASNIK), OIB:13148821633	2493	2. Vlasnički dio: 1/1	HRVATSKI OPERATOR PRIJENOSNOG SUSTAVA D.O.O., OIB: 13148821633, ZAGREB, KUPSKA 4			757
2		7131/2	PUT	9	8050	OSIJEK - VINKOVCI	9473	1/1	REPUBLIKA HRVATSKA-JAVNO DOBRO U OPĆOJ UPORABI, , . (VLASNIK) HRVATSKE CESTE D.O.O., ZAGREB, VONČININA 3 (UPRAVITELJ), OIB:55545787885	10578	1. Vlasnički dio: 1/1	REPUBLIKA HRVATSKA - JAVNO DOBRO U OPĆOJ UPORABI POD UPRAVOM HRVATSKIH CESTA D.O.O., ZAGREB			448
3		649	KUĆA, PRILJEVO 229 DVORIŠTE		72 244	PRILJEVO	769	1/1	PIŠTELEK ZORAN, ŽRTAVA FAŠIZMA 9/B, UMAG (VLASNIK), OIB:79912530120	288	1. Vlasnički dio: 1/1	PIŠTELEK (5TIPIN) ZORAN, UMAG, ŽRTAVA FAŠIZMA 9 B			108
4		647	KĆ. I DV		318	UL.8.XII 1944	4021	1/1	PLEČKOVIĆ DALIBOR, HRVATSKOG ZRAKOPLOVSTVA 11, 32000 VUKOVAR, HRVATSKA (VLASNIK), OIB:65466738662	1362/A	1. Suvlasnički dio: 1/2 2. Suvlasnički dio: 1/2	PLEČKOVIĆ DALIBOR, OIB: 65466738662, HRVATSKOG ZRAKOPLOVSTVA 11, 32000 VUKOVAR PLEČKOVIĆ (MARKOV) DALIBOR, VUKOVAR, 08. XII 1944			182
5		648	ORANICA KĆ. I DV		275 223	UL.8.XII 1944	4021	1/1	PLEČKOVIĆ DALIBOR, HRVATSKOG ZRAKOPLOVSTVA 11, 32000 VUKOVAR, HRVATSKA (VLASNIK), OIB:65466738662	1362/A	1. Suvlasnički dio: 1/2 2. Suvlasnički dio: 1/2	PLEČKOVIĆ DALIBOR, OIB: 65466738662, HRVATSKOG ZRAKOPLOVSTVA 11, 32000 VUKOVAR PLEČKOVIĆ (MARKOV) DALIBOR, VUKOVAR, 08. XII 1944	1	64	234

Slika 2: Tabelarni dio elaborata izvlaštenja (Dalekovod projekt d.o.o.)

2.1. Pregled trase infrastrukture na katastarskom planu

Prikaz trase dalekovoda s pozicijom stupova dio je projektne dokumentacije. On se preuzima kao grafički dio elaborata izvlaštenja (Slika 1). Uobičajeni standard za izradu digitalne verzije grafičkog dijela elaborata je softver AutoCAD. Kako se radi o infrastrukturi koja na nekretnini zauzima koridor koji čine projekcije krajnjih vodiča na katastarsku česticu i površina stupova nosača vodiča neophodno je sve to prikazati na katastarskom planu radi određivanja površine na kojoj se ustanovljava služnost. Površina zemljišta na kojoj su temelji stupova bit će trajno zauzeta. Korištenje nekretnine vlasniku je trajno onemogućeno. Površina ispod zračnih vodiča reducirano će se moći koristiti. Ove dvije činjenice utječu na korekcije okrnjenosti površine koje su nužne radi određivanja naknade. Ako granice katastarskih čestica nisu pouzdane (međe sporne) to neće utjecati na naknadu već na jedan vlasnik dobiti veću a drugi manju naknadu. To ujedno znači da uzurpator neće dobiti naknadu, jer ona pripada knjižnom vlasniku. Postupak uređenja međa može se provoditi i tijekom postupka izvlaštenja. Ugovori o izvlaštenju sklopit će se kada vlasnici urede među.

2.2. Podaci o izvlaštenju (Excel tabela)

Tabelarni pregled katastarskih čestica sa svim podacima iz knjižnih evidencija te izračunom površina stupova i koridora na parceli izrađuje se po katastarskim općinama. Ovaj prikaz se obično radi u Excel tablici radi preglednosti (Slika 2). Pogodnost Excel tablice je mogućnost grafičkog oblikovanja i programiranje ulaza podataka u GIS. Grafički oblikovana tablica često gubi strukturu podataka primjerenu bazi podataka pa takova tablica traži prilagodbu za GIS bazu.

Kako se ne bi narušio vizualni izgled tablice nju je moguće zadržati u izvornom obliku tako da se uspostavi u GIS bazi veza prema tablici (link).

3. Procjena nekretnina za potrebe nagodbe

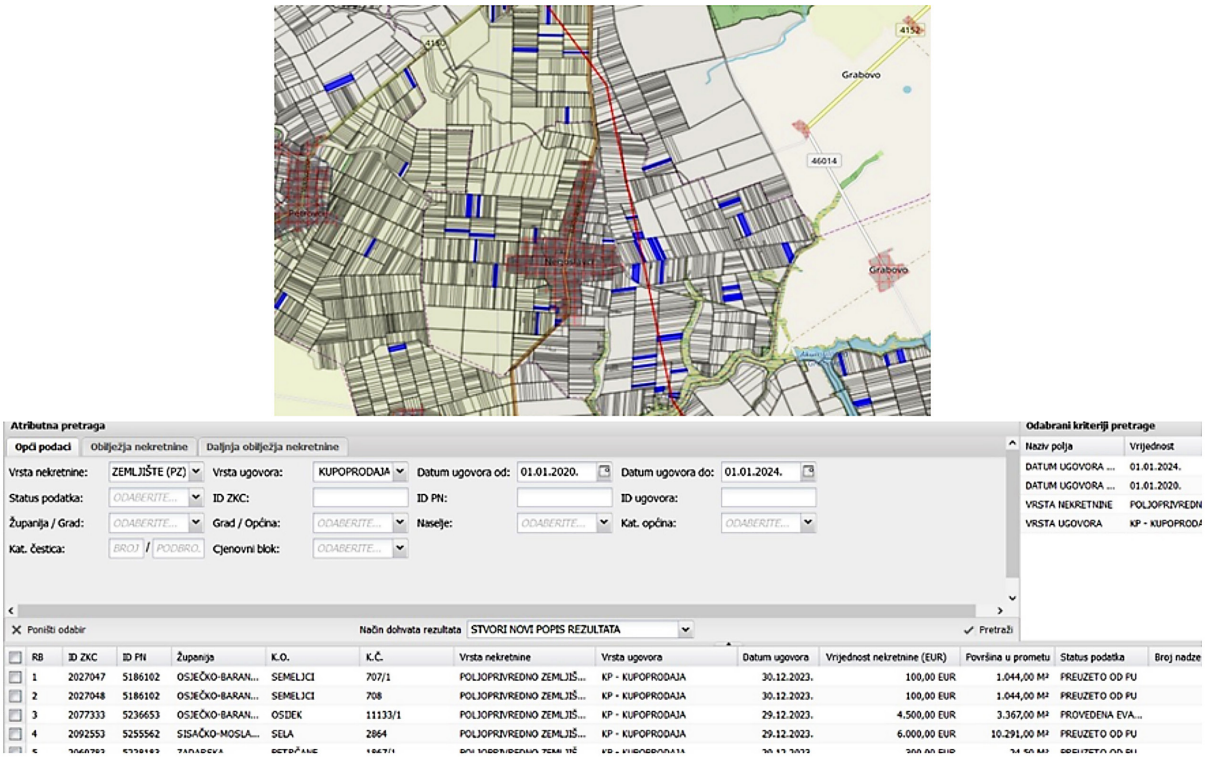
Objektivnost u procjeni nekretnina u tržnoj privredi kompleksan je postupak. I napredna društva Europe su desetljećima razvijale i usavršavale postupke kojim bi se vrijednost nekretnina objektivizirala. Metode procjene nekretnina u Hrvatskoj propisane su Zakonom o procjeni vrijednosti nekretnina NN (2015a). Procjena nekretnina multidisciplinaran je postupak. Propisane metode su poredbena, prihodovna i troškovna.

3.1. Poredbena metoda

Zakon je poredbenoj metodi dao prioritet. Temelji se na zbirci kupoprodajnih cijena transakcija nekretnina koje je registrirala porezna uprava. Pozornost na potencijal nekretnina i na veliku razliku po jedinici površine za raznu infrastrukturu ukazuje se u radu Gjuranić i dr (2015). Ovo se događa zbog odabira uzornih zemljišta za svaku katastarsku česticu zasebno. Procjena za potrebe nagodbe treba objektivizirati naknadu za cijelu trasu elektroenergetskog voda. Zbog toga odabir uzornih nekretnina treba proširiti, na cijelu trasu ili na nekoliko cjelina. Amortizacijski vijek elektroenergetskog voda je 40 godina, pa godišnju naknadu za služnost treba izračunati za cijeli amortizacijski period. Za investitora je ekonomičniji oblik jednokratna isplata za služnost pa četrdesetgodišnju naknadu treba diskontirati. Pri postupku je vođeno računa o karakteru nekretnine (poljoprivredno, građevinsko, prometno zemljište) sukladno zbirci kupoprodajnih cijena iz e Nekretnina (URL 1) .

3.2. Zbirka kupoprodajnih cijena nekretnina e-Nekretnine

Portal e Nekretnine pod nadležnošću Ministarstva prostornog uređenja, graditeljstva i državne imovine, dostupan je ograničenom krugu korisnika čiji je posao vezan za transakcije s nekretninama, kontro-



Slika 3: Uvid u e Nekretnine (URL 1)

lom tih transakcija ili procjenu vrijednosti nekretnina (Slika 3). Zbirka kupoprodajnih cijena stalno se dopunjava.

3.3. Određivanje naknade za ugovorno ustanovljenje služnosti

Zauzetost nekretnine izgradnjom elektroenergetskog voda izražava se u površini stupa ili površini koju čini projekcija krajnjih vodiča na parceli (trasa voda). Uvidom u e Nekretnine može se uspoređivati cijena uzornih nekretnina s kupoprodajnom cijenom po kojoj su prodane. Ovo je standardni postupak propisan Zakonom o procjeni vrijednosti nekretnina. S obzirom na to da nepotpunim izvlaštenjem (ustanovljavanje služnosti) vlasnik zadržava vlasništvo zakon nalaže da se izračunata naknada umanji za određeni koeficijent. Tako je za stup iznos umanjen za 20 % tržne vrijednosti zauzete nekretnine (koeficijent 0,8), dok je za iznos koji je određen za površinu trase voda umanjenje za 90 % (koeficijent 0,1). Postotak umanjenja procjenjuje stalni sudski vještak procjenitelj vodeći se svojim iskustvom sukladno prilogu 2 Pravilnika o metodama procjene vrijednosti nekretnina NN (2015b).

Za potrebe nagodbe uvedena su još dva elementa: amortizacija i diskontiranje. Oba ova postupka su investicijski pokazatelji, njene održivosti i troškova prethodnog postupka. Objektivnost procjene za ovu namjenu provodi investitor i u taj postupak nije potrebno konzultirati stranku. Odabir procjenitelja i odvjetničkog ureda koji će po dogovoru sa strankom sklopiti ugovor, provodi se na temelju odredbi Zakona o odvjetništvu NN (2021) ili Zakonu o javnoj nabavi NN (2022).

DV 2X110 kV VUKOVAR - ILOK S PRIKLJUČKOM NA TS NIJEMCI
Dionica: VUKOVAR – TS 110/35/10 KV NIJEMCI
(I i II faza iz lokacijske dozvole)

PROCJENA NAKNADE VLASNICIMA ZEMLJISTA

K.O. NIJEMCI, PUK VUKOVAR, ODJEL ZA KATASTAR NEKRETNINA VINKOVCI | K.O. NIJEMCI, Opcinski sud u Vukovaru, ZK ODJEL VINKOVCI

Rbr. čest.	Broj katastarske čestice	Kultura	Površina parcele ha	Površina parcele m²	Naziv parcele	Broj posjed. lista		POSJEDNIK Prezime, ime i ime oca posjednika, mjesto stanovanja i kućni broj	Rbr. ZK uloška	VLASNIK Prezime, ime i ime oca vlasnika mjesto stanovanja i kućni broj	Površina za nepotpuno izvlaštenje br.mjes	m²	zmk.m²	poljoprivredno zemljište stup 150*m2	poljoprivredno zemljište zrnek 19*m2	građevinsko zemljište (1) stup 130*m2	građevinsko zemljište (1) zrnek 650*m2	građevinsko zemljište zrnek 80*m2	UKUPNO	DISKONTIRANJE Ukupno*0,6717	NAKNADA
1	1479/1	ORANICA	8	2796	ŠKALJAVICA	1673	1/1	MEDIĆ VELIMIR, MARŠALA TITA 25, BANOVCI, HRVATSKA (VLASNIK), OIB:39011087421	1816	1. Vlasnički dio: 1/1 MEDIĆ VELIMIR (MILOVAN), OIB: 39011087421, V. BANOVCI, M. TITA 25			656		12464				12464	8372	8400
2	1479/5	ORANICA	8	3528	ŠKALJAVICA	1678	3/4	SALVA DALIBOR, MARŠALA TITA 7, 32247 BANOVCI, HRVATSKA (VLASNIK), OIB:09237743859	1821	1. Suvlasnički dio: 1/4 TOMIĆ KOJO (MILAN), OIB: 49398407412, BANOVCI, M. TITA 29			959		18221				18221	12239	12200
							1/4	TOMIĆ KOJO, MARŠALA TITA 29, 32247 BANOVCI, HRVATSKA (VLASNIK), OIB:49398407412		5. Suvlasnički dio: 3/4 SALVA DALIBOR (MILAN), OIB: 09237743859, VINKOVAČKI BANOVCI, MARŠALA TITA 7											
3	2660	PUT		4328	SELO	1747	1/1	OPĆINA NIJEMCI - JAVNO DOBRO U OPĆOJ UPORABI, TRG KRALJA TOMISLAVA 6, NIJEMCI (VLASNIK)	1	2. Vlasnički dio: 1/1 OPĆINA NIJEMCI-JAVNO DOBRO U OPĆOJ UPORABI			51					4080	4080	2741	2700
4	2505	KANAL		6107	SELO	750	1/1	RH-JAVNO VODNO DOBRO, ZAGREB (VLASNIK), HRVATSKE VODE ZA UPRAVLJANJE VODAMA, UL.GRADA VUKOVARA 220, ZAGREB (UPRAVITELJ), OIB:28921383001	1648	1. Vlasnički dio: 1/1 REPUBLIKA HRVATSKA - JAVNO VODNO DOBRO 2.1 Pod upravljanjem: HRVATSKE VODE ZAGREB			72		1368				1368	919	900
5	1478/1	ORANICA	9	3538	ŠKALJAVICA	741	1/1	REPUBLIKA HRVATSKA, ZAGREB, ZAGREB (VLASNIK), OIB:52634238587	1514	1. Vlasnički dio: 1/1 REPUBLIKA HRVATSKA	69/2	81	1826	12150	34694				46844	31465	31500

Slika 4. Prikaz tablice - elaborat izvlaštenja dopunjen s procjenom nekretnina (Dalekovod projekt d.o.o. i GEOprem d.o.o.)

Jednokratna uplata vlasniku za četrdeset godišnju služnosti može se prikazati izrazom:

Iznos naknade = površina x jedinična cijena uzornog zemljišta x koeficijent umanjenja x amortizacijski vijek elektroenergetskog voda x koeficijent diskontiranja (Co).

Koeficijent diskontiranja $Co = Cn \times ((1+ p/100)^{h})^{-1}$. Pri čemu je Cn iznos bez diskontiranja, p faktor ukamaćivanja (odabran 1 %), h vrijeme diskontiranja. U ovom zadatku Co = 0,6717

Faktori diskontiranja su objavljeni u prilogu 8 Pravilnika o metodama procjene vrijednosti nekretnina.

U vrijeme provođenja ovog postupka službena valuta u Republici Hrvatskoj je bila kuna pa su iznosi izračunati u kunama, Konačan iznos zaokružen je na 100 kuna. Prikaz tablice je vidljiv na Slici 4.

Uz pristanak vlasnika investitor i vlasnik sklapaju ugovor o ustanovljavanju služnost. Na temelju ovog ugovora provodi se uknjižba u zemljišnoj knjizi. Time je postupak uređenja imovinsko pravnih poslova okončan i postupak izvlaštenja nije potrebno provoditi.

4. Postupak izvlaštenja ako se stranke nisu uspjele dogovoriti oko naknade

Ako vlasnik nije suglasan s ponuđenom naknadom investitor to mora pismeno dokazati. To je jedan od kumulativnih uvjeta koji investitor mora dokazati u pokretanju postupka. Investitor pokreće postupak pred nadležnim tijelom.

Sukladno Zakonu o uređivanju imovinskopravnih odnosa u svrhu izgradnje infrastrukturnih građevina NN(2011) koje grade tvrtke u pretežnom vlasništvu RH, RS, JLS na nekretninama u njihovom vlasništvu ne naplaćuju međusobno služnost. Mišljenje Upravnog suda RH je u suprotnosti s poimanjem samog duha zakona, jer tvrdi da sestrinska trgovačka društva (u predmetnom slučaju HOPS d.d. je u vlasništvu HEP d.d.) čiji su osnivači navedeni subjekti ne podliježu odredbama ovog zakona. Posljedično za nekretnine u vlasništvu navedenih subjekata je bilo potrebno provesti postupak izvlaštenja.

4.1. Imenovanje procjenitelja uz suglasnost zainteresiranih stranaka

Postupak izvlaštenja u pravilu inicira zainteresirana stranka, počinje predlaganjem više kandidata koji imaju znanje i ovlasti procjenjivati nekretnine. Nadležno tijelo inicira zabilježbu postupka u zemljišnoj knjizi. Procjena nekretnina multidisciplinaran je posao. Investitor i vlasnik trebaju biti suglasni s odabranim jednim ili više procjenitelja. O iznosu procjene procjenitelj preko nadležnog tijela istodobno obavještava i investitora i stranku. S obzirom na to da je postupak javan, uočena je tendencija da se vlasnik konzultira s više osoba i u pravilu traži veću naknadu. Za procjenitelja je odabran stalni sudski vještak agronomske struke i stalni sudski vještak geodetske struke. Iznos procjene je u pravilu bio niži od prvobitno nuđenog iznosa tako da su stranke zahtijevale sporazumni ugovor čime je postupak izvlaštenja prekinut.

4.2. Procjena gospodarskog potencijala katastarske čestice za poljoprivrednu proizvodnju

Pri ustanovljavanju služnosti za izgradnju elektroenergetskog voda stranke su svjesne da će elektroenergetska građevina onemogućiti ili otežati korištenje dio poljoprivredne površine na uobičajeni način. Stalni sudski vještak i procjenitelj iz područja poljoprivrede sukladno objavljenim statističkim podacima o prinosima i cijeni pojedinih kultura predlaže iznos za obeštećenje. Iznos se predočava i investitoru i vlasniku. Ako su suglasni, služnost se može ugovoriti kao nagodba. U praksi postoje razni slučajevi produženja postupka. Uspoređuju se naknade susjeda, zahtjeva se procjena od strane drugog procjenitelja i dr. Opravdanost zahtjeva ocjenjuje voditelj postupka i ako smatra ispravnim rješenjem ustanovljava služnost, nezadovoljne stranke upućuje na drugostupanjski postupak.

4.3. Predočavanje trase elektroenergetskog voda i granica katastarske čestice stranci

Uočeno je da prvotno stranke nisu pristale na sklapanje ugovora, jer su osim cijene bile nesigurne u granice svojih katastarskih čestica pa je stalni sudski vještak za geodeziju svojim pokazivanjem međe na terenu otklonio pristranost procjenitelja poljoprivredne struke. Osim toga neke međe katastarskih čestica na trasi elektroenergetskog voda su bile sporne i u sudskom postupku. Odluka suda kojom su se međe parcela uređivale odražavale su se i na promjenu geodetskog elaborata izvlaštenja pa je prisustvo sudskog vještaka geodetske struke bilo presudno za objektivnost ugovaranja naknade između vlasnika (Slika 5).

4.4. Rješenje o izvlaštenju

Rješenje o izvlaštenju upravni je akt, čija pravovaljanost nastupa protekom određenog roka. Nezadovoljna stranka može izjaviti žalbu Ministarstvu pravosuđa i uprave, a u slučaju nepovoljnog ishoda nezadovoljna stranka može pokrenuti upravni spor. Poslije donošenja rješenja o izvlaštenju nadležno tijelo će inicirati brisanje zabilježbe o pokretanju postupka. Na temelju rješenja zemljišno knjižni sud će upisati služnost na djelomično izvlaštenoj nekretnini.

5. Komunikacija sa sudionicima postupka

Komunikacija među sudionicima: investitor, vlasnik, ured za provođenje postupka, odvjetnici, procjenitelji, geodeti, katastar, zemljišna knjiga odvija se pisa-



Slika 5. Terenski očevid (foto: V. Slivac)

nim i verbalnim putem. Pojedine faze komunikacije iziskuju dokaze radi poštivanja zakonskih rokova. U ovom poslu za verbalnu komunikaciju je korišten „call centar" odvjetničkog društva, čime je postignut učinkovitiji kontakt s vlasnicima nekretnina. Jako je važno da je ta komunikacija dostupna tijekom cijelog radnog dana. Izvještavanje naručitelja o stanju pojedinog predmeta omogućeno je GIS aplikacijom neprekidno (24/7/365).

6. Postupak uz podršku web GIS aplikacije

Osim ukazivanje na pojedine postupke kod rješavanja imovinskopravnih odnosa između investitora i vlasnika nekretnine svrha je promovirati i alate kojima se postiže uvid u stanje predmeta krugu ljudi koje investitor odredi bez potrebe sastajanja, pisanja izvješća ili uvida u pojedini dokument na kojem se temelji postupak. Za univerzalni pristup je korišten web pristup, a u svrhu kreiranja baze podataka su odabrani softver alati AutoCAD Map i DB Browser. Za vizualizaciju podataka i web prikaz prostornih baza podataka je korišten softver MapGuide otvorenog koda koji je informatički prilagođen potrebama zadatka. U sklopu informatičkih prilagodbi je izrađen i dodatak za MapGuide u svrhu generiranja izvještaja i skica svakog pojedinog predmeta u postupku izvlaštenja. Ulazni parametri su bili: elaborat izvlaštenja (grafički i tabelarni dio), procjena za potrebe nagodbe, prostorni plan iz koga je vidljiva namjena nekretnina na kojima će se ustanoviti služnost, on line pristup bazi katastra (grafički i pisani dio), prilagođena baza zemljišno knjižnog stanja nekretnina. Tijekom rada baza se dopunjavala ponuđenim i potpisanim ugovorima, rješenjima o izvlaštenju, prijedlozima za uknjižbu i ZK izvatkom poslije uknjižbe. Sudionici koji su imali pristup mogli su vidjeti sve dokumente i prema potrebi dobiti tražene podatke u vidu tabela bilo digitalno (XLS, PDF format) ili ispisom na svom pisaču.

Ovaj model je odabran radi kontrole velikog broja podataka koji se u pojedinim dokumentima ponavljaju, čime se reduciraju eventualne greške. Osim toga ovako organizirani podaci mogu se bez gubitaka migrirati u informatički sustav tvrtke kao što je HOPS d.d.

7. Zaključak

Reguliranje odnosa vlasnika infrastrukture i vlasnika nekretnine na kojoj se ona gradi je nužnost. Kompleksnost djelomičnog izvlaštenja upisom stvarnog prava služnosti, koji se u RH provodi za vodove, proizlazi iz velikog broja nekretnina na kojima se infrastruktura gradi, režima vlasništva i namjene nekretnine za gospodarsku ili drugu svrhu. Ovo od procjenitelja traži posebna znanja o potencijalu nekretnine i karakteristikama infrastrukture. Provođenje postupka je multidisciplinaran posao. Sinergijsko djelovanje naručitelja, procjenitelja i vještaka raznih struka, odvjetničkog ureda i nadležnog tijela koje vodi postupak temelji se na propisima i stručnom iskustvu sudionika.

Geodetska struka bi u ovom postupku trebala biti puno agilnija, jer vodi temeljne registre države o nekretninama i infrastrukturi. Osim toga informatičkim znanjem o GIS-u ubrzava procese dopune informacijskih rješenja tvrtke koja upravlja infrastrukturom. Ubrzavanje regulacije uređenja imovinsko pravnih odnosa povećavamo pravnu sigurnost države i njenih građana, a drugima ukazujemo da težimo pravno uređenoj državi.

Literatura:

Ambroš, F., Bajt, J., Rulj, A., Skelin, M. (2016): Special Legal Regimes Pertaining to Infrastructure – the Task of Geodetic Profession to Create a Technical Base for the Application of Legal Regulations Pertaining to Infrastructure, International Symposium on Engineering Geodesy SIG 2016, Varaždin

Gjuranić, M., Salopek, D., Žuti, V., Ambroš, F. (2015): Procjena okrnjenosti nekretnina na kojima je

izgrađena infrastruktura – osvrt na nekretnine na kojima je izgrađena elektronička komunikacijska infrastruktura, rad u zborniku:4.kongres sudskih vještaka i procjenitelja, Zagreb

NN (1994): Zakon o odvjetništvu, Narodne novine RH, Zagreb 09/94, 117/08, 50/09, 75/09, 18/11, 126/21.

NN (2011): Zakon o uređivanju imovinskopravnih odnosa u svrhu izgradnje infrastrukturnih građevina, Narodne novine RH, Zagreb, 80/11 i 144/21.

NN (2014) Zakon o izvlaštenju i određivanju naknade, Narodne novine RH, Zagreb, 74/14, 69/17, 98/19/.

NN (2015a): Zakon o procjeni vrijednosti nekretnina, Narodne novine RH, Zagreb, 78/2015.

NN (2015b): Pravilnik o metodama procjene vrijednosti nekretnina, Narodne novine RH, Zagreb, 105/2015.

NN (2016): Zakon o javnoj nabavi, Narodne novine RH, Zagreb, 120/16, 114/22.

NN (2021): Zakon o odvjetništvu, Narodne novine RH, Zagreb, 09/94, 117/08, 50/09, 75/09, 18/11, 126/21.

NN (2022): Zakonu o javnoj nabavi, Narodne novine RH, Zagreb, 120/16, 114/22.

URL 1: Ministarstvo prostornog uređenja, graditeljstva i državne imovine https://nekretnine.mgipu.hr/Auth/ (11. 6. 2024.).

Expropriation and Assessment of Real Estate for the Construction of Energy Infrastructure

Abstract

Solving property legal relations between infrastructure investors and owners of real estate on which that infrastructure is built is a demanding technical, administrative and legal procedure. The regulation of ownership relations during the construction of infrastructure which is of interest to the Republic of Croatia is carried out in accordance with the Act on Expropriation and Determination of Compensation. For its construction, energy infrastructure uses the real estate of legal and natural persons in various legal regimes within planned use of space. By building the subject infrastructure, the owner is partially expropriated, and this is done by entering the easement in the land register as a real burden. The infrastructure is built on cadastral parcels, so the procedure begins with the presentation of the route of the infrastructure on the cadastral plan. Use case of easement for an individual property is specific to each cadastral parcel. With the construction of infrastructure, the cadastral parcel is degraded according for its planned use, to a greater or lesser extent, so the owner is entitled to get an compensation. The procedure includes preparation of the expropriation report, real estate evaluation, provision of a budget for compensation, and an attempt to reach an agreement with every individual owner. In the event that an agreement is not reached, the real estate is appraised by different appraiser, upon which the competent authority of the County (or the City of Zagreb) makes a decision on expropriation and ends with the registration of the easement in the land register. The owner which remains dissatisfied with the compensation, is referred to the court in order to determine the fair compensation for the use of his real estate. The paper describes a case with a description of the role of participants from various professions. It points out the complexity and length of the procedure when conducting the procedure and suggests how to speed up the procedure. At the same time, it is pointed out the possibility of controlling each stage of the procedure and insight into the state of the case through a web application based on GIS.

Keywords: *expropriation study, assessment study, easement registration, multidisciplinary procedure*

3.

DALJINSKA ISTRAŽIVANJA I FOTOGRAMETRIJA

High-Resolution UAV-based Photogrammetry for 3D Modelling and Monitoring Changes of Earth Pillars: Case Study Devil's Town – Project Demonitor

Nenad Brodić[1], Uroš Đurić[1], Mileva Samardžić-Petrović[1], Anastasija Martinenko[1], Marko Pejić[1]

[1] Faculty of Civil Engineering, University of Belgrade, Bulevar kralja Aleksandra 73, Belgrade, Serbia, nbrodic@grf.bg.ac.rs, udjuric@grf.bg.ac.rs, mimas@grf.bg.ac.rs, amartinenko@grf.bg.ac.rs, mpejic@grf.bg.ac.rs

Abstract

In the project "Devil`s town Erosion MONITORing - DEMONITOR," accessible earth pillars in the Devil`s town area will be monitored for two years using a variety of non-invasive techniques. Photogrammetric imaging with unmanned aerial vehicle (UAV) as a platform showed a great potential for 3D modeling of this site, monitoring significant changes of earth pillars and identification of rockfall occurence. In this study, it was demonstrated that manual free-flight UAV photogrammetry outperformed automatic flight missions made with vertical imagery from predefined flight plans in terms of higher level of detail on 3D model. For the period of 6 years of UAV photogrammetry monitoring it was possible to identify rockfall from the top of certain earth pillars and the complete collapse of one earth pillar.

Keywords*: 3D modeling, earth pillars, photogrammetry, rockfall*

1. Introduction

The DEMONITOR project focuses on monitoring a rare geological phenomenon at the "Devils' town" site near Prolom Spa in southern Serbia. The interaction of erosional forces and volcanic rock have resulted in the formation of approximately 200 tall earth pillars that are referred to unofficially as "the Devils" at this location. The mentioned landforms are the result of centuries of erosion and weathering.

Earth pillars would be monitored for three years using advanced, non-invasive techniques like aerial photogrammetry with unmanned aerial vehicles (UAV), terrestrial laser scanning (TLS), interferometric synthetic aperture radar (InSAR), and geophysical techniques to quantify changes like the rate of erosion, the occurrence of rockfall, and ground subsidence. For the needs of this paper, only results collected with UAV photogrammetry will be discussed because this method was used for monitoring of the whole area of interest for several years. With the fundamental principles of photogrammetry combined with robust algorithms from the computer vision community, collections of overlapping images can be automatically processed to rapidly extract the 3D point cloud (Lowe, 2004; Snavely et. al., 2008). With this method, it should be possible to track significant changes of the earth pillars such as rockfall from the top of the pillars or the total collapse of some of this landforms during a certain period.

This project is a continuation of the pilot project MEĐA, which was carried out by a part of the DEMONITOR research team between the years 2017 and 2018 (Đurić et. al., 2018). During that project, two acquisitions of the test site were performed in November 2017 and November 2018 (using TLS and UAV methods). As a 3D representation of the initial terrain surface, the first acquisition produced a so-called zero state model. Each subsequent acquisition produced a new point cloud with the same reference system, resolution, and precision. By comparing the new 3D model with the previous, the spatial differences that occurred between two acquisition epochs as a consequence of the erosion of an earth pillar can be picked up and measured (Ylmaz et. al., 2010). In February 2024, the most recent UAV acquisition was carried out as part of project DEMONITOR.

Photogrammetrically recorded images can be used for 3D modeling of the area, but these results were not reliable for erosion monitoring (Alexiou et. al., 2021). The fundamental benefit of using UAV as a platform for photogrammetric imaging is the possibility to perform imaging above and from the side of this landforms and get a better access for 3D modelling of some hidden spots and shadowed objects not accessible from the ground.

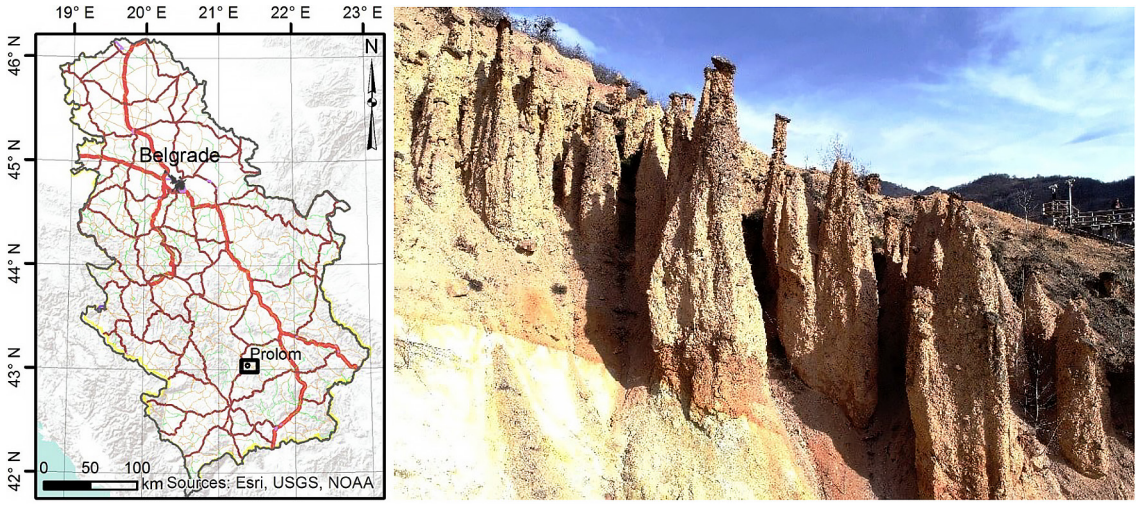


Figure 1: Devils' town location in Serbia (left) and its landforms – earth pillars (right)

The DEMONITOR project's outcomes are anticipated to not only depict the change but also enable prediction of its change rate and trend. This will allow for the development of appropriate preventative or stabilization measures, which will ultimately result in the permanent site's conservation. The site will be promoted and credited with all scientific findings, particularly in relation to United Nations Educational, Scientific and Cultural Organization (UNESCO), while also increasing its tourist value, which may further benefit the local economy.

2. Study area

Nearly 200 earth pillars, some of which are up to 15 m tall and 6 m in diameter, are found in Devils' town, a rare geomorphological and geological phenomenon that is a protected natural heritage site in southern Serbia. These earth pillars were formed over years by erosional forces. The site is part of the Lece volcanic complex, showcasing a unique combination of volcanic genesis and erosion. Geological evidence of past volcanic activity, including violent eruptions that produced pyroclastic flows, can be found in these landforms, which are commonly referred to as "the Devils". The erosion process, influenced by various factors, continues to shape and change (collapsing, sinking and emerging) these remarkable landforms, prompting intrigue about their future amidst climate change.

3. Concept and Methodology

Currently, TLS and UAV approaches are usually used for collecting data in soil erosion monitoring (Alexiou et. al., 2021, Somayeh et. al., 2024 and D'Oleire-Oltmanns et. al., 2012). TLS and UAV methods will provide high-resolution local surface models for the requirements of this project. InSAR will be used to monitor displacements of fixed ground control points (corner reflectors, and possibly strong natural reflectors, such as caprock), ensuring that the global stability of the site is satisfied, i.e., that the changes are relative to the pillars and not the wider terrain deformations, such as regional subsidence for instance. UAV photogrammetry aka structure-from-motion (SfM) method using UAV imagery is also a beneficial tool for topographic data collection (Westoby et. al., 2012).

At least two UAV acquisition sequences, or site visits per year, were planned. In order to reduce the amount of noise caused by vegetation, both visits

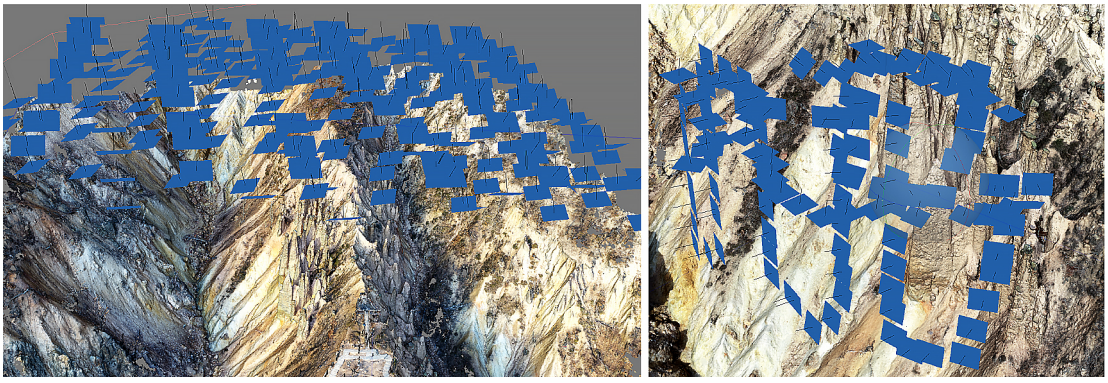


Figure 2. Two type of flight plans– automated flight plan from a height of 50 m (left) and manual free-flight plan with distance less than 20 m from the camera to the earth pillars (right)

Table 1: Results comparison of each UAV mission

Epoch	Number of images	Number of points	GCP total error [cm]	Processing time [h]
2017	254 (80 m height)	15,8 million	1.0	16
2018	424 (182 at 50 m and 242 at 80 m height)	31.3 million	1.1 (50 m) 2.9 (50 m+80 m)	20
2024	680 (20 m distance)	48.1 million	2.6	26

are scheduled for the non-vegetative season (late autumn/early spring). Each sequence of imaging will produce a current surface model (3D point-cloud) of the major landforms. The principal idea is to compare these surface models in an appropriate software package such as CloudCompare (URL 1, 2024), which will allow interpretation, i.e., detection and quantification of the 3D surface change between consecutive sequences (or any other combination of sequences). Simply put, it would be possible to spatially visualize which parts of this landforms have changed between two visits and for how much.

The software solution Agisoft Metashape (URL 2, 2024) was used to generate point clouds with UAV imagery. It represents an advanced solution for 3D modeling based on images, which aims to generate high-quality 3D content from images. The images can have any position, but under the condition that the object to be reconstructed is visible in at least two images. Image alignment and 3D model reconstruction are fully automated.

Spatial data collection using photogrammetric methods requires several stages. The first phase is flight preparation, which includes the creation of a flight plan and stabilization and marking of the ground control points (GCP) on the field. This points that evenly cover the site area are used for georeferencing of the 3D model and therefore their coordinates should be determined. The flight plan is defined in such a way as to ensure the minimum flight overlap between images (transverse 80%, longitudinal 80%), certain number of the flight lines and the sufficient number of images within each line. In this case, the GCP coordinates were determined by post-processing the data collected with TLS in the local coordinate system. The scanner registers data in its unique coordinate system.

In MEĐA project, all of the flight missions for UAV photogrammetry were performed in a way to cover the whole area of interest with a sufficient number of overlapping images needed for 3D reconstruction. These images were usually vertical and collected from above at a height of 50 m or 80 m above the ground. The imaging was double-routed, using longitudinal and transverse flight directions. In the first acquisition of the DEMONITOR project, imaging was performed manually during a manual free-flight mission which offers greater coverage of complex objects such as these landforms. In this way, much more images were collected during this type of flight, but a higher level of detail was acquired with a smaller number of shadowed parts of the objects (Fig. 2).

Based on this analysis, it is clear that in order to get more detail with a UAV as a platform, the object of interest should be flown over and photographed from every angle to collect as many images as possible and get more greater detail.

4. Results and Discussion

In November 2017, first fieldwork was carried out in the MEĐA project. After the second acquisition, which was carried out in November 2018, the initial results of the erosion calculation were obtained. It was concluded that the time between this missions was insufficient in order to detect any observable changes in these landforms by using photogrammetry method.

As it was said, the first fieldwork in the DEMONITOR project was conducted in February 2024. UAV imaging lasted about one hour and 30 minutes with three batteries used. The UAV used for the photogrammetric mission was a quadcopter DJI Phantom 4 PRO. This aircraft has a 20Mpix camera with a mechanical shutter which makes this UAV camera more suitable for photogrammetry needs. This model of the aircraft doesn't have real-time kinematic (RTK) positioning needed for direct georeferencing of images. Real field conditions caused certain parts of the objrcts to remain inaccessible for imaging, for example, parts between the closely positioned earth pillars, which shadowed one another. Also, there were areas behind these landforms that were not accessible for measuring. A local coordinate system was set up with a total of 10 GCPs for georeferencing photogrammetric block of aerial images.

A total of 680 images were recorded from a distance smaller than 20 m from UAV camera to earth pillars which resulted in image acquisition at each 2 m of traveled path that gives sufficient image overlap between consecutive image locations (> 80%). The recording included an area of 0.047 km^2. The mean total error of the resulting point cloud was about 2.6 cm. For the creation of a dense point cloud with high quality option, 48.1 million points were generated. A comparison with UAV missions performed in 2017 and 2018 is presented (Table 1).

An orthomosaic with a ground sample distance (GSD) of 1 cm/pix was generated while the reconstructed digital surface model (DSM) GSD was 4 cm/pix.

As it can be seen from the results, 3D point clouds generated in 2024 showed much higher level of de-



Figure 3: Difference in the level of detail between the 3D model reconstructed with automated flight plan made in 2018 year (left) and manual free-flight plan made in 2024 year (right) and identification of collapsed earth pillar marked with black ellipse on both images

tail when compared with 3D point clouds obtained from missions performed in 2017 and 2018. This is obviously the result of using a new imaging procedure with a manual free-flight plan that gives higher spatial resolution and better coverage of this complex landforms. Here 3D models of earth pillars have much better morphology and higher detail in terms of visibility of pebbles and other small details (Fig. 3).

In order to compare 3D models from different time epochs, it was needed to align one model to another in CloudCompare because these were georeferenced in different coordinate systems. When comparing 3D models generated from missions performed in 2018 and 2024, it can be identified that there are some major changes on some of this landforms, despite areas with growing vegetation. One pillar that was almost 7.5 m high have completely collapsed (Fig. 3 – marked with black ellipse) and two of them lost their hats - rocks have fallen from the top of the pillars (example is shown on Fig. 4).

Also there were situations when rocks that were on the top of the earth pillars continued to sink in the terrain due to the erosion and weathering happened between the observation epochs (Fig. 5).

5. Conclusions

Modern UAV systems as measuring platforms are gaining more and more space in geodetic and other engineering activities. Fast, high-resolution data acquisition with optimal project costs brings UAV photogrammetry into the sphere of interest for the engineering and photogrammetry public.



Figure 4: Identification of earth pillar with a lost cap made of rock between 3D model generated from 2018 mission (left) and model generated from 2024 mission (right)



Figure 5: Identification of sinking rock that was on the top of earth pillar between 3D model generated from 2018 mission (left) and model generated from 2024 mission (right)

UAV photogrammetry has the indisputable advantage of collecting data in inaccessible areas, especially when it is not possible to find a stable position to place the measuring instrument. Thus, UAV usage as a platform is extremely useful in recording and tracking objects in engineering photogrammetry, but also in monitoring the topography of the terrain in larger areas of interest. In this paper, the acquisition of imagery data by using UAV system is shown, which enables very precise spatial data generation for further analysis and the mutual comparison of the subsequent imaging missions.

By performing manual free-flight UAV imaging with an optimal flight path it is possible to collect data for 3D model generation with much higher spatial resolution due to the shorter imaging distance from camera to the earth pillars. In this way also shadowed areas will be avoided as much as possible. This was much better than the missions performed in the past with almost nadir images captured from a bigger distance above this landforms.

As it can be seen from the results of this paper, rockfall occurrence is possible to detect with UAV photogrammetric missions especially when comparing models during longer periods for this geomorphological phenomenon. It was found that one earth pillar was collapsed, two of the pillars had rock fallen off from the top, and some of the rocks that were on the top of this landforms continued to sink in the terrain.

Acknowledgments

This research was supported by the Science Fund of the Republic of Serbia, Grant TF C1389-YF, Project No. 7515, Project: Devils Town Erosion Monitoring - DEMONITOR.

References

Alexiou, S., Deligiannakis, G., Pallikaraki A., Papanikolaou I., Psomiadis, E. and Reicherter, K. (2021): Comparing High Accuracy t-LiDAR and UAV-SfM Derived Point Clouds for Geomorphological Change Detection, International Journal of Geo-Information, 10. (6), doi: 10.3390/ijgi10060367.

D'Oleire-Oltmanns, S., Marzolff, I., Peter, K.D. and Ries, J.B. (2012): Unmanned Aerial Vehicle (UAV) for Monitoring Soil Erosion in Morocco, Remote Sens., 4 (11), pp. 3390-3416. doi: https://doi.org/10.3390/rs4113390.

Đurić, U., Pejić, M., Marjanović, M., Đurić, D., and Krušić, J. (2018): Monitoring of erosion in the area of Đavolja Varoš: Project MEĐA", 17th Serbian Geological Congress, vol. 2, 780-785., Vrnjačka Banja, Serbia.

Lowe, D. (2004): Distinctive Image Features from Scale-Invariant Keypoints, International

Journal of Computer Vision. 60. 91-110, doi: 10.1023/B:VISI.0000029664.99615.94

Snavely, N., Seitz, S.N., Szeliski, R. (2008): Modeling the world from internet photo collections, International Journal of Computer Vision 80, 189-210., doi: 10.1007/s11263-007-0107-3

Somayeh, M., Gomez, C., Pajoohesh, M. and Abdollahi, K. (2024): Soil erosion and sediment change detection using UAV technology, in book: Remote Sensing of Soil and Land Surface Processes Monitoring, Mapping and Modeling, doi: 10.1016/B978-0-443-15341-9.00025-3.

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, doi: 10.1016/j.geomorph.2012.08.021.

Ylmaz, H. M., Yakar, M., Yildiz, F., Karabork, H., Kavurmaci, M. M., Mutlouoglu, O. and Goktepe, A. (2010): Determining rates of erosion of an earth pillar by terrestrial laser scanning, The Arabian Journal for Science and Engineering, 35(2A), 163-172.

URL 1 CloudCompare (version 2.13) [GPL software]. Retrieved from http://www.cloudcompare.org/, Accessed: 2024-05-10.

URL 2 Agisoft Metashape (version 2.1.1) [Software]. Retrieved from http://www.agisoft.com/downloads/installer/, Accessed: 2024-05-10.

Praćenje promjena zemljanih stupova: studija slučaja Đavolja Varoš – projekt Demonitor

Sažetak

U projektu "MONITORing erozije Đavolje Varoši - DEMONITOR" dvije će se godine različitim neinvazivnim tehnikama pratiti dostupni zemljani stupovi na području Đavolje Varoši. Fotogrametrijsko snimanje s bespilotnom letjelicom (UAV) kao platformom pokazalo je veliki potencijal za 3D modeliranje ovog lokaliteta, praćenje značajnih promjena zemljanih stupova i identifikaciju pojava odrona kamenja. U ovoj je studiji pokazano da UAV fotogrametrijskom metodom s ručno vođenim slobodnim letom nadmašuje automatske misije leta s vertikalnim slikama iz unaprijed definiranih planova leta u smislu većeg detalja 3D modela. U razdoblju od 6 godina praćenja UAV fotogrametrijom bilo je moguće identificirati odron stijena s vrha pojedinih zemljanih stupova i potpuno urušavanje jednog zemljanog stupa.

Ključne riječi: *3D modeliranje, zemljani stupovi, fotogrametrija, odroni kamenja*

Procjena dugotrajnog učinka klimatskih utjecaja primjenom podataka daljinskih istraživanja

Mateo Gašparović[1], Ivana Metić[1]

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

Sažetak

Predmet ovog istraživanja je dugotrajna procjena dinamike kvalitete vegetacije na području Spačvanskog bazena od 1984. do 2023. godine. Cilj je odrediti na koji način i u kojoj mjeri određeni klimatski čimbenici utječu na stanje vegetacije. Istraživanje je provedeno metodama daljinskih istraživanja, analizom satelitskih snimki misije LANDSAT i Sentinel. Područje interesa ovog istraživanja je Spačvanski bazen, koji zauzima površinu od 43.519 ha. Za prikupljane, obradu i analizu podataka korištena je platforma Google Earth Engine. Mjerene su vrijednosti NDVI-a za razdoblje od 1984. do 2023. godine, iz čega je vidljivo kako usprkos naglašenim klimatskim parametrima, vrijednost indeksa raste. Ekstrahirani su podaci NDVI-a za šestogodišnje razdoblje od 2018. do 2023. iz čega su procijenjeni početak i kraj fenološkog ciklusa. Ti procijenjeni rezultati zatim su uspoređeni s rezultatima dobivenima pomoću algoritma koji računa početak i kraj fenološkog ciklusa. Ustanovljeno je da fenološki ciklus u prosjeku oscilira mjesec dana, dok je prethodne, 2023. godine, oscilirao dva mjeseca. Provedena je i klasifikacija nadziranom metodom CART (Classification and Regression Tree), za svakih 5 godina od 1984. do 2023. godine. Uz to su provedene dvije podrobnije analize za period prije i nakon poplave 2014. godine, te prije i nakon oluje 2023. godine. Ukupno gledajući, povećanje temperature i smanjenje količina padalina utječu na fenološki ciklus, no učinak je vidljiv za kratak period vremena. Veću prijetnju stvaraju ekstremni vremenski uvjeti poput poplave i oluje, koji su također učinci klimatskih promjena.

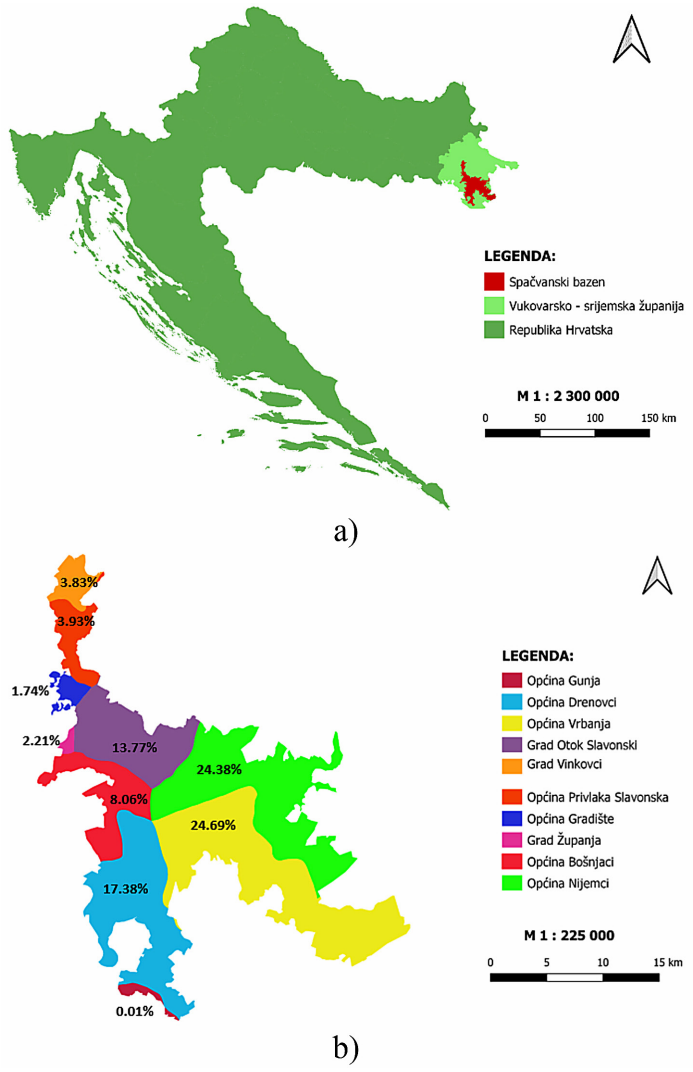
Ključne riječi: *daljinska istraživanja, klimatske promjene, prostorno-vremenska analiza, Spačva, vegetacija*

1. Uvod

Klimatske promjene vrlo su aktualna tema zadnjih nekoliko godina, stoga su se brojni znanstvenici i istraživači u svojim radovima osvrnuli na to pitanje. Velik broj istraživanja proveden je u Americi i većim europskim državama, no znatan broj radova pronađen je i za područje interesa ovog rada – Spačvanskog bazena.

Dubravac (2010) se u svom radu bavi hrastom lužnjakom u Hrvatskoj i Spačvanskom bazenu, te o važnosti, povijesti sušenja i dosadašnjim spoznajama. Za analizu su korišteni arhivski podaci koji prikazuju kako se šumovitost u Slavoniji mijenjala od kraja 18. stoljeća do danas. Važan zaključak ovog rada, je da se Spačvanski bazen, zahvaljujući šumarskoj struci, nije značajnije smanjio u površini tijekom posljednjih sto godina. Mikac i dr. (2020) u svom radu govore o utjecaju recentnih promjena klime na nizinske šumske ekosustave hrasta lužnjaka u Hrvatskoj, točnije u šumskim bazenima Lonjsko polje i Spačva. Za istraživanje su koristili dendrokronološke metode, a rezultati su pokazali da su stabla na području Spačvanskom bazena osjetljivija na klimatske promjene od onih u Lonjskom polju. Lasić (2023) se u svom radu bavi temom gospodarskog vrednovanja šuma Spačvanskog bazena. Navodi važnost tih šuma u gospodarstvu Vukovarsko-srijemske županije i Hrvatske. Uvodi nas u problematiku ugroze bazena, koja je karakterizirana sušenjem sastojina.

Iako postoji znatan broj radova koji se bavi problematikom utjecaja klimatskih promjena na zdravlje i kvalitetu šuma Spačvanskog bazena, posebnost ovog rada je u tome što su provedene dugotrajne analize za razdoblje od 1984. do 2023. godine. Osim analiza dugotrajnih klimatskih promjena poput povećanja temperature, smanjenja količine padalina, promjene površinske temperature tla, provedena je i analiza za razdoblje od 2018. do 2023. gdje je prikazano kako se pomiče ciklus početka i kraja sezone ozelenjivanja na području Spačvanskog bazena. Uz to je izvršena klasifikacija područja od interesa, kojom je stečen uvid u efekte ekstremnih vremenskih uvjeta poput poplave i oluja.



Slika 1: Područje istraživanja a) Lokacija Spačvanskog bazena u Republici Hrvatskoj i b) Podjela teritorija Spačvanskog bazena

2. Materijal i metode

2.1. Područje istraživanja

Područje istraživanja ovog rada je Spačvanski bazen (Slika 1). Područje Spačvanskog bazena dio je panonske nizine u najnižem dijelu Posavine. Smješten je u Vukovarsko – srijemskoj županiji, između rijeka Save i Dunava, u porječju rijeke Bosut i njenih pritoka. Središnji tok je rijeka Spačva, po kojoj je bazen i dobio ime. Prostire se na 43.519 ha, što ga čini najvećom cjelovitom nizinskom šumom hrasta lužnjaka u Hrvatskoj i u Europi. Hrastom najbogatija europska zemlja, Francuska, vlasnica je šume hrasta lužnjaka zvane Fontainebleau koja broji tek nešto više od 18 tisuća hektara, što je znatno manje od Spačvanskog bazena (Lončar, 2005). Područje Spačvanskog bazena nalazi se na teritoriju deset jedinica lokalne samouprave, od kojih najveću površinu zauzimaju općine Vrbanja (24,69%) i Nijemci (24,38%). Nešto manji dio područja pripada općini Drenovci (17,38%) i gradu Otoku Slavonskom (13,77%). Gradovi Vinkovci i Županja te općine Bošnjaci, Privlaka Slavonska, Gradište i Gunja imaju manje od 8% u udjelu površine područja (Slika 1b).

Prostor Vukovarsko-srijemske županije i šume Spačvanskog bazena nalazi se na području umjereno kontinentalne klime. Ljeta su sunčana i vruća, a zime su hladne i snježne. Srednja godišnja temperatura kreće se oko 11°C sa srednjim najtoplijim maksimumom od 29,9°C i srednjim minimumom od 12,2°C. Srednje godišnje padaline kreću se u relativno uskom rasponu. Najniže su u krajnjem istočnom dijelu gdje iznose oko 650 mm, a idući prema zapadu vrijednost srednjih godišnjih padalina postupno raste do 800 mm. Najviše padalina ima u proljeće i sredinom ljeta, što pogoduje usjevima. Srednja relativna vlaga iznosi 79%. Premda su količine oborina relativno jednolično raspoređene na cijelu godinu, treba naglasiti da najsušniji dio pripada zimskom dijelu godine (Nacrt plana upravljanja Spačvanski bazen, 2013).

Nadalje, potrebno je istaknuti kako Spačvanski bazen predstavlja nacionalno blago po pitanju doprinosa dosadašnjem i budućem razvoju Vukovarsko – srijemske županije, ali i cijele Republike Hrvatske. Na ovom području koncentrirana je otprilike petina cjelokupne površine hrasta lužnjaka u Hrvatskoj. Najveći prerađivač drva je Drvna industrija Spačva d.d. koja drvne proizvode izvozi u Italiju, Francusku, Španjolsku te Bosnu i Hercegovinu. U 2014. godini ostvarena dobit Uprave šuma Vinkovci iznosila je 60 milijuna kuna, što čini čak 41% ukupne dobiti Hrvatskih šuma te godine (Lasić, 2023).

2.2. Izvori i prikupljanje podataka

Izvor klimatskih podataka ovog rada je portal Climate Change Knowledge Portal. CCKP je središte informacija, podataka i alata povezanih s klimom za World Bank Group. Portal pruža online platformu uz pomoć koje se pristupa sveobuhvatnim podacima vezanima uz klimatske promjene i razvoj (URL 1). Sa portala su preuzeti podaci o srednjoj godišnjoj temperaturi zraka i srednjoj godišnjoj količini padalina u razdoblju od 1983. do 2023. godine. Izvor satelitskih podataka bila je Google Earth Engine platforma. Radi se o platformi za znanstvenu analizu i vizualizaciju skupova geoprostornih podataka, za akademske, neprofitne, poslovne i službene korisnike. Earth Engine je nevjerojatno moćan alat za praćenje okoliša. Alat je dizajniran za geografe, znanstvenike i istraživače kako bi im omogućio brz pristup i analizu više od 600 skupova podataka o prostoru, uključujući i satelitske snimke od 1970-ih do danas. Platforma je bazirana na JavaScript API programskom jeziku (URL 2).

Izvor podataka satelitskih snimaka za četrdesetogodišnju analizu je misija LANDSAT. Za potrebe ovog rada kombinirane su kolekcije snimaka misija LANDSAT 5, LANDSAT 7, LANDSAT 8 i LANDSAT 9. Kolekcije snimki satelitske misije LANDSAT 5 korištene su za analizu od 1984. do 2000. godine. Kolekcije snimki satelitske misije LANDSAT 7 korištene su za analizu od 2000. do 2013. godine. Kolekcije snimki satelitske misije LANDSAT 8 korištene su za analizu od 2013. do 2021. godine, dok su kolekcije snimki satelitske misije LANDSAT 9 korištene za analizu od 2021. do 2023. godine. Prije provođenja analize, postavljeno je nekoliko parametara. Prvi parametar bila je granica, pomoću koje su generirane samo one snimke koje se nalaze unutar područja od interesa. Za područje od interesa u platformu je ubačen vektorski sloj granica Spačvanskog bazena, preuzet sa Bioportala (URL 3). Sljedeći parametar koji je bilo potrebno podesiti je prekrivenost snimke oblacima. Parametar je podešen tako da generira samo one snimke čija prekrivenost oblacima je manja od 20%. Na taj način je još više reduciran prostor traženja, zbog čega je softver brže došao do rezultata.



3. Računanje prosječne temperature tla temeljem satelitskih snimaka

Temperaturu tla (engl. Land Surface Temperature – LST) moguće je prikupiti temeljem LANDSAT satelitskih misija. Navedena varijabla predstavljam vrlo važan izvornik za provedbu znanstvenih istraživanja u domeni procjene dugotrajnog učinka klimatskih utjecaja (Gašparović i dr. 2023). Kombinirajući opažanja niza satelitskih konstelacija, temperaturu površine kopna ne ometaju oblaci, osiguravajući kontinuirano, dosljedno i znanstveno pouzdano bilježenje podataka u zadnjih gotovo četiri desetljeća. Posljedično, nema zahtjeva za održavanjem širokih mreža fizičkih senzora. Analiza temperature tla u ovom radu provedena je na temelju satelitskih snimaka iz LANDSAT 5, LANDSAT 7 , LANDSAT 8 i LANDSAT 9 misija. Analiza je provedena na području Spačvanskog bazena u periodu od 1984. do 2023. godine, pomoću algoritma razvijenog po uzoru na istraživanje Ermida i dr. 2020.

4. Vegetacijski indeks normalizirane razlike (NDVI)

Vegetacijski indeks normalizirane razlike mjera je količine i bujnosti vegetacije na površini zemlje. U pravilu, NDVI vrijednosti kreću se u rasponu od -1.0 do 1.0, gdje negativne vrijednosti predstavljaju oblake i vodu, pozitivne vrijednosti blizu nule predstavljaju golo tlo, a više pozitivne vrijednosti predstavljaju vegetaciju. Nisko raslinje i rijetka vegetacija najčešće poprimaju vrijednosti 0.1 – 0.5, dok šume i gusta vegetacija poprimaju vrijednosti od 0.6 nadalje.

NDVI računa se pomoću bliskog infracrvenog i crvenog kanala, a formula glasi:

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (1)$$

U formuli (1) „RED'' označava crveni dio elektromagnetskog spektra (0.6-0.7 μm), dok NIR predstavlja bliski infracrveni dio elektromagnetskog spektra (0.75-1.5 μm) (URL 12).

Prilikom provedbe analize bilo je važno voditi računa o kanalima pojedinih satelitskih misija. Za izračunavanje NDVI indeksa pomoću snimaka dobivenih sa LANDSAT 5 i LANDSAT 7 misija korišteni su treći (crveni) i četvrti (bliski infracrveni) kanal. S druge strane, za izračunavanje NDVI indeksa pomoću snimaka dobivenih sa LANDSAT 8 i LANDSAT 9 misija korišteni su četvrti (crveni) i peti (bliski infracrveni) kanal.

5. Detekcija promjene fenološkog ciklusa

Fenologija je definirana kao znanstveno proučavanje sezonskih dinamika različitih bioloških faza, koje se javljaju tijekom životnog ciklusa biljaka (Lieth, 1974).

Kopnena fenologija (engl. Land Surface Phenology – LSP) može se definirati kao proučavanje sezonskih dinamika vegetacije korištenjem multispektralnih satelitskih opažanja. (De Beurs i Henebry, 2004). Glavni pojmovi u fenologiji su početak sezone rasta (Start of Season – SOS) i kraj sezone rasta (End of Season – EOS). Početak sezone rasta (SOS) može biti povezan s otvaranjem lišća ili cvjetanjem, a kraj vegetacijske sezone (EOS) može biti povezan s jesenskim obojenjem lišća ili opadanjem lišća. Kao i na sve prirodne procese, klimatske promjene imaju značajan utjecaj i na fenološki ciklus, odnosno na pomicanje početka i kraja sezone rasta uslijed naglog porasta temperature. U ovom radu provedena je šestogodišnja analiza od 2018. do 2023. za područje Spačvanskog bazena, uz pomoć Sentinel-2 satelitskih snimaka. Analiza je provedena uz pomoć razvijenog algoritma razvijenom u radu Descals i dr. 2020. Potom je uspoređena s procijenjenim početkom i krajem sezone rasta iz izračunatih NDVI vrijednosti.

6. Klasifikacija

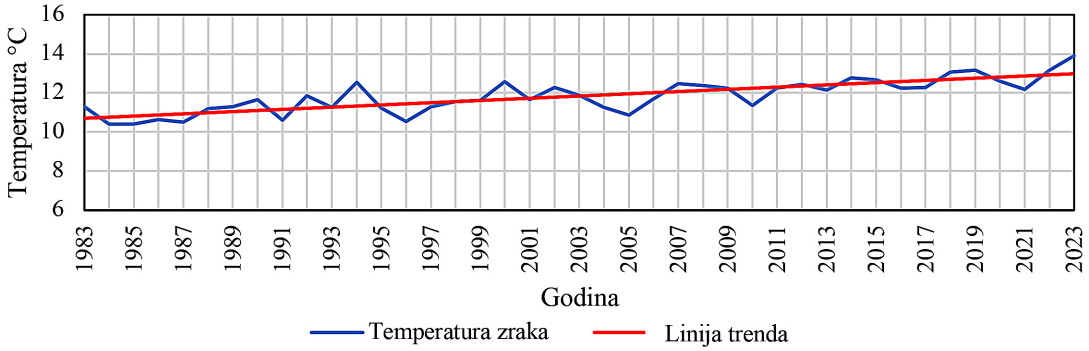
Klasifikacija je proces kategorizacije piksela satelitskih snimaka u klase na temelju njihovih spektralnih karakteristika. Četiri su osnovne klase: vegetacija, voda, golo tlo i izgrađeni objekti. Svaka od te četiri klase ima dovoljno različite spektralne potpise da algoritam bez problema izvrši klasifikaciju. Postoje dvije glavne vrste klasifikacija, a to su nadzirana i nenadzirana klasifikacija. U sklopu ovog rada korišten je algoritam nadzirane klasifikacije CART. Glavna karakteristika nadzirane klasifikacije, je ta što korisnik unaprijed definira klase i uzorke poznatih područja za obuku algoritma.

Klasifikacija je izvršena na LANDSAT snimkama za svakih pet godina u periodu od 1984. do 2023. godine. Uz to su izvršene posebne klasifikacije prije i nakon poplave u Gunji 2014. godine, te prije i nakon olujnog nevremena, koje je pogodilo veći dio kontinentalne Hrvatske u srpnju 2023. godine.

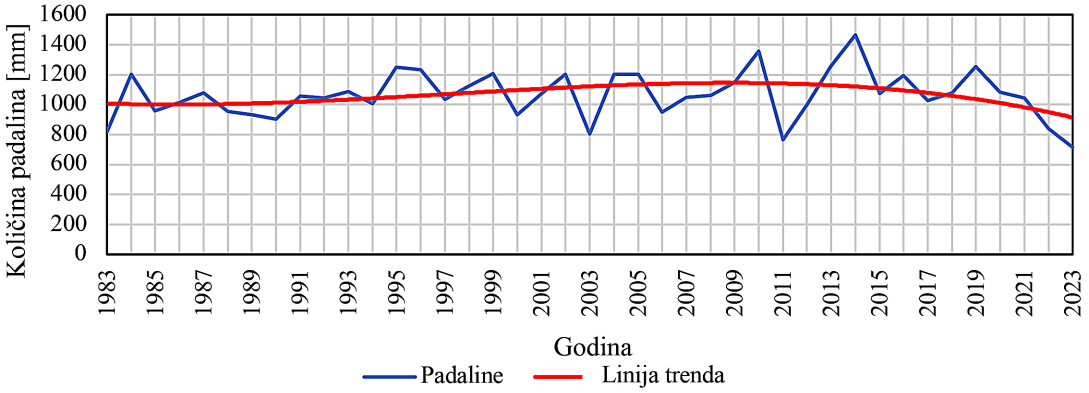
Postupak klasifikacije na platformi Google Earth Engine sastoji se od nekoliko koraka. Prvi korak bio je učitati kolekciju snimaka, koja je potom filtrirana na datum od interesa i područje od interesa. Definirani su vizualni parametri za crveni, zeleni i plavi dio elektromagnetskog spektra, te su sukladno tome odabrani i kanali iz satelitske kolekcije potrebni za provođenje klasifikacije. Prilikom korištenja snimaka iz LANDSAT 5 i LANDSAT 7 misija korišteni su kanali 3, 2 i 1, dok su prilikom korištenja snimaka iz LANDSAT 8 i LANDSAT 9 misija korišteni kanali 4, 3 i 2.

7. Rezultati

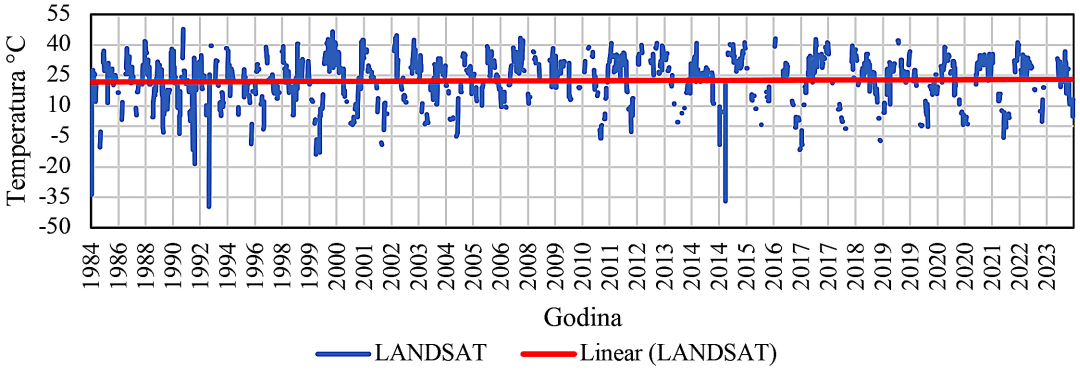
Rezultati analize klimatskih parametara doveli su nas do relativno očekivanih rezultata. Iz grafičkog prikaza prosječne temperature zraka u Hrvatskoj (Slika 2), vidljivo je kako temperatura rapidno raste. Poseban rast zabilježen je od 2014. godine. U posljednjih deset godina temperatura zraka porasla je za gotovo dva stupnja. Ako uzmemo u obzir da je već više od pedeset godina prosječna temperatura zraka Hrvatske 10° - 12°, porast na 14° predstavlja značajan rast



Slika 2: Grafički prikaz prosječne temperature zraka u Hrvatskoj od 1983. do 2023. godine



Slika 3: Grafički prikaz prosječne količine padalina u Hrvatskoj od 1983. do 2023. godine



Slika 4: Grafički prikaz površinske temperature na području Spačvanskog bazena od 1984. do 2023.

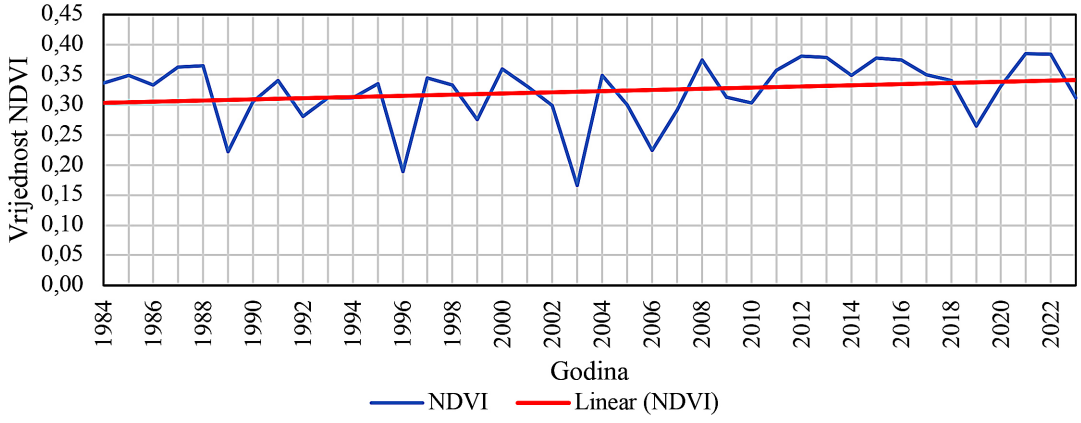
i razlog za brigu. Graf također potvrđuje podatak Svjetske meteorološke organizacije, koji kaže da je 2023. godina bila najtoplija od kad postoje mjerenja.

Iz grafičkog prikaza prosječne količine padalina u Hrvatskoj (Slika 3), iščitavamo kako je količina padalina s godinama postala sve manja. Smanjenje količine padalina nije toliko drastično kao što je porast prosječne temperature. Godine kada je Gunju zadesila razorna poplava, zabilježena je najveća količina padalina u svih četrdeset godina istraživanja. Od 2014. količina padalina poprima silazni tok. Ako u razmatranje uzmemo i prethodni graf gdje je je 2014. prosječna temperatura znatno krenula rasti, dolazimo do zaključka da su klimatske promjene u Hrvatskoj, u posljednji deset godina zbilja uzele maha.

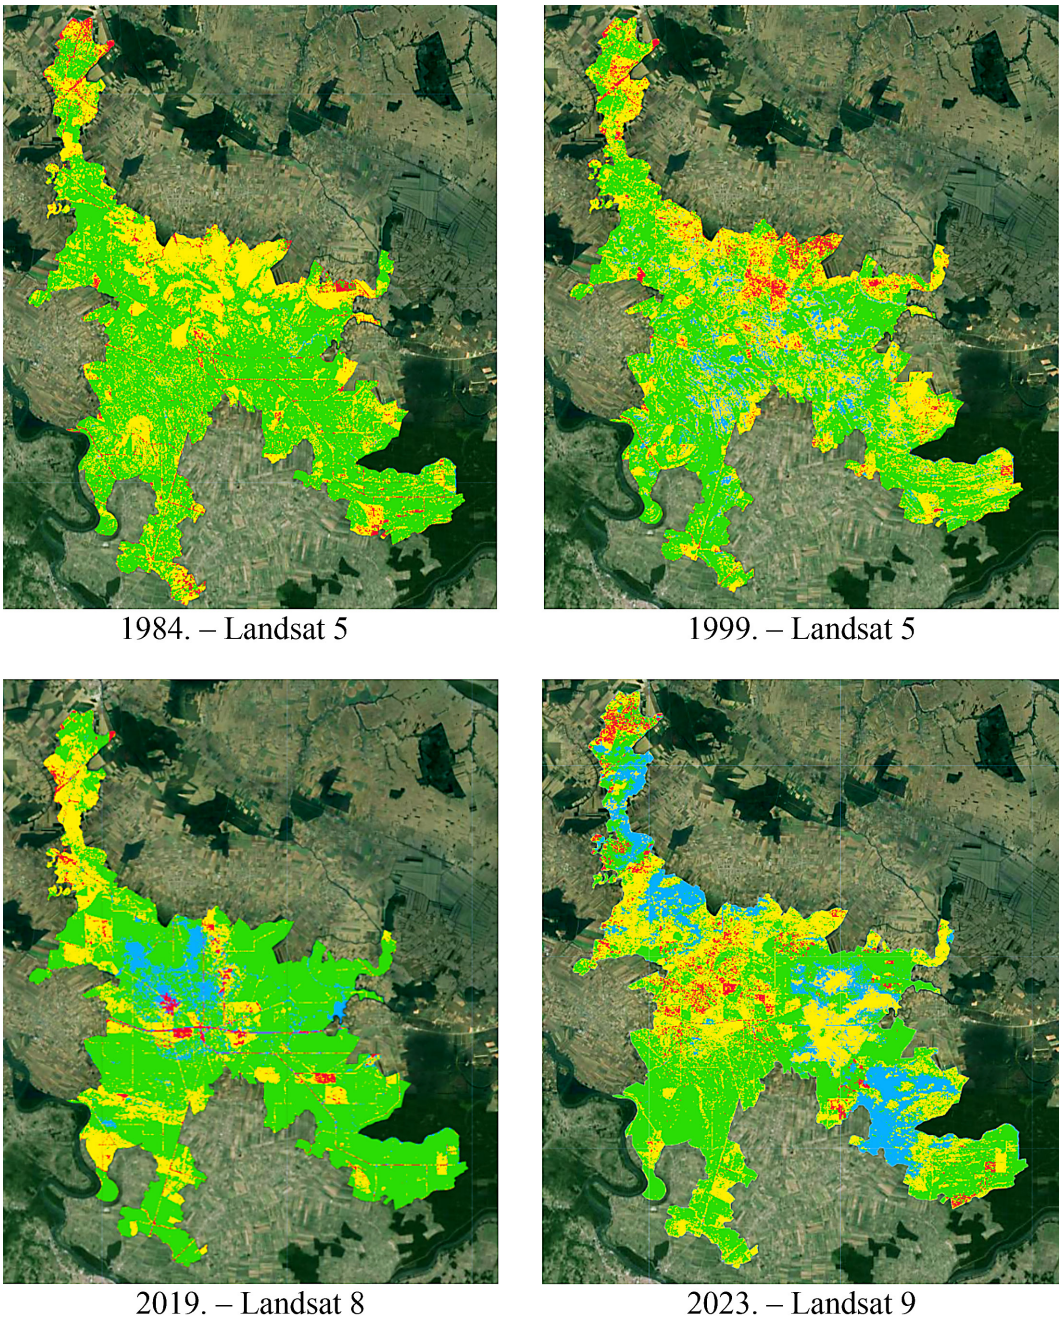
Grafički prikaz prosječne temperature površine zemlje (Slika 4) također je doveo do očekivanih rezultata. Jasno je da temperatura zemlje ne može oscilirati tako drastično kao temperatura zraka. Zemlji treba više vremena da poprimi određenu temperaturu, ali i da ju promjeni. Također treba uzeti u obzir da se promatrala površinska temperatura tla šume Spačvanskog bazena, koja je po prirodi vlažnija, tamnija i hladnija. Vidljiv je blagi rast površinske temperature. Uz to iščitavamo kako je u proteklih deset godina znatno manja količina ekstremno niskih temperatura tla nego što je to bilo u prva dva desetljeća istraživanja.

Rezultat NDVI analize od 1984. do 2023. godine (Slika 5) ukazuje da je neovisno o drastičnom povećanju temperature i blagom smanjenju količine padalina, količina zdrave vegetacije u blagom porastu. Godine sa znatno manjim vrijednostima ispod linije trenda su 1989., 1996. 2003., 2006. To je potvrđuje prethodnu tvrdnju da je period od 2002. do 2006. godine bio najtopliji do tad. U već promatranoj 2014. godini, vidljivo je da je količina zdrave vegetacije iznad linije trenda, no ipak je u blagom padu do 2015. godine. To povezujemo sa činjenicom da je 2014. godina bila najtoplija godina do tad, te je područje Spačvanskog bazena zadesila razorna poplava. Nakon toga je vegetaciji trebalo vremena da se obnovi. Rast NDVI vrijednosti zabilježen je od 2015. godine. Isti zaključak donosimo i za 2019. godinu, koja je bila najtoplija do tad, što je rezultiralo padom vrijednosti NDVI. Vidljivo je da i za 2023. godinu NDVI pada ispod linije trenda, što je u suglasnosti sa činjenicom da je to bila najtoplija godina od kad postoje mjerenja.

Glavni cilj ove analize bio je procijeniti u kojim mjesecima počinje i završava sezona rasta, odnosno odrediti vremenski interval fenološkog ciklusa. Odabran je isti vremenski period kao i u analizi fenološkog ciklusa provedenoj pomoću algoritma na platformi *Google Earth Engine*. Na taj način će se provesti usporedba procijenjenog početaka i kraja fenološkog ciklusa dobivenog na temelju NVDI vrijednosti, te vrijednosti dobivenih uz pomoć algoritma. Za potrebe ovog razvijen je algoritam za izračunavanje početka i kraja sezona rasta hrasta lužnjaka na području Spačvanskog bazena, a rezultati su prikazani u Tablici 1.



Slika 5: Rezultat NDVI analize od 1984. do 2023. godine.



Slika 6. Rezultat klasifikacije.

Tablica 1: Rezultat izračuna početka i kraja sezone rasta hrasta lužnjaka na području Spačvanskog bazena

	Izračun SoS i EoS na temelju algoritma	
Godina	Mjesec početka	Mjesec kraja
2018.	travanj	kolovoz
2019.	svibanj	kolovoz
2020.	travanj	rujan
2021.	svibanj	rujan
2022.	travanj	kolovoz
2023.	svibanj	listopad

Normalan fenološki ciklus hrasta lužnjaka započinje u ožujku i travnju, a završava tijekom rujna. Ako izračunate podatke (Tablica 1) usporedimo s normalnim ciklusom, primjećujemo da je unazad pet godina ciklus pomaknut za barem mjesec dana, bilo da se radi o početku ili kraju. Prethodne 2023. godine ciklus je pomaknut za čak dva mjeseca. Kasnije je počeo, ali i završio. To je na nekim predjelima dovelo do toga da je drveće ponovno počelo pupati, jer su klimatski uvjeti u listopadu bili kao u proljeće.

Na temelju ~100 proizvoljno odabrana uzorka, izrađene su klasifikacije za satelitske snimke za različite godine sukladno dostupnim LANDSAT misijama (Slika 6). Godine 1984. vidljivo je kako više od pola teritorija Spačvanskog bazena čine šume. Godine 1999. primjećujemo pad postotka teritorija pokrivenog šumom u odnosu 1984. To odgovara podatku da je

od 1996. do 2005. posječeno 2 700 000 m3 slučajnog prihoda hrasta lužnjaka (Dubravac, 2010). Klasificirani prikaz snimke iz kolovoza 2023. godine, nakon olujnog nevremena jasno ukazuje kako je tek nešto više od 50% teritorija Spačvanskog bazena prekriveno šumom, a gotovo 15% teritorija prekrivaju vodeni nanosi. Ako ovu klasifikaciju usporedimo s onom prije oluje 2019., jasno je da je oštećena ili potpuno uništena, gotovo trećina šume.

4. Zaključak

Učinci klimatskih promjena prisutni su i vidljivi u cijelom svijetu. Nagle klimatske promjene glavni su izazov današnjeg čovječanstva. S obzirom da su šume pluća svijeta, posebno je nužno pratiti učinke koje klimatske promjene imaju na njih, te na sveukupnu vegetaciju. Uz to, ključnu ulogu u brizi oko šuma i vegetacije ima čovjek. Treba djelovati na uzročnike naglih klimatskih promjena, kako bi stopa drastičnog rasta pala, ali treba i sankcionirati posljedice. Metodama daljinskih istraživanja provedena je prostorno-vremenska analiza dinamike i kvalitete šumskog pokrova kroz četrdesetogodišnji ciklus. Uz to je provedena analiza za šestogodišnji ciklus, koja detektira promjene u fenološkom ciklusu hrasta lužnjaka na području Spačvanskog bazena. Sve analize provedene su pomoću algoritama na platformi *Google Earth Engine*.

Analizom dobivenih rezultata, donesen je zaključak o stanju kvalitete šume Spačvanskog bazena. Usprkos drastičnom porastu temperature i smanjenoj količini padalina, šuma bilježi trend rasta kvalitete vegetacije. Veću prijetnju predstavljaju ekstremni vremenski uvjeti. Poplava u Gunji 2014. godine ostavila je posljedice na šumu, od kojih se oporavljala gotovo deset godina. Postotak šumskog pokrova pet godina nakon poplave i dalje je bio za gotovo 10% manji, od stanja prije poplave. Tek 2023. godine zabilježen je porast šumske vegetacije na iznad 80%, no iste godine područje je zadesila razorna oluja, od koje se šuma oporavlja još dan danas.

Ključni zaključak ovog istraživanja, je da dugotrajni klimatski učinci imaju efekta na stanje vegetacije, no u posljednje vrijeme, za te efekte ne moramo čekati toliko dugo kao što je bilo prije. Smanjeni ciklus klimatskih promjena obrnuto je proporcionalan s problemima i štetom po pitanju stanja vegetacije. Što se ciklus više smanjuje, posljedice na vegetaciju bi mogle biti drastičnije.

Literatura

Descals, A., Verger, A., Yin, G., & Peñuelas, J. (2020). Improved estimates of arctic land surface phenology using Sentinel-2 time series. Remote Sensing, 12(22), 3738.

Dubravac T. (2010). Hrast Lužnjak u Hrvatskoj i Spačvanskom bazenu – važnost, povijest sušenja i dosadašnje spoznaje, Hrvatski šumarski institut, http://www.hkisdt.hr/podaci/dokumenti/dubravac_na.pdf (02.06.2024.).

Ermida, S. L., Soares, P., Mantas, V., Göttsche, F. M., Trigo, I. F. (2020). Google earth engine open-source code for land surface temperature estimation from the landsat series. Remote Sensing, 12(9), 1471.

Gašparović, M., Zorić, Š., Singh, S. K. (2021). Urbanisation impact on creation of heat islands in large cities. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 43, 313-318.

Mikac, S., Trlin, D., Žmegač, A., Dekanić, S., Miklić, B., Anić, I. (2020). Utjecaj recentnih promjena klime na nizinske šumske ekosustave hrasta lužnjaka (Quercus robur L.) u Hrvatskoj // Gospodarenje šumama u uvjetima klimatskih promjena i prirodnih nepogoda. Zagreb: Hrvatska akademija znanosti i umjetnosti (HAZU), 2020. str. 1-16 (01.06.2024.).

Nacrt plana upravljanja Spačvanski bazen (2013): Natura 2000 Upravljanje i Monitoring –NATURA MANMON, Spačvanski bazen, Predloženo Natura 2000 područje, Nacrt plana upravljanja (30.05.2024.).

Lasić, M. (2023). Gospodarsko vrednovanje šuma Spačvanskog bazena, Repozitorij Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, 2023, str. 6-8 (31.05.2024.).

Lončar, T. (2005). Kad kažem hrast, mislim na spačvanske šume, Geografija.hr, https://geografija.hr/kad-kazem-hrast-mislim-na-spacvanske-sume/ (03.06.2024.).

Metić, I. (2024). Procjena dugotrajnog učinka klimatskih utjecaja primjenom podataka daljinskih istraživanja, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb.

URL 1: Climate Change Knowledge Portal, https://climateknowledgeportal.worldbank.org/ (30.05.2024.).

URL 2: Google Earth Engine, https://earthengine.google.com/ (30.05.2024.).

URL 3: Bioportal, https://bioportal.hr/, (15.04.2024.).

Assessment of the Long-Term Impact of Climate Impacts Using Remote Sensing Data

Abstract

The subject of this research is a long-term assessment of the dynamics of vegetation quality in the Spačvan basin from 1984 to 2023. The goal is to determine how and to what extent certain climatic factors affect the state of vegetation. The research was conducted using remote sensing methods, by analysing satellite images from the LANDSAT and Sentinel missions. The area of interest of this research is the Spačvan basin, which covers an area of 43,519 hectare. The Google Earth Engine platform was used for data collection, processing and analysis. NDVI values were measured for the period of time from 1984 to 2023, from which is evident that despite the highlighted climate parameters, the value of the index is increasing. NDVI data were extracted for the six-year period from 2018 to 2023, from which the beginning and end of the phenological cycle were estimated. These estimated results were then compared with the results obtained using an algorithm that calculates the beginning and end of the phenological cycle. It was established that the phenological cycle oscillates for one month on average, while in the previous year, 2023, has oscillated for two months. A classification using the supervised CART (Classification and Regression Tree) method was also carried out, for every 5 years from 1984 to 2023. In addition, two more detailed analyzes were carried out for the period before and after the flood in 2014, and before and after the storm in 2023. Overall, an increase in temperature and a decrease in precipitation affect the phenological cycle, but the effect is visible for a short period of time. A greater threat is created by extreme weather conditions such as floods and storms, which are also effects of climate change.

Keywords*: climate change, remote sensing, Spačva, spatio-temporal analysis, vegetation*

Razvoj algoritma za potrebe industrijske fotogrametrijske izmjere

Mateo Gašparović[1], Filip Radić[1], Ivan Lukačević[2], Boris Fuštar[3]

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

[2] Sveučilište u Zagrebu, Građevinski fakultet, Kačićeva 26; Zagreb, Hrvatska, ivan.lukacevic@grad.unizg.hr

[3] ELEA iC d.o.o., Ulica Radoslava Cimermana 14; Zagreb, Hrvatska, borisfustar@hotmail.com

Sažetak

Umor materijala može se opisati kao oštećenje konstrukcijskog elementa u konstrukciji nastankom i postupnim širenjem pukotine, koje je uzrokovano učestalim ponavljanjem naprezanja. Za potrebe dokaza pouzdanosti novih konstrukcija ili procjene životnog vijeka postojećih konstrukcija uslijed umora provode se ispitivanja kod kojih se konstrukcijski detalj ili čitava konstrukcija izlaže repetitivnom vlačnom, tlačnom ili posmičnom naprezanju. Rad se bavi razvojem algoritma za područje industrijske fotogrametrijske izmjere korištenjem računalnih biblioteka za obradu snimaka. Cilj rada je razviti algoritam za detekciju trenutka nastanka pukotine uslijed umora. Mogućnosti određivanja trenutka nastanka jedne ili više pukotina odredit će se pomoću metode određivanja veznih točaka određenih na svim snimkama. Korištenjem metoda radiometrijske obrada i primjene konvolucijskih filtera u pripremi i naknadnoj obradi snimaka, početak i veličina pukotine će se kartirati i mjeriti. Svrha ovog rada je stvoriti algoritam koji je moguće primijeniti na više područja ispitivanja umora gdje je kao cilj odrediti trenutak nastanka i veličinu pukotine korištenjem snimaka dobivenih metodama blizupredmetne fotogrametrije. Temelj rada je obrada snimaka ispitivanja čeličnih zavarenih konstrukcijskih detalja izloženih umoru predstavljenih u radu Fuštar i dr., 2022.

Ključne riječi: *blizupredmetna fotogrametrija, industrijska fotogrametrijska izmjera, OpenCV, umor*

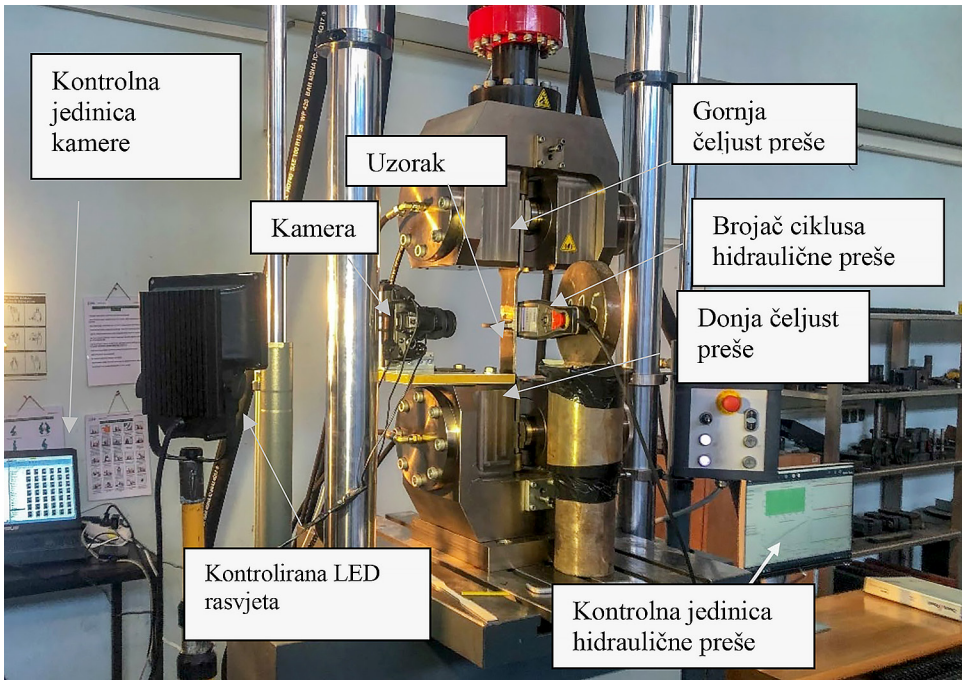
1. Uvod

Prema definiciji, blizupredmetna fotogrametrija jednostavno je prikupljanje i obrada fotogrametrijskih podataka gdje je subjekt udaljen manje od 100 metara od snimališta. Metode prikupljanja mogu biti zemaljske ili zračne, a konačni rezultat može se prikazati dvodimenzionalno ili trodimenzionalno (Luhmann, 2010). Blizupredmetna fotogrametrija je vrijedan alat koji nadilazi različita polja, pridonoseći preciznosti, učinkovitosti i točnosti. Njegova prilagodljivost i raznolika primjena čine ju nezamjenjivom tehnologijom u modernom svijetu, od koje koristi sve, od proizvodnje i zrakoplovstva do medicine, forenzike i prirodnih znanosti. Njena uloga u očuvanju povijesne i arhitektonske baštine, podržavanju medicinskih istraživanja i poboljšanju inženjerskih procesa pokazuje njegov široki utjecaj na društvo. Blizupredmetna fotogrametrija u industriji postala je tehnički i ekonomski uspješna sredinom 1980-ih, s prvim probojem u automatiziranim i visoko preciznim 3D mjerenjima (Fraser & Brown, 1986).

Umor materijala je pojam koji opisuje oštećenje konstrukcijskog elementa u konstrukciji postupnim nastankom i širenjem pukotine, koje je uzrokovano učestalim ponavljanjem naprezanja a može dovesti do sloma elementa ili čitave konstrukcije. Za potrebe dokaza pouzdanosti novih konstrukcija ili procjene životnog vijeka postojećih konstrukcija uslijed umora provode se ispitivanja kod kojih se konstrukcijski detalj ili čitava konstrukcija izlaže repetitivnom vlačnom, tlačnom ili posmičnom naprezanju. Kod ispitivanja se koriste hidraulički, pneumatski ili elektromagnetno pogonjene preše koje različitim frekvencijama opterećuju uzorak koji se ispituje. Izlazni podaci iz preša su visokoprecizni, a i dobivaju se podaci za svaki odrađeni ciklus ispitivanja.

Dodavanjem fotogrametrijskih metoda u ispitivanje uzoraka na umor otvaraju se nove mogućnosti u praćenju ispitivanja. Grana fotogrametrije koja se može primijeniti na ovakva ispitivanja jest blizupredmetna fotogrametrija koja pruža sub milimetarsku točnost koja u većini ispitivanja ispunjava traženu točnost. Fotogrametrija omogućava modeliranje uzorka u dvije ili tri dimenzije te za visoku točnost ne zahtjeva profesionalnu opremu već se s opremom srednje klase ispunjavaju zahtjevi, što cijenu primjene drži pristupačnom. Dobivanjem modela uzorka otvaraju se mogućnosti modeliranja pukotina uslijed umora u više dimenzija, smjerova i nudi mogućnost obrazloženja dobivenih rezultata.

U radu Shufrin i dr., 2016, predstavljena je eksperimentalna studija koja potvrđuje koncept akustičkih sklopova s ojačanom jezgrom. Testirani su brojni prototipovi proizvedenih metoda stereolitografije i selektivnog laserskog skeniranja. Za mjerenje deformacija korištena je metoda blizupredmetne foto-



Slika 1: Prikaz prikupljanja podataka (Fuštar i dr., 2022).

grametrije bazirane na mjernim markerima kako bi preciznost snimaka bila na razini desetinke piksela. Primjer za iznimno jednostavnu, isplativu i efikasnu metodu praćenja umora materijala predstavljen je u radu Egger i dr., 2021. Svaki uzorak označen je s dva kruga narančaste boje koji uz dva kruga na stabilnom dijelu instrumenta čine mjerne markere. Primjenom RGB (engl. Red Green Blue) filtera na snimkama ostaju samo označeni krugovi, jednostavnim algoritmom za detekciju sredine kruga dobiva se položaj točke koji se može pratiti na svakoj snimci.

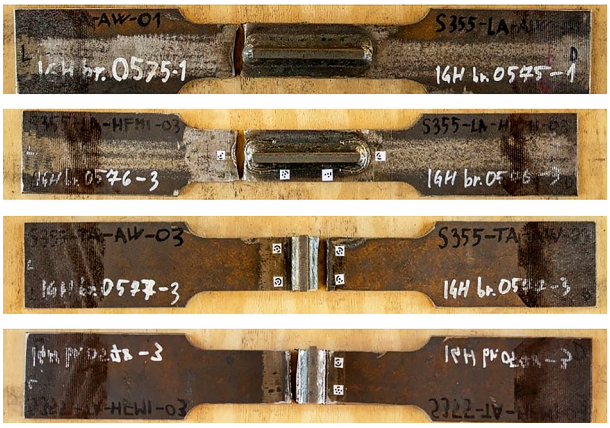
U ovom radu cilj je razviti algoritam koji razvija automatizaciju obrade snimaka za potrebe ispitivanja umora materijala dobivenih metodom blizupredmetne fotogrametrije. Glavna točka rada je detekcija trenutka početka nastanka pukotine ispitanog uzorka uz obrazloženje na temelju dobivenih podataka sa snimaka. U prethodno opisanim radovima Egger i dr., 2021 i Shufrin i dr., 2016 korišteni su mjerni markeri ili slične metode kako bi međusobno povezali snimke u svrhu detekcije promjena nad uzorcima, ovaj rad se temelji na metodi određivanja promjena nad identičnim točkama dviju snimki, što znači da nisu potrebni dodatni napori kako bi zadovoljili točnost i samu metodu izmjere. Važnu ulogu u motivaciji za osmišljavanje ovakvog algoritma ima pojam automatizacija, sama automatizacija procesa utječe na smanjivanje koraka u izmjeri i povećava pouzdanost, preciznost i točnost konačnih podataka. Također, automatizacijom procesa smanjujemo potrebu za stručnim osobljem što povećava isplativost implementacije drugih metoda u ispitivanja, kao u ovom slučaju uzoraka.

Razvoj algoritma temeljio se na biblioteci otvorenog koda OpenCV. OpenCV pruža mnoštvo mogućnosti u procesuiranju digitalnih snimaka, stoga bilo koji razvijeni algoritam se može unaprijediti od strane izvornog autora ili treće osobe koja koristi dio algoritma za svoje potrebe. Razvojem open source algoritma pruža se beskrajan rast i inovativnost što čini konkurenciju komercijalnim algoritmima.

2. Materijal i metode

2.1. Fotogrametrijska industrijska izmjera

Ispitivanja umora materijala (ciklička ispitivanja) rada (Fuštar i dr., 2022) provedena su u Laboratoriju za konstrukcije Instituta IGH d.d., na hidrauličkom ispitnoj preši Zwick/Roell—Amsler HB250 pri cikličkim naprezanjima konstantnih amplituda. Ispitivanja umora su provedena do sloma uzorka. Ispitivanje je zaustavljeno za uzorke koji nisu doživjeli slom uslijed umora nakon određenog broja ciklusa. Praćenje ruba zavara kao kritičnog mjesta na uzorku uspješno je postignuto tehnikama blizupredmetne fotogrametrije. Za praćenje razvoja pukotina na rubu zavara DSLR (engl. Digital single-lens reflex camera) kamera se montirala na 20-30 cm od površine uzorka. Točna udaljenost kamera određena je empirijski (blizu teoretski izračunate hiperfokalne udaljenosti) za svaku vrstu uzorka kako bi se fokusirala očekivana područja početka otvaranja pukotine. Kamera je spojena na besprekidni izvor napajanja i računalo. Računalni program, DigiCamControl, omogućuje *timelapse* snimanje svakih 10 s. Računalo također nudi pohranu za svaku fotografiju snimljenu tijekom cikličkog ispitivanja. Sustav rasvjete sastoji se od dodatnih LED (engl. light-emitting diode) i halogenih žarulja koje su neophodne zbog zahtijevane velike brzine zatvarača kamere. Brzina zatvarača, otvor blende i ISO osjetljivost prilagođavaju se svakom testu. Kako bi se uhvatila i pukotina na rubu zavara i broj trenutnih ciklusa (N) na istoj fotografiji, postavlja se zaslon koji prikazuje broj ciklusa (Slika 1) (Fuštar i dr., 2022).



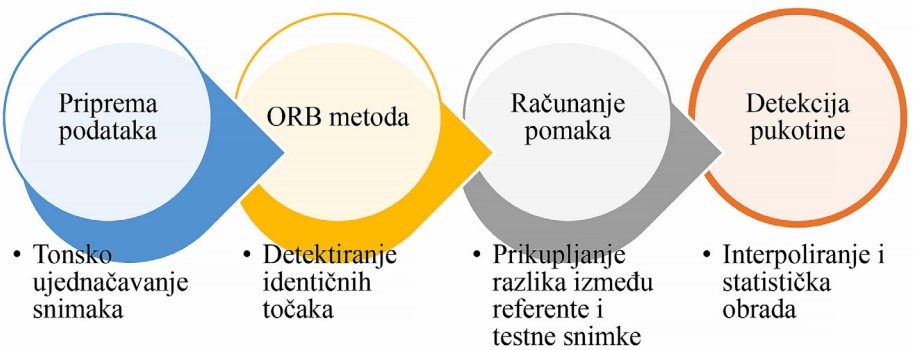
Slika 2: Primjer uzorka (Fuštar i dr., 2022).

2.2. Ispitni uzorak

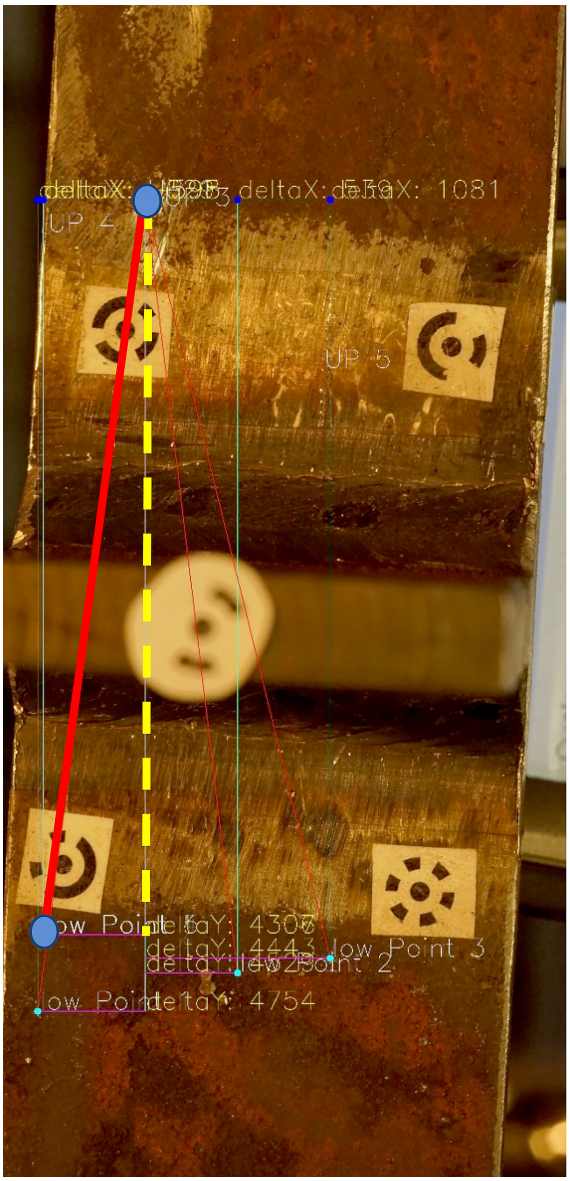
Za potrebe rada korišteni su podaci prikupljeni u sklopu rada *„Fatigue tests of as-welded and HFMI treated S355 details with longitudinal and transverse attachments“* (Fuštar i dr., 2022). U radu se raspravlja o upotrebi metode visokofrekventnog mehaničkog udara (HFMI) za povećanje otpornosti na umor zavarenih čeličnih detalja. Istraživanje koristi dvostupanjski model (TSM) koji zasebno proračunava nastanak i širenje pukotine, koristeći podatke iz ispitivanja umora (Slika 2). Rad naglašava kontrolu kvalitete kod HFMI obrade i uvodi kontinuirani sustav praćenja za prikupljanje podataka o početku i širenju pukotina. Rezultati pokazuju da HFMI obrada značajno produljuje vijek trajanja zavarenih čeličnih detalja, pridonoseći kalibraciji TSM-a (Fuštar i dr., 2022).

2.3. Razvoj algoritma za potrebe industrijske fotogrametrijske izmjere

Razvijeni algoritam (Slika 3) projektiran je za analizu slike, podudaranje ključnih točaka i statističku analizu. Temelj algoritma jest programski paket OpenCV (URL 1) koji pruža osnovne i napredne metode obrade digitalnih snimaka. Algoritam započinje tonskom obradom svih prikupljenih snimaka pojedinog uzorka kako bi se tonske vrijednosti snimaka izjednačili i pružili ujednačenije podatke. Glavni dio algoritma čini ORB (engl. Oriented FAST and Rotated BRIEF) metoda određivanje identičnih točaka na dvije snimke. ORB metodom izračuna se određeni broj točaka koji je u ovom radu optimiziran na 12 500, povećanjem broja točaka metoda postaje zahtjevnija za hardver računala no i samim time točnost pada. Razvijena metoda detekcije pukotine bazira se na praćenju vrijednosti razlika koordinata identičnih točaka para snimke (Slika 4). Za referentnu snimku uzeta je prva snimka skupa podataka, podjelom snimke na gornju i donju zonu promatranja u kojima su detektirane identične točke te je uzeto 5 najboljih rješenja ORB metode za pojedinu zonu. Računanjem vertikalnih udaljenosti točaka zona na referentnoj i trenutnoj snimci dobivamo referentnu i prikupljenu vrijednost, razlikom tih vrijednosti računa se vrijednost pomaka za određivanja pukotine ispitanog uzorka. Krajnji korak algoritma bio je razvitak metode određivanja pukotine elementa, zbog velike količine podataka i nehomogenosti uvjeti pojedine snimke, dobivene podatke je potrebno obraditi statističkim metoda koje kao rješenje ostavljaju uglađeni model ponašanja podataka. Metoda je osmišljena tako da se podaci aproksimiraju polinomom, zbog naravi podataka taj polinom će imati svoje maksimume, ako su uzmu maksimumi iz sredine podataka odnosno ako se odbace krajevi podataka koju svu nestabilni dobiva se reprezentativna maksimalna vrijednost deformacije materijala. Traži se u kojem trenutku za određeni postotak vrijednost polinom nadilazi maksimum iz sredine podataka te se taj ciklus uzima kao detekcija pukotine elementa odnosno kritična vrijednost s kojom započinje širenje pukotine (Gašparović i dr., 2024).



Slika 3: Dijagram toka razvoja algoritma (Gašparović i dr., 2024).



Slika 4: Prikaz izračunatih identičnih točaka i princip računanja vertikalnih koordinatnih razlika (žuta linija).

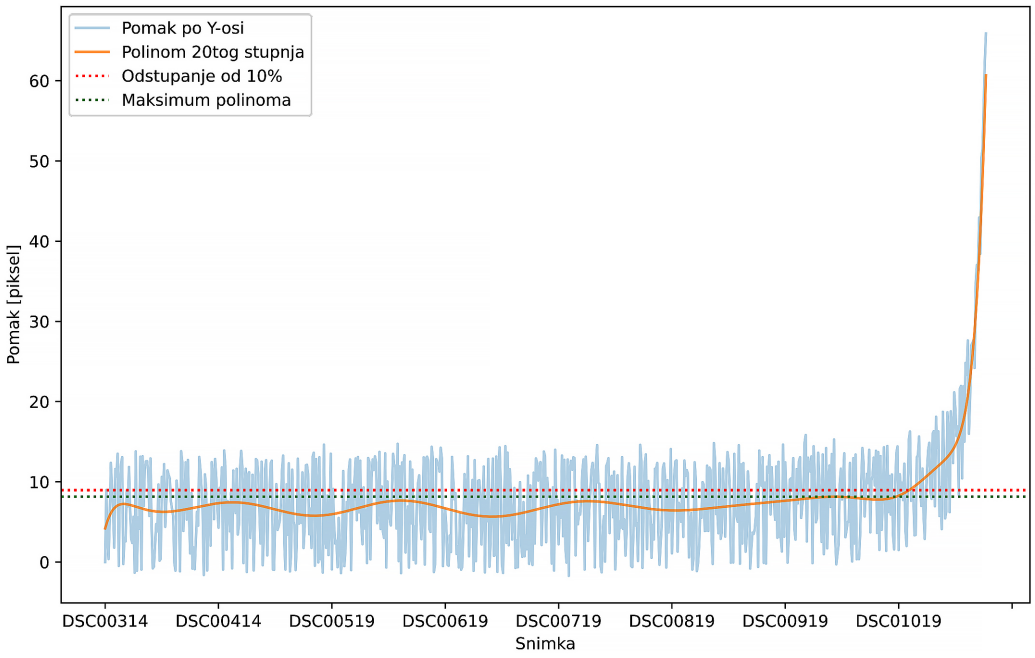
2.3. Ocjena točnosti

Kao ocjena točnosti uzeta je razlika između broja ciklusa na snimci koja odgovara kritičnoj vrijednosti odstupanja i broj ciklusa preuzet iz metode određivanje otvaranja pukotine na temelju pomaka čeljusti hidraulične preše (Fuštar i dr., 2022, Fuštar, 2023). Ocjena točnosti je radi jednostavnosti preračunata u postotak od ukupnog broj ciklusa za pojedini uzorak.

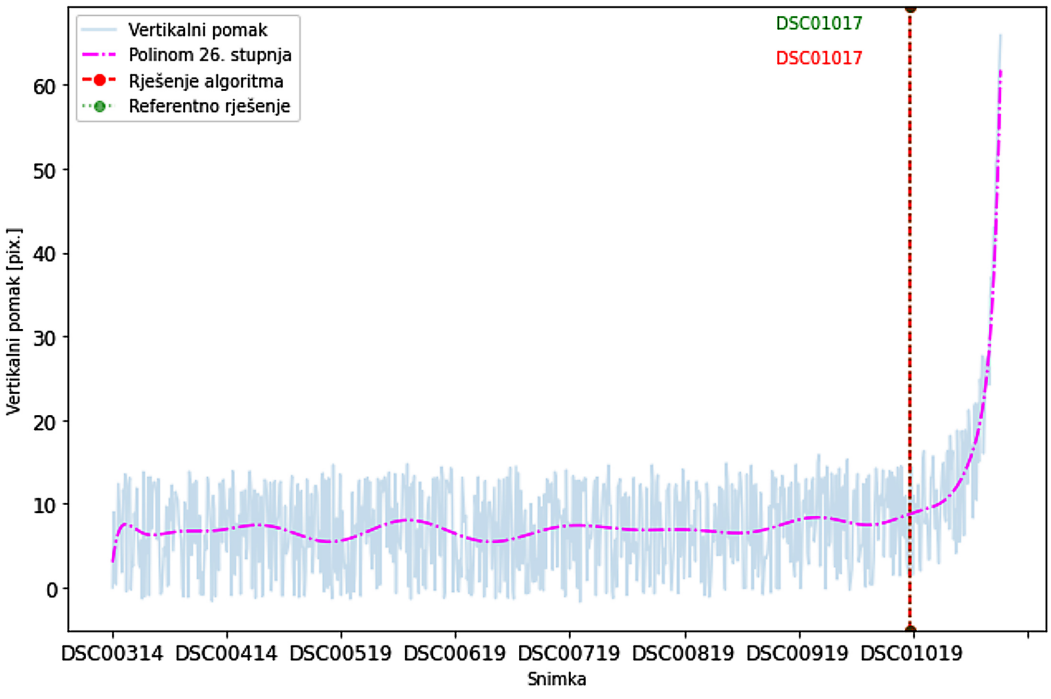
3. Rezultati

Na Slici 5 vizualiziran je korak traženja rješenja pomoću kritične vrijednosti odstupanja vrijednosti podataka od vrijednosti maksimuma polinoma kojom se podaci pomaka uzorka modeliraju. Na Slici 6 prikazano je konačno rješenje algoritma i referentno rješenje navedeno u poglavlju ocjene točnosti algoritma.

Ocjena točnosti dana je kao razlika između broja ciklusa na snimci koja odgovara kritičnoj vrijednosti odstupanja i broj ciklusa preuzet iz metode određivanje otvaranja pukotine na temelju pomaka čeljusti hidraulične preše (Fuštar i dr., 2022, Fuštar i dr., 2022, Fuštar, 2023) preračunata u postotak. Za prikazani uzorak, preliminarni rezultati razlike bili su manji od 0,10% što ukazuje na vrlo dobro rješenje obzirom na ukupni broj ciklusa koji se kretao na razini većoj od 125000.



Slika 5: Vizualizacija kritične vrijednosti odstupanje od maksimuma polinoma 20. stupnja uzorka (Radić, 2024).



Slika 6: Vizualizacija rješenja za uzorak (Radić, 2024).

4. Zaključak

Sumirajući korake rada, može se zaključiti da se metoda blizupredmetne fotogrametrije može primijeniti na gotovo sve aktivnosti koje zahtijevaju prostornu analizu. U ovom radu fokus je na primjeni u industrijskom okruženju koje zahtijeva visoku točnost i preciznost. Glavni motiv za primjenu fotogrametrije je njezina pristupačnost i jednostavnost korištenja. Odnos između potrebne opreme i točnosti konačnog rezultata izrazito je pozitivan. Razvoj algoritma kao što je ovaj automatizira proces dobivanja rješenja koja omogućuju analizu i izvlačenje zaključaka. Ovaj algoritam smanjuje ili eliminira potrebu za prisustvom stručnjaka u primjeni fotogrametrijskih metoda za različite namjene. Promicanjem korištenja fotogrametrijskih metoda razvija se sve više ovakvih algoritama koji su bazirani na otvorenom kodu i dostupni su svima, a kako se njihova upotreba bude povećavala, ti će algoritmi postajati sve učinkovitiji i automatiziraniji.

Literatura

Egger, J. E., Rojas, F. R., Massone, L. M. (2021). High-strength reinforcing steel bars: Low cycle fatigue behavior using rgb methodology. International Journal of Concrete Structures and Materials, 15(1), 1-13.

Fuštar, B., Lukačević, I., Skejić, D., Gašparović, M. (2022). Fatigue tests of as-welded and HFMI treated S355 details with longitudinal and transverse attachments. Welding in the World, 66(12), 2549-2561.

Fuštar, B. (2023). Procjena životnoga vijeka kod umora zavarenih čeličnih konstrukcijskih detalja obrađenih metodom mehaničkoga udara visokom frekvencijom. Doktorska disertacija, Sveučilište u Zagrebu, Građevinski fakultet, Zagreb.

Gašparović, M., Radić, F., Lukačević, I., Fuštar, B. (2024). Algorithm for fatigue crack initiation assessment based on Industrial photogrammetry. Rad u postupku objavljivanja.

Luhmann, T. (2010). Close range photogrammetry for industrial applications. ISPRS journal of photogrammetry and remote sensing, 65(6), 558-569.

Radić, F. (2024). Razvoj algoritma za potrebe industrijske fotogrametrijske izmjere, Diplomski rad, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb.

Shufrin, I., Pasternak, E., Dyskin, A. V. (2016). Deformation analysis of reinforced-core auxetic assemblies by close-range photogrammetry. physica status solidi (b), 253(7), 1342-1358.

URL 1: Open CV: https://opencv.org, (30.05.2024.).

Development of an Algorithm for the Needs of Industrial Photogrammetry

Abstract

Material fatigue can be described as damage to structural elements or structure by crack initiation and propagation caused by frequent stress repetition. To design new structures or fatigue life assessment of existing structures, fatigue tests are carried out in which the structural detail or the entire structure is subjected to repetitive tensile, compressive or shear stress. The paper deals with the development of an algorithm for the field of industrial photogrammetric measurement using computer libraries for image processing. The work aims to develop an algorithm for detecting the fatigue crack initiation period. The possibilities of determining the crack initiation period of one or more cracks will be determined using the method of determining the connection points determined on all imageries. By using the methods of radiometric processing and the application of convolutional filters in the preparation and post-processing of the images, the crack initiation period and size of the crack will be mapped and measured. The purpose of this work is to create an algorithm that can be applied to several areas of fatigue testing where the goal is to determine the crack initiation period and crack size using images obtained by close-range photogrammetry methods. The basis of the work is the processing of images resulted from fatigue tests of welded steel structural details presented in the work of Fuštar et al., 2022.

Keywords*: close-range photogrammetry, industrial photogrammetry, OpenCV, fatigue*

Urbanizacija i klimatske promjene: Analiza kretanja površinske temperature u Gradu Splitu (2013.–2022.) primjenom satelitskih podataka

Marina Tavra[1], Ivan Racetin[1] i Josip Peroš[1]

[1] Fakultet građevinarstva, arhitekture i geodezije u Splitu, Matice Hrvatske 15, Split, Hrvatska, tavramarina@gmail.com, ivan.racetin@gradst.hr, josip.peros@gradst.hr

Sažetak

Grad Split u Republici Hrvatskoj, kao i mnogi drugi gradovi diljem svijeta, suočava se s izazovima urbanizacije i klimatskih promjena. Da bi se razumjelo kako ove promjene utječu na lokalnu klimu i životnu sredinu, provedena je analiza površinske temperature (LST - eng. Land Surface Temperature) u Splitu tijekom desetogodišnjeg razdoblja od 2013. do 2022. godine. Korištenje geoinformatičkih tehnologija u ovom istraživanju daje uvid u trendove i promjene površinske temperature, pružajući temelje za održivo urbano planiranje i prilagodbu klimatskim promjenama. Analiza je temeljena na podacima prikupljenim satelitima Terra i Aqua, opremljenim slikovnim spektroradiometrom umjerene rezolucije (MODIS – eng. Moderate Resolution Imaging Spectroradiometer) i to 8-dnevnim MODIS LST proizvodima. Rezultati ovog istraživanja pokazali su trend porasta prosječne godišnje površinske temperature u Gradu Splitu tijekom promatranog razdoblja. Kroz rad prikazana je primjena geoinformatičkih tehnologija u svrhu omogućavanja uvida u prostorne i vremenske promjene površinske temperature. Ovi podaci mogu se upotrijebiti pri razvoju strategija i alata koje će pomoći gradovima da se prilagode klimatskim promjenama i smanje negativne učinke urbanizacije. Pored toga, prikazani rezultati mogu se koristiti i u razvoju strategija za održivo urbano planiranje i prilagodbu klimatskim promjenama, u skladu s ciljevima Agende 2030 za održivi razvoj.

Ključne riječi: *klimatske promjene, površinska temperatura, urbano planiranje*

1. Uvod

Urbanizacija i klimatske promjene postaju sve značajniji izazovi za gradove diljem svijeta, uključujući Grad Split u Republici Hrvatskoj. Da bi se razumjelo kako ove promjene utječu na lokalnu klimu i okoliš, provedena je detaljna analiza površinske temperature (LST – eng. Land Surface Temperature) u Splitu tijekom desetogodišnjeg razdoblja od 2013. do 2022. godine.

Korištenje geoinformatičkih tehnologija u ovom istraživanju omogućuje uvid u trendove i promjene površinske temperature, pružajući temelje za održivo urbano planiranje i prilagodbu klimatskim promjenama. Analiza je temeljena na podacima prikupljenim satelitima Terra i Aqua, opremljenim slikovnim spektroradiometrom umjerene rezolucije (MODIS – eng. Moderate Resolution Imaging Spectroradiometer) (Justice i dr., 2002). U ovoj analizi korišteni su 8-dnevni MODIS LST proizvodi te podaci spektralne površinske reflektance (Wan, 2008). Satelitski podaci omogućuju sistematično praćenje promjena površinske temperature u pravilnim prostornim i vremenskim razmacima, pružajući time podatke za proučavanje trendova promjena površinske temperature u prostornoj i vremenskoj domeni (Li i Becker, 1993).

Rezultati ovog istraživanja pokazali su trend porasta prosječne godišnje površinske temperature u Gradu Splitu tijekom promatranog razdoblja. Povećanje površinskih temperatura u gradovima može povećati intenzitet i učestalost pojave urbanih toplinskih otoka (Rizwan, Dennis, i Liu, 2008). Kroz ovaj rad prikazana je primjena geoinformatičkih tehnologija za omogućavanje uvida u prostorne i vremenske promjene površinske temperature, što je ključno za razvoj strategija i alata koji će pomoći gradovima da se prilagode klimatskim promjenama i smanje negativne učinke urbanizacije (Grimmond, 2007). Također, prikazani rezultati mogu se koristiti kao podrška u razvoju strategija za održivo urbano planiranje i prilagodbu klimatskim promjenama, u skladu s ciljevima Agende 2030 za održivi razvoj (United Nations, 2015).

2. Materijali i metode

2.1. Geomorfološka i klimatska svojstva Grada Splita

Split je središte Splitsko-dalmatinske županije i drugi po veličini grad u Hrvatskoj, smješten je na Splitskom poluotoku u srednjoj Dalmaciji, prostire se na ukupnoj površini od 229,29 km^2, od čega kopneni dio

zauzima 79,83 km², a morski dio 149,46 km². Splitska obala, ukupno dugačka 66,67 km, dijeli se na 48,66 km kopnenog dijela i 18,01 km obale na otoku Čiovu (PPU, Sl.gl. Grada Splita br. 31/05, 38/20 i 46/20).

Geomorfološku strukturu ovog područja karakterizira raznolikost reljefa koja je rezultat njegove položaja između Jadranskog mora i Dinarida.

Splitski poluotok koji s otokom Čiovom zatvara Kaštelanski zaljev, oblikuje prirodni kontekst grada. Najistaknutije uzvisine su Marjan (178 m) koji dominira gradskom panoramom, planina Mosor (vrh Veliki Kabal, 1339 m) na sjeveroistoku, i Kozjak (Veli vrj, 780 m) na sjeverozapadu. Marjan, kao "pluća grada", predstavlja značajnu ekološku i kulturnu vrijednost. Ovaj zaštićeni park-šuma nije samo važan za rekreaciju i turizam, već ima ključnu ulogu u očuvanju biološke raznolikosti i ekološke ravnoteže u urbanom okruženju Splita. Planinski masivi Mosor i Kozjak, s bogatstvom okolnih otoka, pružaju dodatnu dimenziju prirodne i kulturne baštine ovog područja.

Split je podijeljen u dvije glavne funkcionalne cjeline: obalnu, koja uključuje naselja Slatine, Split, Stobreč, Kamen i Žrnovnicu, te zaobalnu, koja obuhvaća Srinjine, Sitno Donje i Sitno Gornje. Urbani prostor Splita obuhvaća 27,5 km², dok ostala naselja zauzimaju 52,3 km² (PPU, Sl.gl. Grada Splita br. 31/05, 38/20 i 46/20).

2.2. Klimatska obilježja

Split se odlikuje tipičnom mediteranskom klimom, prema Köppenovoj klasifikaciji označenom kao Csa/Cfa. Ovo se ogleda u vrućim, umjereno suhim ljetima i blagim, vlažnim zimama. Prosječna godišnja temperatura iznosi oko 16°C, što doprinosi ugodnom životnom okruženju.

Zime u Splitu su obično blage, s prosječnom temperaturom u siječnju od oko 5°C. Snijeg je rijedak, ali 2012. godine Split je doživio neobično veliku količinu snijega, što je pokazalo kako ekstremni vremenski uvjeti mogu utjecati na grad. Ljeta su, s druge strane, vruća s prosječnim temperaturama oko 30°C u srpnju. Split godišnje uživa u više od 2600 sunčanih sati, što ga čini idealnom destinacijom za turiste i lokalno stanovništvo.

Oborine su raspoređene tijekom cijele godine s prosječnom godišnjom količinom od oko 820 mm. Studeni je najvlažniji mjesec, dok je srpanj najsuši. Bura i jugo, vjetrovi karakteristični za ovu regiju, imaju značajan utjecaj na lokalne vremenske uvjete, posebice u zimskim mjesecima (Mariani, 2023).

2.3. Slikovni spektroradiometar umjerene rezolucije – MODIS

Slikovni spektroradiometar umjerene rezolucije - MODIS (eng. Moderate Resolution Imaging Spectroradiometer) ključni je instrument na satelitima Aqua (izvorno poznat kao EOS PM-1, slika 1) i Terra (izvorno poznat kao EOS AM-1) (NASA, 2023). Satelit Terra lansiran je 18. prosinca 1999. godine, a satelit Aqua 4. svibnja 2002. godine. Sateliti se nalaze na visini od 705 km u približno polarnoj, Sunčevoj sinhronoj orbiti. Terrina orbita osmišljena je tako da gibajući se od sjevera prema jugu prolazi preko ekvatora ujutro, dok Aqua prolazi preko ekvatora u popodnevnim satima gibajući se od juga prema sjeveru. U ovoj konstelaciji MODIS ima širinu vidnog pojasa od 2330 km, što mu omogućuje snimanje cijele površine Zemlje svakih jedan do dva dana.

S obzirom na sve navedeno, MODIS igra važnu ulogu u razvoju validiranih, globalnih i interaktivnih modela sustava Zemlje koji mogu predvidjeti globalne promjene sa svrhom da pomognu donositeljima politika u donošenju dobrih odluka koje se tiču zaštite i očuvanja okoliša.

2.4. Određivanje površinske temperature

Određivanje površinske temperature – LST (eng. Land Surface Temperature) iz MODIS podataka predložio je MODIS-ov znanstveni tim u obliku dnevnih i noćnih globalnih zemljanih proizvoda rezolucije 1km, uključujući izvedene proizvode na nižim vremenskim frekvencijama i prostornim rezolucijama. Termalni infracrveni zapis očitan na satelitskom senzoru određen je temperaturom površine, emisivnošću/reflektivnošću površine i atmosferskim utjecajem na termalno zračenje s površine (uključujući emisiju, apsorpciju i raspršenje), te djelovanje sunčeve radijacije tijekom dana. LST se može odrediti iz podataka MODIS-ovih termalnih kanala za cijelu kopnenu površinu Zemlje, uključujući zimzelene i listopadne šume, grmlje, usjeve i livade, unutarnje vodene površine, snijeg i led, površine s izloženim tlom, pijeskom i stijenama, te urbana područja.

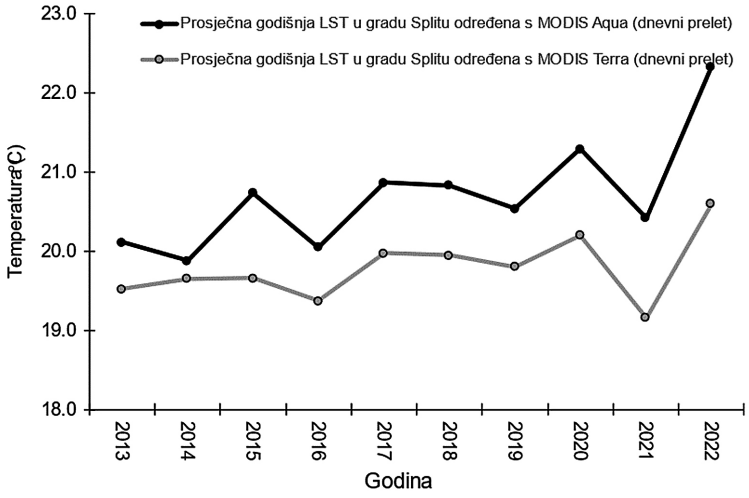
U ovoj analizi su upotrijebljeni 8-dnevni proizvodi oznake MOD11A2 i MYD11A2 iz kolekcije 6.1 MODIS proizvoda (NASA, 2019) rezolucije 1 km. Proizvodi s oznakom MOD odnose se na podatke satelita Terra, a MYD na podatke satelita Aqua.

3. Površinska temperatura u gradu Splitu u periodu 2013.-2023.

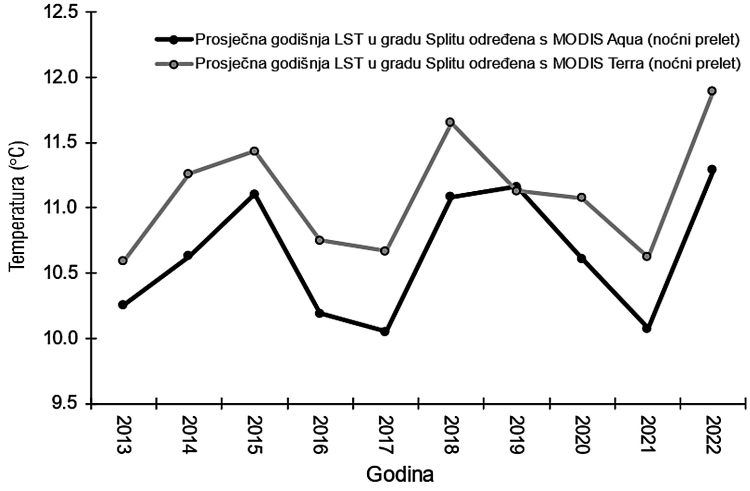
U ovom poglavlju prikazan je hod površinske temperature (LST) na području grada Splita u desetogodišnjem periodu od početka siječnja 2013. godine do kraja prosinca 2022. godine. Ulazni podaci koji su analizirani su MODIS LST 8-dnevni proizvodi prikupljani s prostornom rezolucijom od 1 kilometra, koji su u analizi usrednjeni na godišnje vrijednosti.

3.1. Analiza kretanja prosječne godišnje LST u gradu Splitu

U promatranom razdoblju od 2013. do 2022. godine, prosječna godišnja LST u gradu Splitu kretala se u rasponu od 19,16°C koji su zabilježeni u 2021. godini na podacima sa satelita Terra, do najviših 22,33°C koji su zabilježeni u 2023. godini na podacima sa satelita Aqua tokom dnevnih preleta (Slika 1). U svim promatranim godinama prosječna godišnja LST bila je veća na podacima MODIS Aqua u odnosu na podatke



Slika 1. Prosječne godišnje LST u gradu Splitu određene pomoću MODIS Aqua i MODIS Terra tokom dnevnih preleta



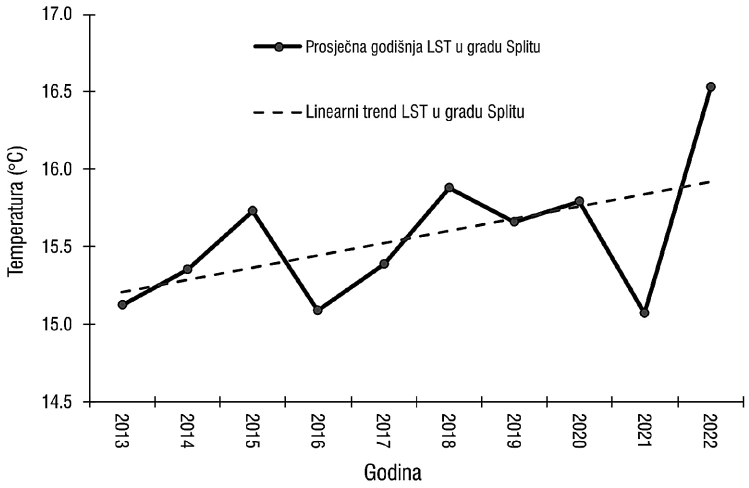
Slika 2. Prosječne godišnje LST u gradu Splitu određene pomoću MODIS Aqua i MODIS Terra tokom noćnih preleta

MODIS Terra instrumenta. Prosječna godišnja LST u dnevnom preletu za period 2013.-2022. na području grada Splita iznosila je 20,71°C za MODIS Aqua te 19,79°C za MODIS Terra. Ovakva distribucija je u skladu s očekivanjima s obzirom da Aqua prelijeće grad Split oko 13 sati, a Terra oko 10 sati po lokalnom vremenu. Standardno odstupanje godišnjih LST vrijednosti za dnevni prelet u promatranom periodu veće je za MODIS Aqua nego za MODIS Terru te iznosi 0,68°C odnosno 0,40°C.

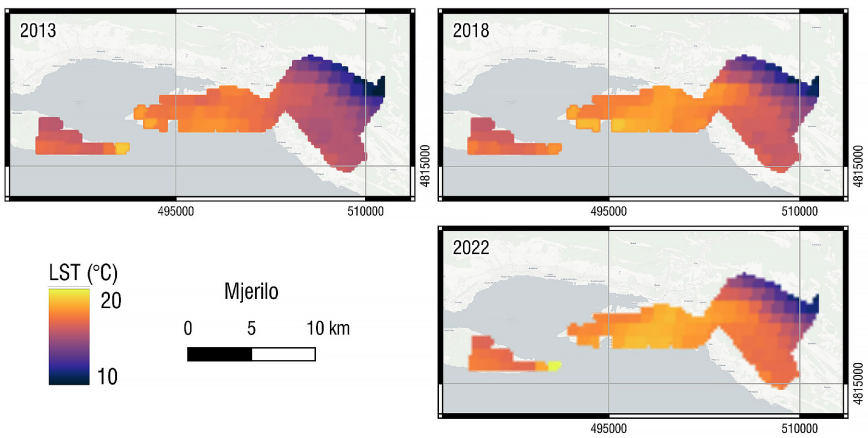
Prosječna godišnja LST u gradu Splitu u noćnim preletima kretala se od najnižih 10,05°C u 2017. godini (MODIS Aqua) do 11,89°C u 2022. godini (MODIS Terra) (Slika 2). Izuzev 2019. godine, više vrijednosti prosječne godišnje LST u noćnom preletu zabilježene su u na MODIS Terra podacima u odnosu na MODIS Aqua. U 2019. godini razlika određenih LST vrijednosti iznosila je 0,03°C što predstavlja malen iznos i može se zanemariti. MODIS Terra prelijeće područje grada Splita oko 21 sat, a MODIS Aqua oko 2 sata iza ponoći po lokalnom vremenu. Prosječno standardno odstupanje LST u noćnom preletu za period od 2013. do 2022. godine na području grada Splita iznosila je 0,46°C (MODIS Aqua) i 0,43°C (MODIS Terra).

Usrednavanjem dnevne i noćne prosječne godišnje LST vrijednosti za MODIS Aqua i Terra (Slika 1 i Slika 2) određena je jedinstvena vrijednost za svaku promatranu godinu (Slika 3). Pored toga, određen je linearni trend kretanja LST na temelju prosječnih godišnjih LST vrijednosti u promatranom periodu za područje grada Splita (Slika 3). Izrađene su tematske karte godišnjih LST na području grada Splita (Slika 4) te karte temperaturnih razlika površinske temperature u odnosu na početnu 2013. godinu (Slika 5). Iako je najniža LST od 15,07°C zabilježena u 2021. godini, zabilježen je pozitivan trend porasta LST. Najviša vrijednost LST od 16.53°C zabilježena je u godini iza, ujedno i posljednja analizirana godina. Prosječna LST

na području grada Splita u periodu od 2013. do 2022. godine iznosila je 15,56°C, a pripadajuće standardno odstupanje iznosilo je 0,43°C. Linearni trend određen na temelju prikazanih podataka na slici 4 pokazao je pozitivan prirast LST na području grada Splita od 0,08°C godišnje.

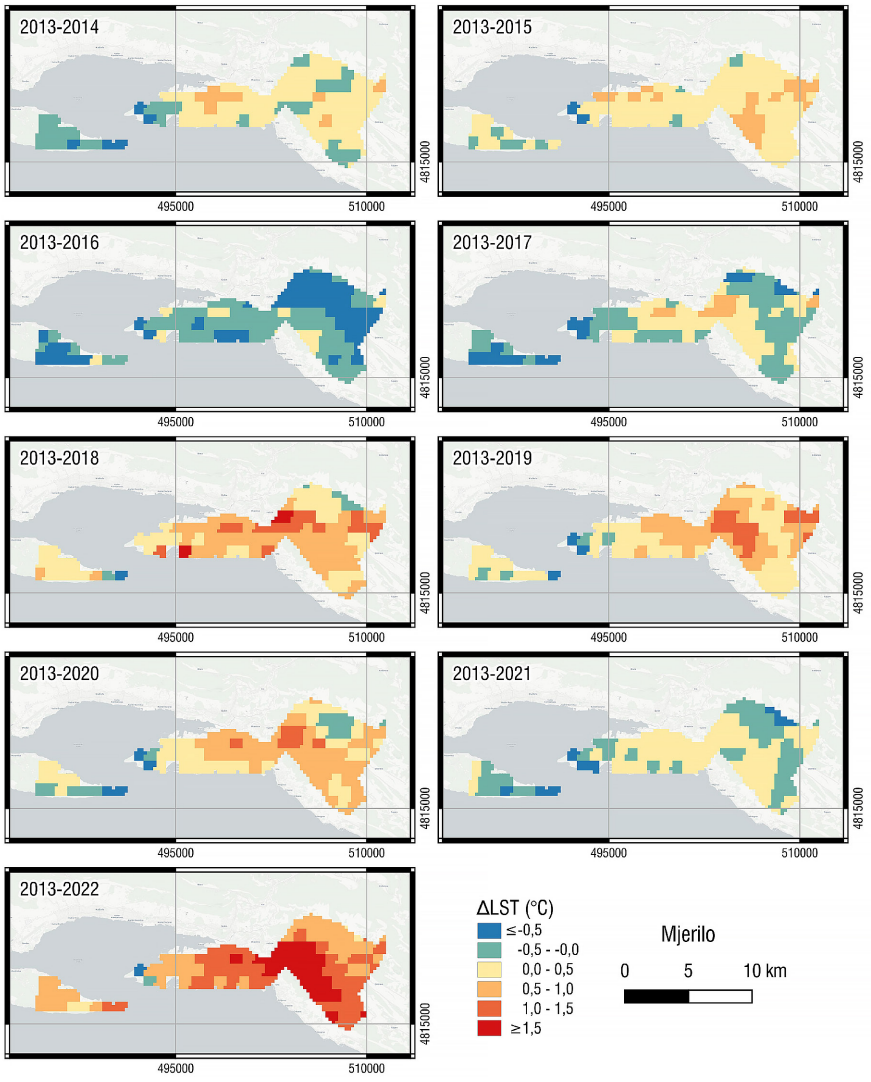


Slika 3. Prosječne godišnje LST u gradu Splitu određene usrednjavanjem dnevnih i noćnih MODIS Aqua i MODIS Terra podataka te pripadajući linearni trend gibanja LST.



Slika 4 Tematske karte prosječne godišnje LST u gradu Splitu određene usrednjavanjem dnevnih i noćnih MODIS Aqua i MODIS Terra podataka.

17. SIMPOZIJ OVLAŠTENIH INŽENJERA GEODEZIJE
Praktična znanja budućnosti u geodeziji i geoinformatici
23.-26. listopada 2024.
Poreč, Hotel Parentium



Slika 5 Tematske karte razlika prosječnih godišnjih LST u gradu Splitu u odnosu na početnu 2013. godinu.

4. Zaključak

Korištenjem geoinformatičkih tehnologija, poput MODIS satelitskih podataka, omogućeno je detaljno praćenje i analiza površinske temperature (LST) tijekom desetogodišnjeg razdoblja. Rezultati analize pokazali su porast prosječne godišnje površinske temperature u Gradu Splitu u iznosu od 0,08 C godišnje. Ovi podaci ističu važnost praćenja klimatskih promjena i njihovog utjecaja na urbane sredine, kao i potrebu za prilagodbom urbanog planiranja kako bi se smanjili negativni učinci. Prikazani rezultati mogu se koristiti kao temelj za razvoj strategija za održivo urbano planiranje i prilagodbu klimatskim promjenama, što je u skladu s ciljevima Agende 2030 za održivi razvoj. Daljnje istraživanje i praćenje ovih trendova ključno je za razumijevanje dugoročnih učinaka urbanizacije i klimatskih promjena te za izradu učinkovitih mjera za poboljšanje kvalitete života u urbanim sredinama.

Zahvala / Acknowledgment

Ovo istraživanje je djelomično sufinancirano kroz projekt KK.01.1.1.02.0027, koji je sufinanciran od strane Hrvatske Vlade i Europske Unije kroz European Regional Development Fund - the Competitiveness and Cohesion Operational Programme. Istraživanje je sufinancirano u sklopu Poziva za prijavu projekata/programa udruga iz područja zaštite okoliša od interesa za Grad Split za 2023. godinu kroz projekt Udruge Zeleni plan: Analiza površinske temperature i vegetacije na području grada Splita u periodu 2013.-2022.

Literatura

Grimmond, S. (2007): Urbanization and global environmental change: Local effects of urban warming, The Geographical Journal, 173, 83–88.

Justice, C. O., Townshend, J. R., Vermote, E. F., Masuoka, E., Wolfe, R. E., Saleous, N., Roy, D. P., Morisette, J. T. (2002): An overview of MODIS Land data processing and product status, Remote Sensing of Environment, 83, 3–15.

Li, Z.-L., Becker, F. (1993): Feasibility of land surface temperature and emissivity determination from AVHRR data, Remote Sensing of Environment, 43, 67–85.

McGlone, J. C. (2004): Manual of Photogrammetry, 5th ed., American Society for Photogrammetry and Remote Sensing, Bethesda.

Rizwan, A. M., Dennis, L. Y. C., Liu, C. (2008): A review on the generation, determination and mitigation of Urban Heat Island, Journal of Environmental Sciences, 20, 120–128.

United Nations (2015): Transforming our world: the 2030 Agenda for Sustainable Development, United Nations, New York.

Wan, Z. (2008): New refinements and validation of the MODIS Land-Surface Temperature/Emissivity products, Remote Sensing of Environment, 112, 59–74.

Kriegler, F.J., Malila, W.A., Nalepka, R.F., Richardson, W. (1969): Preprocessing

Mariani, B. (2023): Klimatska obilježja Republike Hrvatske: područje Dalmacije (Doctoral dissertation, University of Split. Faculty of Science. Department of Physics).

Prostorni plan uređenja Grada Splita (Sl.gl. Grada Splita br. 31/05, 38/20 i 46/20)

NASA (2019): Korisnički priručnik za proizvode iz MODIS kolekcije 6.1, https://lpdaac.usgs.gov/documents/715/MOD11_User_Guide_V61.pdf

NASA (1999): Teoretska osnova algoritma za određivanje LST iz MODIS podataka, https://modis.gsfc.nasa.gov/data/atbd/atbd_mod11.pdf

URL 1: NASA MODIS, https://modis.gsfc.nasa.gov, (16.6.2023.).

URL 2: NASA PACE, https://pace.oceansciences.org/images/history06_aqua.jpg, (16.6.2023.).

NASA. (16. studeni 2023). Dohvaćeno iz NASA PACE: https://pace.oceansciences.org/images/history06_aqua.jpg

NASA. (15. studeni 2023). NASA MODIS. Dohvaćeno iz https://modis.gsfc.nasa.gov/

Urbanization and Climate Change: Analysis of Land Surface Temperature Dynamics in Split (2013-2022) Using Satellite Data

Abstract

Urbanization and climate change pose major challenges to cities worldwide, including Split, Croatia. To understand the impact of these changes on the local climate and environment, a ten-year analysis (2013-2022) of land surface temperature (LST) in Split was conducted. By using geospatial technologies, this study offers insights into LST trends and fluctuations and provides information for sustainable urban planning and climate change adaptation strategies. The analysis is based on satellite data from the Terra and Aqua satellites equipped with the Moderate Resolution Imaging Spectroradiometer (MODIS). More specifically, the 8-day LST products from MODIS were used. Satellite data allows systematic monitoring of LST changes at regular spatial and temporal resolutions, which facilitates the investigation of LST trends in different spatial and temporal domains. The results reveal an increasing trend in mean annual LST in Split during the study period. This work demonstrates the application of spatial technologies to gain insights into spatio-temporal LST variations, which are crucial for the development of strategies and tools to help cities adapt to climate change and mitigate the negative impacts of urbanization. In addition, the results presented can inform sustainable urban planning and climate change adaptation strategies that are aligned with the Sustainable Development Goals (SDGs) of the 2030 Agenda.

Keywords: *climate change, surface temperature, urban planning*

4.

TEHNOLOGIJE SADAŠNJOSTI I BUDUĆNOSTI

Izrada geodetskih podloga za projektiranje linijskih infrastrukturnih građevina primjenom multisenzorskih snimanja

Momir Mitrović[1], Mladen Šoškić[2], Igor Nedeljković[3]

[1] MapSoft d.o.o., Ustanička 64, Beograd, momir@mapsoft.rs

[2] Građevinski fakultet u Beogradu, Bulevar kralja Aleksandra 73, Beograd, mladens@grf.bg.ac.rs

[3] MapSoft d.o.o., Ustanička 64, Beograd, igor@mapsoft.rs

Sažetak

Kvaliteta i brzina projektiranja linearnih infrastrukturnih građevina uvelike ovisi o istražnim radovima koji uključuju izradu geodetskih podloga. Proizvodnja podloga može se značajno poboljšati upotrebom multisenzorskih snimanja s mobilnih platformi. Poboljšanje se ogleda u skraćenju rokova izrade uz zadovoljenje svih aspekata točnosti i pouzdanosti izlaznih proizvoda. U radu je prikazana metodologija izrade geodetskih podloga krupnog mjerila kombiniranjem multisenzorskih snimanja. Metodologija je nastala kao rezultat rada na realizaciji desetaka kapitalnih projekata u posljednjih dvadesetak godina, u okviru kojih su izrađene geodetske podloge za projektiranje tisuća kilometara željezničkih pruga i cesta. Metodologija uključuje optimizaciju odabira hardverskih i programskih komponenti te njihovu prilagodbu i dodatni razvoj. Kako bi se maksimizirale performanse visokokvalitetnih senzora sustava, prvo je redizajnirana letjelica (zrakoplov), a tome je naknadno prilagođen način georeferenciranja i kontrole kvalitete sirovih podataka, kao i obrada podataka upotrebom posebno projektirane i razvijene profesionalne digitalne fotogrametrijske stanice za digitalnu stereorestituciju.

Ključne riječi*: aerofotogrametrija, digitalni model terena, digitalni topografski plan, geodetske podloge, LiDAR, linijske infrastrukturne građevine*

1. Uvod

Geodetske podloge čine prostornu osnovu za projektiranje linijskih infrastrukturnih građevina u svim fazama projektiranja. Kvaliteta i brzina izrade projekta linijske infrastrukture umnogome zavisi od kvalitete i brzine istražnih radova u koje ubrajamo i izradu topografskih podloga.

Projektanti uglavnom koriste vektorske podatke, tj. digitalne geodetske podloge u vidu CAD (engl. *Computer Aided Design*) crteža prije svega zbog toga što su i softverski alati za projektiranje nadogradnje standardnih CAD softvera. Zbog toga se i geodetske podloge prilagođavaju upotrebi u CAD softverima. Osnovne geodetske podloge čine digitalni topografski plan, digitalni model terena i ortofoto, ali pored toga i oblak točaka, 3D mesh, GIS (engl. *Geographic Information System*) baze podataka i BIM (engl. *Building Information Modeling*) modeli.

Svjedoci smo eksponencijalnog rasta mogućnosti tehnologije prostornog pozicioniranja, instrumenata za prikupljanje prostornih podataka i softvera i hardvera za njihovu obradu na osnovi kojih se izrađuju geodetske podloge. U današnje vrijeme pojednostavljeno je kombiniranje senzora i metoda prikupljanja prostornih podataka. Upravo optimizacija izbora senzora za snimanje i njihovo prilagođavanje specifičnostima prikupljanja prostornih podataka za potrebe projektiranja linijskih infrastrukturnih građevina, s kontrolom kvalitete s aspekta točnosti i količina podataka, predstavlja izazov u izradi geodetskih podloga za razne nivoe projektiranja.

Metodologija izrade geodetskih podloga prikazana u radu rezultat je rada na realizaciji desetina kapitalnih projekata u posljednjih dvadesetak godina, u okviru kojih su izrađene geodetske podloge za projektiranje tisuća kilometara željezničkih pruga i cesta. Kako bi se maksimizirale performanse visokokvalitetnih senzora sustava, prvo je redizajnirana letjelica (zrakoplov), a tome je naknadno prilagođen način georeferenciranja i kontrole kvalitete sirovih podataka, kao i obrada podataka upotrebom posebno projektirane i razvijene profesionalne digitalne fotogrametrijske stanice za digitalnu stereorestituciju.



Slika 1: Zrakoplov SILA 750 – specijalno projektiran za aerofotogrametrijsko snimanje

2. Multisenzorsko snimanje iz zraka

2.1. Platforma

Sustavi za snimanje iz zraka instaliraju se na različite vrste platformi u zavisnosti od potreba i obima projekta. Najčešće se koriste zrakoplovi, helikopteri, bespilotne letjelice, baloni itd. Prednost primjene zrakoplova i helikoptera u odnosu na bespilotne letjelice je u tome što imaju daleko veću autonomiju leta, mogu nositi sustave za snimanje veće mase, pa se njima mogu snimiti veća područja sustavima boljih performansi. Za manja područja upotreba bespilotnih letjelica je jeftinija, naročito u usporedbi s upotrebom helikoptera.

Uobičajena je praksa da se standardni tipovi zrakoplova i helikoptera posebno modificiraju kako bi se instalirala oprema za snimanje. U ovom slučaju je izabran drugačiji pristup. Naime, izvršeno je potpuno preprojektiranje zrakoplova SILA750 proizvođača AeroEastEurope kako bi se u potpunosti prilagodio potrebama instalacije raznih senzora i omogućilo efikasno snimanje malih i srednjih projekata.

Ključne karakteristike zrakoplova prilagođenog za multisenzorska snimanja su:

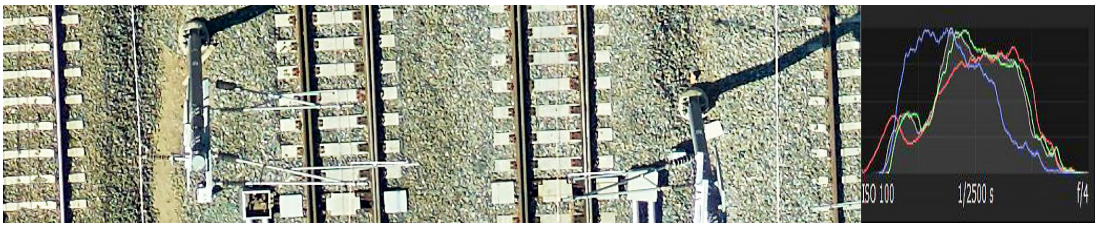
1. Prilagodba montiranju različitih senzora – upravljačke komande u zrakoplovu su sprovedene uz njegove bočne strane umjesto kroz sredinu što je uobičajeno u zrakoplovima. Na taj način omogućeno je otvaranje veće rupe u trupu zrakoplova nad kojom je jednostavna instalacija različitih senzora (slika 2 - lijevo). Izvršena je promjena centra letjelice kako bi bila osigurana nosivost i masa senzora (do 150 kg). Ugradnjom dodatnih alternatora omogućena je ugradnja aktivnih senzora koji su veliki potrošači struje.
2. Ekstremno dobre letačke karakteristike – instaliran je turbo motor visokih performansi i preprojektirana su krila kako bi se zadržala maksimalna brzina letenja (260 km/h), optimizirala brzina penjanja i ono što je najbitnije, postigla stabilnost letenja pri malim brzinama. Standardne radne brzine za ovaj tip letjelica su 180-220 km/h, a modificirana SILA 750 s opremom i posadom leti stabilno i pri 110 km/h. Ovo je izuzetno važno za dobivanje kvalitetnijih snimaka krupne rezolucije (do 2 cm), veće gustoće točaka laserskog skenera i bolje kvalitete geometrije trajektorije.
3. Autonomija leta do 9 sati – ugradnjom dodatnih rezervoara (slika 2 - desno) produžena je autonomija zrakoplova sa standardnih 4-5 sati na 8-9 sati. Jednom misijom letenja uz uobičajene postavke parametara snimanja moguće je pokriti približno od 4000 do 5000 hektara iz kojih je moguća izrada geodetskih podloga krupnih mjerila.
4. Upotreba bezolovnog benzina, mogućnost slijetanja i polijetanja s kratkih pista, autopilot, ...

2.2. Senzori

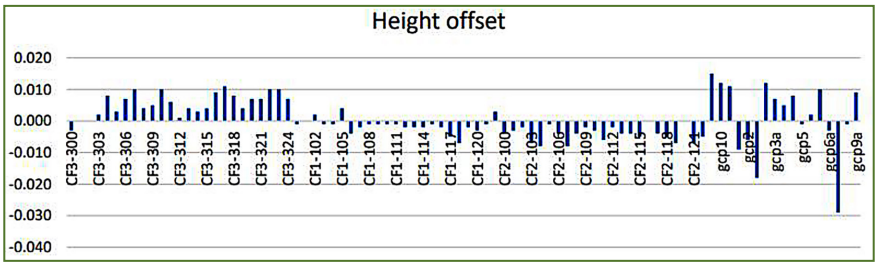
Sustav za multisenzorsko snimanje iz zraka uglavnom čine tri glavne komponente: aerofotogrametrijska kamera, LiDAR (engl. *Light Detection and Ranging*) uređaj i uređaj za navigaciju/pozicioniranje (Toth, 2016). Uz to, sustav često čine i drugi senzori kao što su NIR (engl. *Near-infrared*) i termalne kamere, hiperspektralni skeneri, itd, ali oni imaju manju primjenu u izradi geodetskih podloga za potrebe projektiranja linijskih infrastrukturnih građevina.



Slika 2: Zrakoplov SILA 750 – lijevo: rupa u trupu zrakoplova, sredina: kontrolna ploča, desno: dodatni rezervoar za gorivo



Slika 3: lijevo: Primjer dijela aerofotogrametrijskog snimka pruge Beograd – Novi Sad, desno: histogram aerofotogrametrijskog snimka



Slika 4: Grafički prikaz odstupanja oblaka točaka dobiven iz LiDAR skeniranja iz zrakoplova u odnosu na točke određene preciznom GNSS statičkom metodom

2.2.1. Aerofotogrametrijska kamera

U fotogrametriji se, naročito kod visoko preciznih radova, najčešće koriste mjerne kamere tj. kamere s poznatim geometrijskim osobinama (distorzija objektiva, žarišna daljina, glavna točka i sl.), s kontrolom ekspozicije (Schenk, 2005). Osim toga, bitne su i njihove radiometrijske osobine: dinamički raspon (engl. *Dynamic Range*), osjetljivost na svjetlo (engl. *Sensitivity*) i spektralna rezolucija. Kamere su obavezno geometrijski kalibrirane, a poželjna je i radiometrijska kalibracija čime se osigurava odnos između intenziteta svjetlosti u prirodi i digitalnih vrijednosti na slici. Za realizaciju projekata koridorskog tipa optimalna je upotreba kamera srednjeg formata (~ 50-150 MPix).

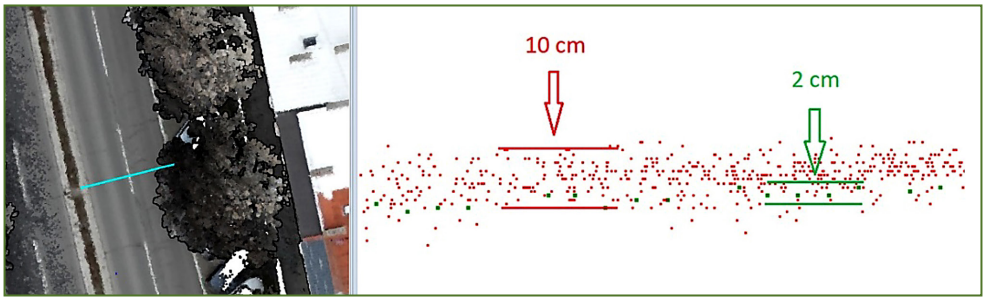
Na slici 3 je primjer dijela aerofotogrametrijskog snimka pruge i histogram slike iz kojih je vidljiva mogućnost interpretacije i najsitnijeg detalja, a da izvorni histogram pokazuje dobru osvijetljenost slike, dobar kontrast, dinamiku boja, itd.

2.2.2. LiDAR uređaj

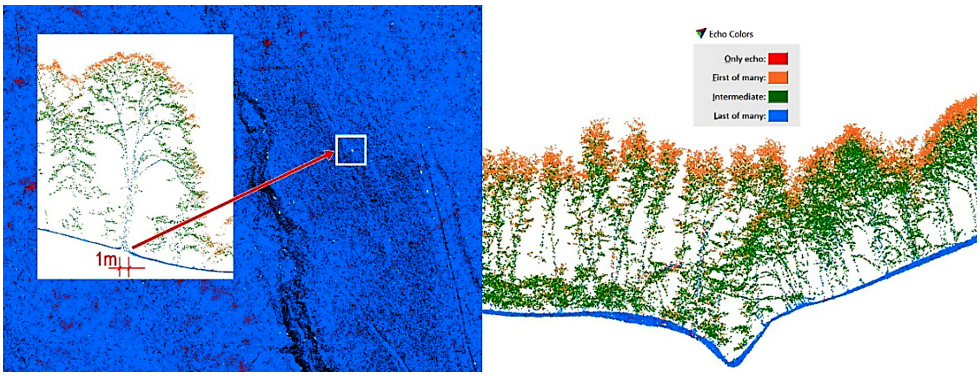
Danas na tržištu postoji veliki broj tipova LiDAR uređaja tako da je neophodno analizirati sve aspekte kvalitete uređaja i prema tome odabrati optimalni LiDAR uređaj za izradu geodetskih podloga krupnog mjerila. Osnovne osobine po kojima se određuje kvaliteta LiDAR uređaja su: točnost određivanja udaljenosti i 3D položaja točaka, domet mjerenja, frekvencija skeniranja, mogućnost registriranja više povratnih signala, divergencija laserske zrake, količina šuma u mjerenjima, horizontalni i vertikalni opseg skeniranja i stabilnost rada sustava tijekom vremena. Za izradu geodetskih podloga za potrebe projektiranja linijskih infrastrukturnih građevina najčešće se koriste LiDAR uređaji najviše klase. Kroz naredna tri primjera su ilustrirane neke od karakteristika visoko kvalitetnih LiDAR uređaja.

Na slici 4 prikazan je grafički prikaz odstupanja oblaka točaka dobiven iz LiDAR skeniranja iz zrakoplova za potrebe izrade digitalnih topografskih podloga za potrebe rekonstrukcije pruge Horgoš – Subotica u odnosu na točke mjerene preciznom GNSS (engl. *Global Navigation Satellite System*) statičkom metodom. Iz grafikona se može vidjeti da se visinska odstupanja kreću u rasponu od -2,8 cm do 1,5 cm.

Na slici 5 prikazano je prisustvo šuma u oblacima točaka koji se odnose na ravnu asfaltnu površinu, a koji su dobiveni iz dva različita snimanja. Oblak sa zelenim točkama dobiven je LiDAR skeniranjem iz zraka



Slika 5: Paralelni prikaz profila oblaka točaka dobivenih skeniranjem iz dva izvora na ravnoj asfaltnoj površini (*Teledyne Geospatial Galaxy T1000 – zeleno i DJI Zenmuse L2 – crveno)*



Slika 6: Prikaz penetracije laserskih zraka kroz gustu vegetaciju

upotrebom skenera najviše kvalitete (*Teledyne Geospatial Galaxy T1000*). Oblak s crvenim točkama dobiven je LiDAR skeniranjem upotrebom skenera opće primjene instaliranog na bespilotnoj letjelici (*DJI Zenmuse L2*). Primjetna je razlika u rasipanju točaka (*laser shot noise*), prije svega zbog slabije kvalitete laserskog skenera, ali i zbog lošijeg georeferenciranja. U oblaku dobivenom skeniranjem skenerom visoke klase s visine od 500 m, rasipanje točaka je do 2 cm, dok je kod lošijeg skenera, iako je let bio na 90 m, rasipanje točaka oko 10 cm.

Na slici 6 je dan primjer penetracije laserskih zraka usred guste Fruškogorske šume skenirane u doba godine s gustom vegetacijom za potrebe izrade topografskih podloga za izgradnju Državnog puta IB, dionica: Novi Sad – Ruma. Desna strana slike prikazuje sve točke oblaka gdje je različitim bojama prikazan prijem više signala od jednog poslanog (žuto - točke registrirane od prvog odbijenog signala, plavo - točke registrirane od zadnjeg odbijenog signala, zeleno - točke registrirane između prvog i zadnjeg odbijenog signala, crveno - točke koje su imale samo jedan povratni signal). Na slici 6 (lijevo i desno) vidi se gustoća točaka dobivenih odbijanjem od terena na osnovi čega se može zaključiti da praznine bez točaka terena nisu veće od nekoliko metara.

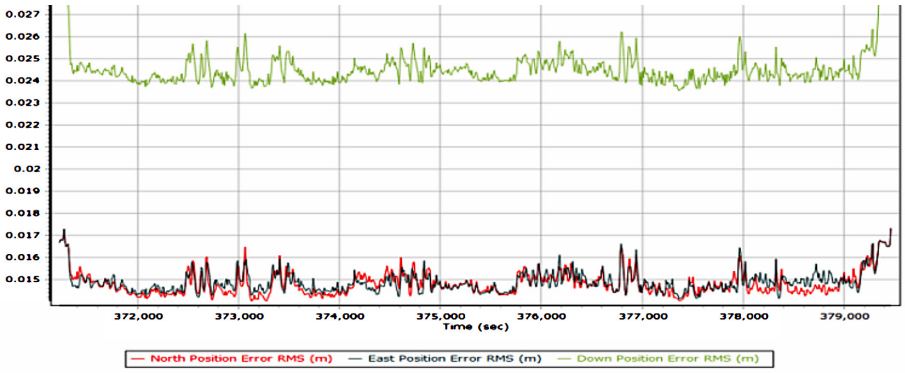
2.2.3.Uređaj za navigaciju/pozicioniranje

Uređaj za navigaciju/pozicioniranje služi za određivanje trajektorije kretanja LiDAR uređaja koja je neophodna za georeferenciranje prikupljenih podataka. Za određivanje trajektorije LiDAR uređaja koriste se GNSS/IMU (engl. *Inertial Measurement Unit*) uređaji (Pöppl, 2023). Kako bi se osigurala zahtijevana točnost potrebna je upotreba GNSS/IMU uređaja najviše klase koji mogu osigurati centimetarsku točnost georeferenciranja trajektorije.

Na slici 7 prikazan je grafikon točnosti određivanja pozicije trajektorije sukladno proteklom vremenu na projektu izrade geodetskih podloga za potrebe rekonstrukcije pruge Beograd-Niš, gdje je korišten sustav s Trimble Applanix AP-50 GNSS uređajem s integriranim Northman Grumman (ex Litton) LN-200 IMU uređajem. Iz grafikona se može zaključiti da je točnost geometrije stabilna tijekom protoka vremena, da je položajna točnost oko 1.5 cm, a visinska oko 2.5, što zadovoljava i najviše zahtjeve za georeferenciranje trajektorije.

2.3. Proces snimanja iz zraka

Proces snimanja započinje pažljivom analizom područja koje zahvaća projekt i ostalih specijalnih zahtje-



Slika 7: Grafikon položajne i visinske točnosti trajektorije zrakoplova u funkciji vremena tijekom snimanja na projektu izrade geodetskih podloga za potrebe rekonstrukcije pruge Beograd-Niš

Tablica 1: Standardna devijacija georeferenciranja snimaka na projektu rekonstrukcije željezničke pruge Pančevo – Subotica

	X [m]	Y [m]	Z [m]	Omega [mdeg]	Phi [mdeg]	Kappa [mdeg]
Srednja	0.012	0.012	0.009	1.9	1.8	0.8
Maksimalna	0.029	0.026	0.023	9.1	7.7	8.9
Minimalna	0.009	0.009	0.008	1.1	1.0	0.3

va projektanata tj. pojava u prirodi koje je neophodno detektirati na terenu i mapirati na geodetskim podlogama. Kao rezultat dobivaju se parametri multisenzorskog snimanja:

1. Parametri leta i to: optimalni pravci leta po dijelovima projekta, poprečni i uzdužni preklop aerofotogrametrijskih snimaka i poprečni preklop LiDAR redova, eventualno unakrsno letenje, itd.
2. Prostorna rezolucija snimaka,
3. Gustoća oblaka točaka,
4. Parametri laserskog skenera i to: optimalna veličina *footprinta* laserske zrake na zemlji, jačina laserske zrake, kut zahvaćanja laserskog skenera, itd…
5. Optimalno vrijeme za realizaciju plana snimanja, ograničenja letenja, itd.

Kao rezultat detaljne analize dobiva se plan snimanja koji je osnova za izradu plana leta zrakoplova i definiranje parametara za svaki od senzora.

Bez obzira na inicijalni obuhvat projekta preporuka je najprije izvršiti prikupljanje osnovnih podataka za šire područje. Iskustva pokazuju da je u cilju skraćenja vremena još u ranoj fazi projektiranja optimalno izvršiti inicijalno prikupljanje podataka multisenzorskim snimanjem iz zraka za širi teritorij projekta, što će kasnije omogućiti jednostavnu dopunu inicijalnih izrađenih geodetskih podloga. Inicijalno prikupljanje podrazumijeva pripremu za multisenzorsko snimanje, samo snimanje i georeferenciranje podataka, dok se izrada geodetskih podloga može kasnije izvoditi po prioritetnim područjima, u skladu s potrebama i zahtjevima.

2.4. Georeferenciranje

Prva faza prilikom izrade geodetskih podloga za potrebe projektiranja linijskih infrastrukturnih građevina je uspostavljanje jedinstvenog koordinatnog sustava inženjerskog objekta (datum). Ovo se mora definirati na samom početku svih geodetskih radova na ovakvim projektima, kako bi se svi kasnije prikupljeni podaci odnosili upravo na tako definirani referentni koordinatni sustav. Na ovaj način se, prije svega, rješava problem prostorne neuniformiranosti podataka u fazama istražnih radova, projektiranja, ali i kasnije izgradnje. Koordinate svih točaka za georeferenciranje oblaka točaka i aerofotogrametrijskih snimaka se određuju u koordinatnom sustavu inženjerskog objekta. S obzirom na zahtijevanu visoku točnost izlaznih produkata, točke za georeferenciranje oblaka točaka i aerofotosnimaka određuju se u koordinatnom sustavu inženjerskog objekta nekom od preciznih i pouzdanih metoda kao što su statička GNSS mjerenja ili mjerenja totalnom stanicom s točaka geodetske mreže inženjerskog objekta.

2.4.1. Georeferenciranje aerofotogrametrijskih snimaka

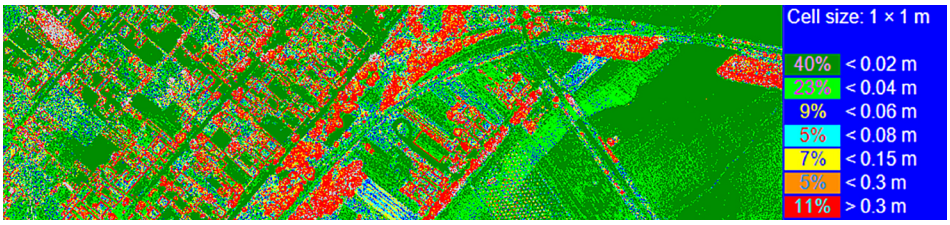
Georeferenciranje snimaka tradicionalno se izvodi korištenjem postupka aerotriangulacije bloka po metodi perspektivnih snopova (Ackermann, 2003), a u novije doba i korištenjem SfM tehnike (engl. *Structure from Motion*) (Schönberger, 2016). U oba slučaja koristi se određen broj točaka za koje se poznaju koordinate u ciljnom koordinatnom sustavu, automatski izmjeren veliki broj zajedničkih točaka na snimkama i podaci georeferencirane trajektorije uređaja.

U tablici 1 prikazani su rezultati izjednačenja bloka perspektivnih snopova aerofotogrametrijskih snimaka na projektu aerofotogrametrijskog snimanja obilaznice oko Beograda i Pančeva, sektor C od km 596+670 do km 627+650. Cjelokupna trasa projekta pokrivena je s 2017 snimaka za koje je određeno 18 orijentacijskih terenskih točaka za georeferenciranje (iskorištene su točke operativnog poligona koje imaju određene koordinate u koordinatnom sustavu objekta). Na osnovi priloženih podataka može se zaključiti da se na osnovi ovako georefenciranih aerofotogrametrijskih snimaka načelno mogu izrađivati topografske podloge u rangu kvalitete koja odgovara i najzahtjevnijim fazama projektiranja.

2.4.2. Georeferenciranje oblaka točaka

Osnovu za georeferenciranje oblaka točaka čini georeferencirana trajektorija sustava za snimanje iz zraka i sirovi LiDAR podaci. U nekim dijelovima se razlikuju postupci georeferenciranja oblaka točaka u zavisnosti od primijenjenog rješenja, ali osnovni koraci podrazumijevaju: izračun koordinata i ostalih atributa za svaku od točaka oblaka, izjednačenje bloka međusobno preklapajućih linija oblaka točaka uz eventualni postupak samokalibracije parametara sustava i na kraju kontrola kvalitete dobivenih rezultata usporedbom oblaka točaka s datim točkama, usporedbom geometrije susjednih linija oblaka točaka, kontrola gustoće točaka, itd. (Habib, 2007).

Na slici ispod prikazana je rasterska karta razlika visina susjednih linija oblaka točaka na njihovom preklopnom području. Iz karte se može vidjeti da se na tvrdim podlogama susjedni oblaci točaka razlikuju do 2-3 cm, a razlike su veće od 6 cm u područjima pod većom vegetacijom, zidovima zgrada i drugim objektima.



Slika 8: Rasterska karta razlika visina susjednih linija oblaka točaka na njihovom preklopnom području

3. Obrada podataka i vektorizacija elemenata geodetskih podloga

3.1. Obrada oblaka točaka

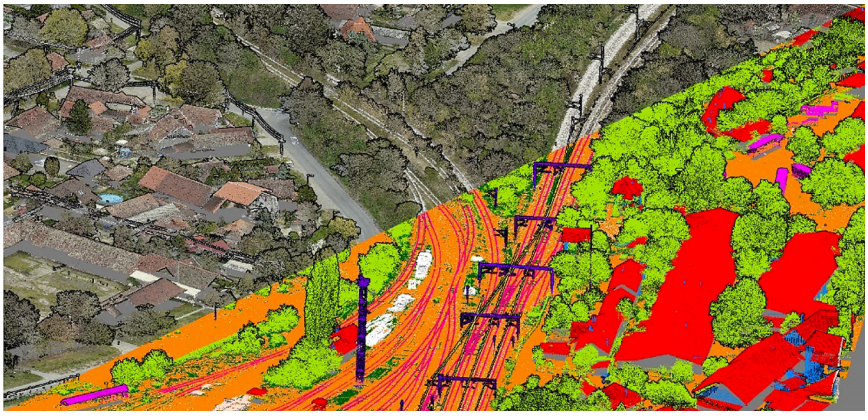
Proces klasifikacije oblaka točaka dobivenih LiDAR skeniranjem podrazumijeva dodjeljivanje određene kategorije ili klase svakoj točki na osnovi nekih njenih karakteristika. Sam proces klasifikacije zasniva se na analizi atributa prikupljenih još u fazi skeniranja multisenzorskim sustavom, kao što su intenzitet, broj odbitka, RGB (Red Green Blue) vrijednost i sl. ali i na osnovi rasporeda točaka i geometrijskih proračuna. Standard za klasifikaciju oblaka točaka definiran je od strane Američkog društva za fotogrametriju i daljinska istraživanja (*American Society for Photogrammetry and Remote Sensing - ASPRS*). ASPRS definira šest osnovnih klasa za klasifikaciju oblaka točaka: teren, niska, srednja i visoka vegetacija, objekti i vodene površine, a pored toga u zavisnosti od potreba projekta i klase niskonaponska mreža vodova, visokonaponska mreža vodova, stupovi električne mreže, ostali stupovi, mostovi, itd. (URL1).

Proces izrade topografskih podloga iz oblaka točaka počinje njegovom klasifikacijom. U zavisnosti od potrebne kvalitete topografskih podloga vrši se klasifikacija s određenom kvalitetom. Nekada je dovoljno primijeniti automatsko procesiranje oblaka točaka, a za najvišu kvalitetu je neophodna i dodatna ručna klasifikacija.

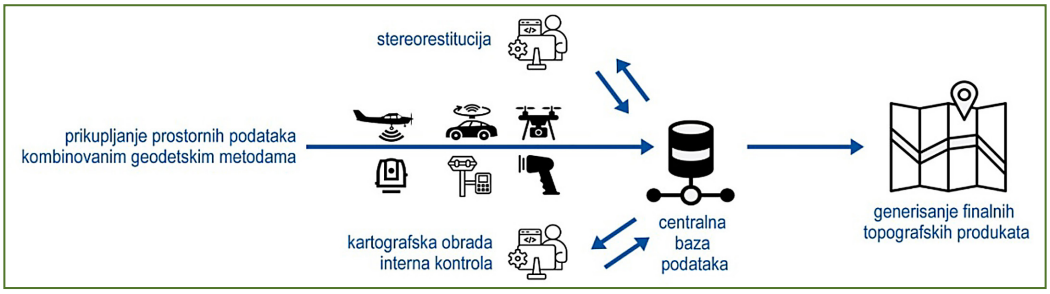
3.2. Izrada vektorskog sadržaja - digitalna stereorestitucija

S obzirom da projekti izrade geodetskih podloga za potrebe projektiranja linijskih infrastrukturnih građevina vrlo često podrazumijevaju izradu geodetskih podloga za veća područja s kratkim rokovima izrade što samim tim dovodi do izazova upravljanja većim količinama podataka uz udio većeg broja timova za prikupljanje i obradu podataka. posebna pažnja mora se voditi o upravljanju vektorskim podacima. Za ove potrebe razvijen je sustav upravljanja podacima tako što se svi prikupljeni podaci pohranjuju u jedinstvenu centralnu prostornu bazu podataka (Microsoft SQL Server ili Oracle baza podataka). Bez obzira na izvor i metodu prikupljanja podataka svi podaci se pohranjuju u centralnu bazu uz vođenje računa o redundantnosti podataka, da svi podaci imaju uz sebe metapodatke o izvoru, epohi i točnosti, a uz svaku definiranu geometriju čuva se i određeni broj tematskih atributa koji određuju tip podatka, način vizualizacije, podatak sudjeluje li geometrija u formiranju DMT-a (engl. *Digital Terrain Model*), itd (slika 10). Iz centralne baze se po potrebi u svakom trenutku mogu generirati izlazni produkti kao što su digitalni model terena, digitalni model reljefa, topografski planovi raznog sadržaja, itd. Ovim postupkom dobivaju se uniformne topografske podloge tijekom vremena, s minimalnim rizikom izrade topografskih podloga na osnovi neadekvatnih, neažurnih podataka.

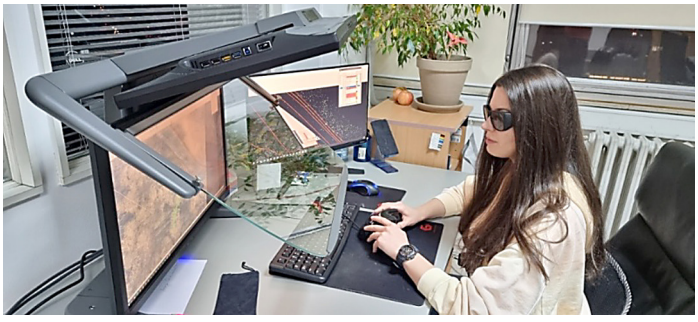
Osnovna metoda vektorizacije geometrijskog sadržaja geodetskih podloga je stereorestitucija na Pho-



Slika 9: Vizualizacija oblaka točaka: slika lijevo – prikaz po RGB atributima; slika desno – prikaz po klasama, projekt modernizacije pruge Subotica - Horgoš



Slika 10: Proces izrade digitalnih topografskih podloga

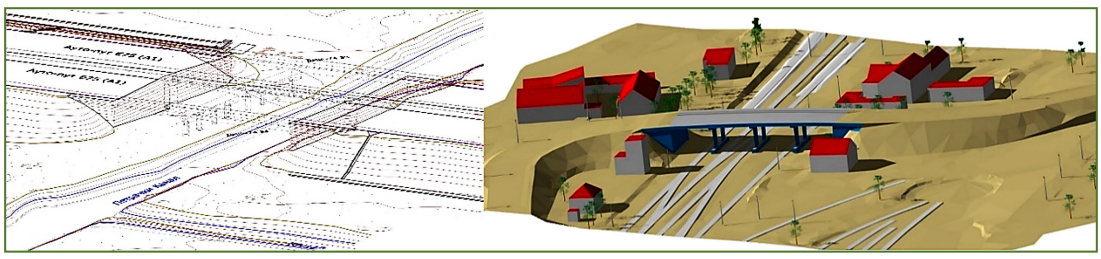


Slika 11: Digitalna fotogrametrijska stanica PhotoSoft

toSoft digitalnoj fotogrametrijskoj stanici (slika 11). Polazni podatci za rad s digitalnom fotogrametrijskom stanicom su georeferencirani aerofotogrametrijski snimci, klasificiran oblak točaka i eventualno sadržaj poluautomatske ili automatske vektorizacije dijela sadržaja na osnovi LiDAR oblaka točaka (elektro vodovi, itd.).

Kroz proces stereorestitucije korištenjem klasificiranog oblaka točaka restitutor vrši vektorizaciju u skladu s pravilima za određeno mjerilo kartiranja i dodatnim uputstvima projektantskih timova. Da bi se rad u Photosoftu olakšao i učinio efikasnijim, restitutoru su na raspolaganju brojne funkcionalnosti, a neke od važnih PhotoSoft funkcionalnosti su:

- Pojedinačno i grupno kartiranje – istovremeno kartiranje više geometrija (npr. stupova rasvjete kao točaka i vodova kao linija),
- Višekorisnički rad – omogućeno editiranje više korisnika istovremeno u intranet ili internet mreži,
- 3D stereoskopski prikaz na glavnom ekranu i okomiti prikaz vektora i rastera na pomoćnom ekranu,
- Promjena prikaza sadržaja na ekranu pomicanjem po prostoru i zumiranjem sadržaja
- Automatsko učitavanje optimalnog stereo modela u zavisnosti od položaja 3D kursora,
- Podrška za 3D miša,
- Napredni režimi snepiranja, geometrijskih i atributskih selekcija, velik broj COGO alata ili specijalizirani alata za konstrukcije,
- Rad s podacima digitalnog modela reljefa (dodatni alati tijekom prikupljanja, formiranje DTM-a, generiranje izohipsa, ...)



Slika 12: Primjer topografskog plana (lijevo: kombinacija 2.5 i 3D sadržaja, desno: 3D sadržaj)
PhotoSoft je razvijen kao samostalni Microsoft Windows desktop softver na bazi međunarodnih i industrijskih standarda i biblioteka kao što su: *OpenGIS Simple Features Access (SFA) specification*, *GDAL - Geospatial Data Abstraction Library*, *OpenGL (Open Graphics Library)*(Cvijetinović, 2011).

3.3. Detaljno dosnimavanje mikrolokacija i specifičnih detalja dopunskim geodetskim metodama

Sav ostali sadržaj koji je sastavni dio geodetskih podloga za projektiranje, kao što su konstrukcije mostova, propusti, podzemni prolazi, ostali podzemni objekti, detalji koji nisu mogli biti snimljeni dovoljnom točnošću ili pouzdanošću multisenzorskim snimanjem, treba snimiti dopunskim metodama kao što su: polarna metoda totalnim stanicama, GNSS metoda, lasersko skeniranje s automobila, lasersko skeniranje SLAM (engl. *Simultaneous Localization and Mapping*) tehnologijom, itd. i učitati u centralnu bazu podataka.

4. Zaključak

Iz rada se može zaključiti da se geodetske podloge za potrebe projektiranja infrastrukturnih linijskih građevina vrhunske kvalitete mogu izrađivati efikasno samo ukoliko se posebna pažnja posveti svakoj komponenti sustava i svakoj fazi izrade. Platforma za snimanje iz zraka može bitno utjecati na efikasnost prikupljanja podataka, ali i na kvalitetu prikupljenih podataka. Izrada potpuno prilagođene platforme za multisenzorsko snimanje iz zraka je složen i skup postupak, ali benefiti od takvog sustava su brojni: veći je opseg rada, jeftinije je snimanje, snimljeni podaci su kvalitetniji (veća gustoća oblaka točaka, bolja prostorna rezolucija snimaka), rezultati georeferenciranja prikupljenih podataka su bolji,... Osim toga, točnost, preciznost i pouzdanost prikupljenih podataka zavisi od izbora glavnih senzora sustava (LiDAR uređaj, aerofotogrametrijska kamera i sustav za pozicioniranje). S obzirom na zahtijevanu visoku kvalitetu izlaznih rezultata, odabir senzora i ostalih hardverskih komponenti sustava mora se izvesti pažljivo jer su hardverske komponente međusobno zavisne i loš odabir jedne od komponenti može umanjiti kvalitetu zahtijevanog krajnjeg rezultata.

Slično izradi platforme, tako se i softveri za prikupljanje podataka moraju u potpunosti prilagoditi ciljevima projekta. Centralna prostorna baza podataka kao glavni repozitorij za pohranu svih prikupljenih podataka i PhotoSoft kao glavni softver za vektorizaciju podataka omogućavaju učinkovito, istovremeno korištenje za više korisnika svih podataka jednog projekta čak i s izmještenih lokacija. Uz efikasne posebno razvijene alate u PhotoSoftu minimiziraju se mogućnosti izvora pogrešaka, nepotrebno ponavljanje nekih aktivnosti, povećava se efikasnost rada i kontrole nad podacima, što na kraju, uz prethodno navedeno, rezultira pouzdanim geodetskim podlogama visoke kvalitete, potpuno prilagođenih potrebama projektantskih timova, koje se po potrebi lako dopunjuju i proširuju.

Literatura

Ackermann, F., Krzystek, P. (2003): Complete Automation of Digital Aerial Triangulation, The Photogrammetric Record 15(89): 645 – 656

Cvijetinović, Ž. (2011): The Development of Modern GIS Based Digital Photogrammetric Workstation, International Scientific Conference and XXIV Meeting of Serbian Surveyors "Professional Practice and Education in Geodesy and Related Fields", 4, 497–505.

Habib, A., Van Rens, J. (2007): Quality Assurance and Quality Control of LiDAR Systemsand Derived Data

Pöppl, F., Neuner, H., Mandlburger, G. , Pfeifer, P. (2023): Integrated trajectory estimation for 3D kinematic mapping with GNSS, INS and imaging sensors: A framework and review, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 196, 287-305

Schenk, T. (2005): Introduction to photogrammetry. The Ohio State University, Columbus, 106(1).

Schönberger, J.,Frahm, J.-M., (2016): Structure-from-Motion Revisited, Conference Proceedings: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)

Toth, C. (2016): Remote sensing platforms and sensors: A survey, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 115, 22-36.

URL 1: ASPRS, https://www.asprs.org/wp-content/uploads/2010/12/LAS_Specification.pdf, (24.06.2024.).

Production of Geodetic Products for the Design of Linear Infrastructure Objects Using Multi-Sensor Measurements

Abstract

The quality and speed of designing linear infrastructure buildings largely depends on investigative works that include the creation of geodetic products. This production can be significantly improved by using multi-sensor measurements from mobile platforms. The improvement is reflected in the shortening of production periods while meeting all aspects of the accuracy and reliability of the output products. The paper presents the methodology of creating large-scale geodetic products by combining multi-sensor measurements. The methodology was created as a result of work on the realization of dozens of capital projects in the last twenty years, within which geodetic products were created for the design of thousands of kilometers of railways and roads. The methodology includes the optimization of the selection of hardware and software components and their adaptation and additional development. In order to maximize the performance of the system's high-quality sensors, the aircraft was first redesigned, and the method of georeferencing and quality control of raw data was subsequently adapted to this, as well as data processing using a specially designed and developed professional digital photogrammetric station for digital stereorestitution.

Keywords*: aerial photogrammetry, digital terrain model, digital topographic plan, geodetic products, LiDAR, linear infrastructure objects*

Porast srednje razine Jadranskog mora na Mareografskoj postaji Bakar

Antonio Tupek[1], Mladen Zrinjski[1], Krunoslav Špoljar[1], Barbara Galić[2], Karlo Stipetić[1], Iva Međugorac[3]

[1] Sveučilište u Zagrebu – Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, antonio.tupek@geof.unizg.hr, mladen.zrinjski@geof.unizg.hr, krunoslav.spoljar@geof.unizg.hr, karlo.stipetic@geof.unizg.hr

[2] Metković, Hrvatska, barbara.galic99@gmail.com

[3] Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Geofizički odsjek, Horvatovac 95, Zagreb, Hrvatska, ivamed@gfz.hr

Sažetak

U ovom radu prikazano je određivanje nadmorske visine srednje razine Jadranskog mora na geografskoj lokaciji Mareografske postaje Bakar. Također, prikazani su rezultati analize promjene, odnosno porasta srednje razine mora u odnosu na kopno u razdoblju od približno 75 godina. U cilju ove analize upotrijebljeni su nivelmanski podaci I. nivelmana visoke točnosti (INVT), II. nivelmana visoke točnosti (IINVT) i neovisne nivelmanske izmjere obavljene od strane Sveučilišta u Zagrebu – Geodetskog fakulteta 2023. godine te mareografski podaci dostupni u otvorenom znanstvenom repozitoriju SEANOE. Promjena, tj. porast srednje razine Jadranskog mora u razdoblju od 75 godina modelirana je linearnom regresijom.

Ključne riječi: *INVT, IINVT, Jadransko more, mareograf Bakar, srednja razina mora*

1. Uvod

More je u kontinuiranom gibanju uslijed mnogo različitih unutarnjih i vanjskih faktora. Pod pojmom „razina mora" najčešće se podrazumijeva srednja razina mora (engl. *mean sea level*) na određenoj lokaciji u određenom razdoblju promatranja, odnosno mjerenja. Uređaj koji kontinuirano mjeri visinu morske razine naziva se mareograf (engl. *tide gauge*). Dugogodišnja neprekidna mareografska mjerenja ukazala su na svu kompleksnost kontinuirane promjene razine mora (periodični i neperiodični utjecaji, kratkoročne i dugoročne promjene, sezonske, međugodišnje i godišnje oscilacije itd.) (Vilibić i dr., 2005).

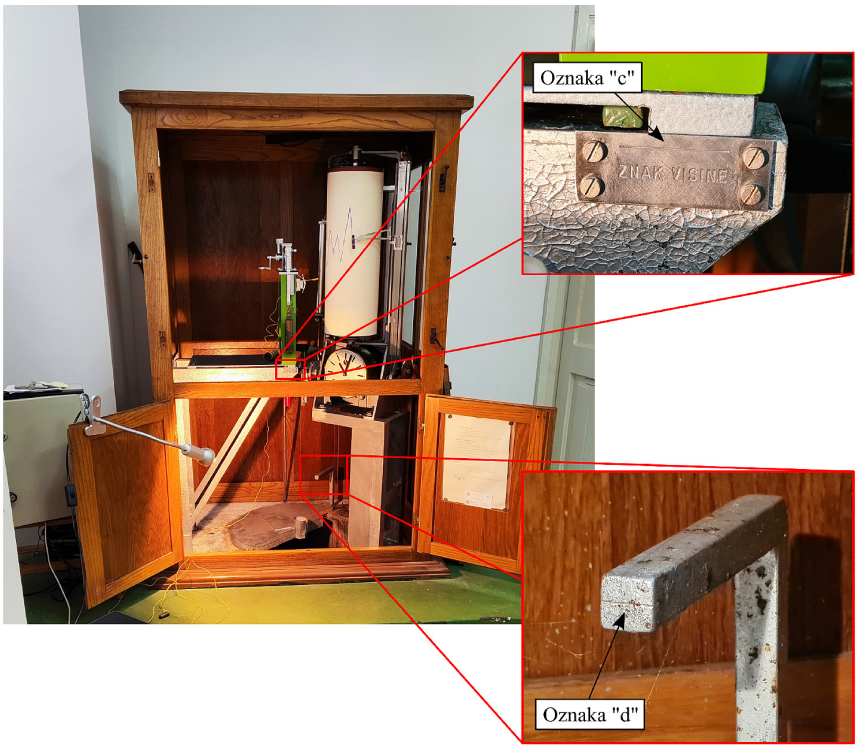
Određivanje srednje razine mora u glavnom nutacijskom periodu od 18,61 godine ključno je za realizaciju visinskoga referentnog sustava države (Rezo i dr., 2010, Rezo i dr., 2014). Tako određena srednja razina mora definira visinsku referentnu plohu visinskog sustava, odnosno ekvipotencijalnu nivo plohu gravitacijskog polja Zemlje.

Visinski referentni sustav Republike Hrvatske, punog naziva Hrvatski visinski referentni sustav – epoha 1971,5 (HVRS71), realiziran je povezivanjem na pet mareografa duž istočne obale Jadranskog mora, tj. na mareografe: Koper (Republika Slovenija), Rovinj, Bakar, Split i Dubrovnik (Republika Hrvatska) (Rožić, 2019). Hrvatski visinski datum – epoha 1971,5 (HVD71), odnosno ishodište visinskog sustava HVRS71, definiran je visinskim položajem srednje razine Jadranskog mora na navedenim mareografima u epohi 1971,5 godina.

Prethodna istraživanja pokazala su da se srednja razina Jadranskog mora, duž njegove istočne obale i u odnosu na kopno, uzdiže brzinom od približno 1 mm/god (Orlić i Pasarić, 1998). Motivirano navedenim podacima, obavljeno je, i u ovom radu prikazano, određivanje promjene srednje razine Jadranskog mora na Mareografskoj postaji Bakar. Određivanje nadmorske visine srednje razine Jadranskog mora obavljeno je na temelju dostupnih nivelmanskih i mareografskih podataka. U obradu i analizu uključeni su podaci I. nivelmana visoke točnosti (INVT) i II. nivelmana visoke točnosti (IINVT) te neovisna nivelmanska mjerenja obavljena od strane Sveučilišta u Zagrebu – Geodetskog fakulteta 2023. godine. U skladu s navedenim, definirane su tri epohe u kojima se određuje srednja razina Jadranskog mora na geografskoj lokaciji mareografa Bakar i to: 1949,0 (INVT), 1971,0 (IINVT) i 2023,9 (GEOF23). Trend promjene srednje razine mora određen je linearnim regresijskim modeliranjem.

2. Mareografska postaja Bakar

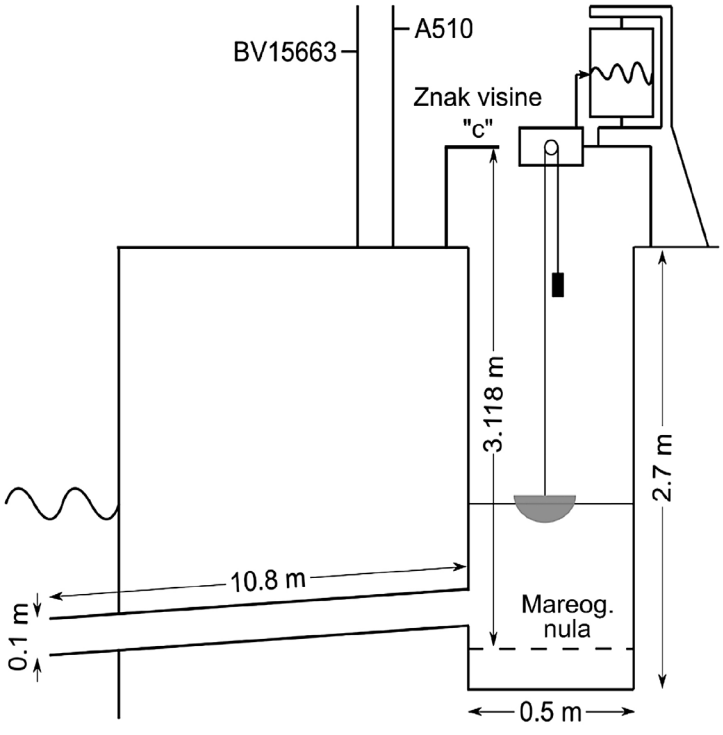
U Bakarskom zaljevu nalazi se najstarija hrvatska mareografska postaja – Mareografska postaja Bakar (Slika 1). Uspostavio ju je zagrebački Geofizički zavod 1929. godine na inicijativu i pod vodstvom akademika Stjepana Škreba (Volarić i dr., 1990). Postaja je radila do 1939. godine i, nakon prekida za vrijeme Drugoga svjetskog rata te obnove 1949. godine, praktički ne-



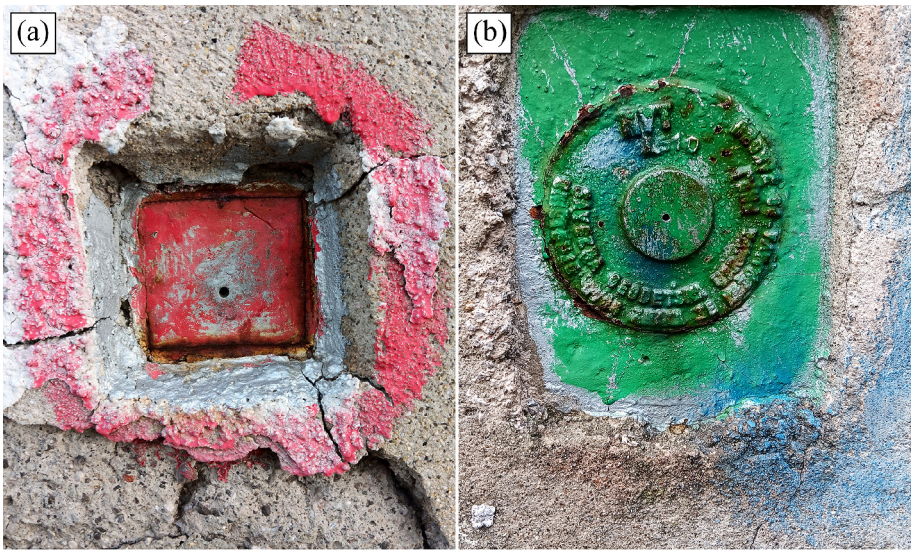
Slika 1: Mareografska postaja Bakar i oznake visina „c“ i „d“ mareografa (Zrinjski i dr., 2023)

prekidno radi do danas (Orlić i Pasarić, 1998). Zabilježeni mereografski podaci postaje Bakar predstavljaju najdulji vremenski niz jednog oceanografskog parametra u Republici Hrvatskoj (Međugorac i dr., 2022).

Mareograf Bakar (Slika 2) mehanički je tip mareografa. Smješten je uz zdenac dubine 2,7 m i promjera 0,5 m. Zdenac je spojnom cijevi duljine 10,8 m i promjera 0,1 m povezan s morem (Orlić i Pasarić, 1998).



Slika 2: Shematski prikaz Mareografske postaje Bakar (prema Međugorac i dr., 2022)



Slika 3: Referentni reperi horizontalno stabilizirani u neposrednoj blizini Mareografske postaje Bakar; a) reper BV 15663, b) reper A510 (Galić, 2024)

Takav dizajn ima za cilj filtriranje kratkoperiodičnih oscilacija perioda manjeg od 1 min (Međugorac i dr., 2022). U zdencu mareografa nalazi se plovak čije se dizanje i spuštanje, uslijed kolebanja razine mora, preko spojne žice i prijenosnog mehanizma prenosi na dijagramski papir u omjeru 1:5 (Orlić i Pasarić, 1998). Mareografska postaja modernizirana je početkom 2000-tih godina kada su instalirani digitalni instrumenti i GSM/GPRS modemi za dohvat podataka u realnom vremenu. Nadalje, u listopadu 2003. godine instaliran je i plovčani digitalni instrument koji pomake plovka mareografa pretvara u digitalne vrijednosti. Analogni i digitalni instrument mareografa bilježe razinu mora neovisno jedan od drugoga. Digitalni instrumenti bilježe jednominutne prosjeke razine mora i šalju ih na server Geofizičkog odsjeka PMF-a s intervalom od 15 minuta (Međugorac i dr., 2022).

Na zgradi u kojoj je smještena Mareografska postaja Bakar horizontalno su stabilizirana dva referentna repera. Na pročelju zgrade nalazi se reper BV 15663 (Slika 3a), a na začelju zgrade reper A510 (Slika 3b). Uloga referentnih repera je integracija i povezivanje mareografa s državnom nivelmanskom mrežom. Posebno se ističe uloga referentnog repera BV 15663. Naime, navedeni reper, uz ostala četiri referentna repera u Kopru, Rovinju, Splitu i Dubrovniku, definira visinski datum HVD71 sustava HVRS71 (Rožić, 2019).

3. Određivanje nadmorske visine srednje razine mora

Određivanje nadmorske visine srednje razine Jadranskog mora na geografskoj lokaciji mareografa Bakar obavljeno je na temelju dostupnih mareografskih mjerenja mareografa i nivelmanskih mjerenja I. nivelmana visoke točnosti (INVT), II. nivelmana visoke točnosti (IINVT) (Klak i dr., 1994) te neovisnih nivelmanskih mjerenja Sveučilišta u Zagrebu – Geodetskog fakulteta (GEOF23). Mareografski podaci upotrijebljeni u okviru ovog istraživanja preuzeti su iz otvorenoga znanstvenog repozitorija SEANOE (engl. *SEA scieNtific Open data Edition*) (Međugorac i dr., 2024). U ovom poglavlju elaborirana je primijenjena metodologija određivanja nadmorske visine srednje razine mora i analizirani su rezultati u pogledu određivanja trenda promjene srednje razine mora.

3.1. Metodologija

U okviru INVT-a, Mareografska postaja Bakar je postranim nivelmanskim vlakom (tzv. slijepim nivelmanskim vlakom) uključena u državnu nivelmansku mrežu na nivelmanski vlak br. 306 (Senj – Rijeka). Postrani nivelmanski vlak povezuje čvorni reper MCXVI i referentni reper mareografa BV 15663. U nedostatku detaljnijih podataka, kao epoha izmjere postranoga nivelmanskog vlaka MCXVI – BV 15663 definira se srednja epoha izmjere INVT-a, odnosno 1949,0 godina (Rožić, 2019).

Realizacijom IINVT-a, Mareografska postaja Bakar je postranim nivelmanskim vlakom br. 2 povezana na državnu nivelmansku mrežu s vlakovima br. 11 (Senj – Bakar) i br. 12 (Bakar – Brajkovići). Reper MCXVI čvorni je reper sva tri nivelmanska vlaka. Trasa niveliranja nivelmanskog vlaka br. 2 podudara se s trasom niveliranja u okviru INVT-a i uključuje sve iste repere izuzev referentnog repera A510. U skladu s dostupnim podacima, nivelmanski vlak br. 2 (MCXVI – BV 15663) mreže IINVT izmjeren je na terenu 1970. i 1971. godine (Rožić, 2019). Stoga, kao epoha izmjere navedenog vlaka definira se 1971,0 godina. Naglašava se razlika navedene epohe u odnosu na epohu realizacije visinskog datuma sustava HVRS71, tj. 1971,5 godina.

Na lokaciji istraživanja Sveučilište u Zagrebu – Geodetski fakultet obavio je neovisnu nivelmansku izmjeru u okviru projekta realiziranog s Prirodoslovno-matematičkim fakultetom Sveučilišta u Splitu i Geofizičkim odsjekom Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu (Zrinjski i dr., 2023). Terenska izmjera, metodom preciznog nivelmana,



Slika 4: Položaj Mareografske postaje Bakar (Mg.), referentnih repera BV 15663 i A510 te čvornog repera MCXVI nivelmanskog vlaka br. 2 IINVT-a

obavljena je 15. i 16. studenoga 2023. godine. Time je epoha izmjere Geodetskog fakulteta (GEOF23) određena kao 2023,9 godina. Trasa niveliranja podudara se s trasom niveliranja INVT-a i IINVT-a, a proteže se od čvornog repera MCXVI do referentnog repera BV 15663 u neposrednoj blizini Mareografske postaje Bakar. Prostorni položaj navedenih repera i Mareografske postaje Bakar (Mg.) prikazan je na Slici 4.

Cilj je ovog istraživanja, temeljem dostupnih mareografskih i nivelmanskih podataka, odrediti visinski položaj srednje razine mora u odnosu na čvorni reper MCXVI stabiliziran u živoj stijeni. Tim pristupom, uzimajući u obzir više vremenski razdvojenih epoha, moguće je analizirati promjenu visinskog položaja srednje razine mora u odnosu na kopno, odnosno odrediti relativni pomak srednje razine mora naspram kopna. Naglašava se da, u okviru ovog istraživanja, nisu uzeti u obzir ni razmatrani eventualni relativni visinski pomaci čvornog repera MCXVI nastali uslijed pomaka Zemljine kore i/ili potresnih djelovanja na području od interesa. U okviru ovog istraživanja uvedena je pretpostavka o stabilnosti čvornog repera MCXVI u proteklih 75 godina.

Nadalje, u cilju određivanja visinskog položaja srednje razine mora u sve tri analizirane epohe, fiksirana je izjednačena visina čvornog repera MCXVI iznosa 61,60333 m (Rožić, 2019) određena u visinskom datumu HVD71. Tim pristupom visinski položaj srednje razine mora na geografskoj lokaciji postaje Bakar, u sklopu ovog istraživanja, određen je rekurzivnim načinom u odnosu na srednju razinu mora koja je dio definicije parametara visinskog datuma. Stoga, iako nestandardno, za analiziranu plohu potpuno je opravdano uvođenje termina *nadmorska visina srednje razine mora*.

U cilju određivanja nadmorske visine srednje razine mora neophodno je specificirati metodologiju obrade mareografskih podataka. Naime, teorijski ispravan način određivanja srednje razine mora podrazumijeva uzimanje u obzir kontinuirana mareografska mjerenja u punom glavnom nutacijskom periodu od 18,61 godine (6794 dana) (Rezo i dr., 2014). Podrazumijeva se da su mareografski podaci distribuirani oko srednje epohe od interesa na način da je polovina podataka (9,305 godina) prije srednje epohe, a polovina podataka (9,305 godina) nakon srednje epohe. Međutim, navedeni pristup nije moguć u okviru ovog istraživanja budući da nije primjenjiv za treću epohu nivelmanskih podataka (2023. godina). Stoga, u cilju metodološki unificiranog pristupa u svim analiziranim epohama, mareografski podaci uzeti su u analizu u razdoblju od 18,61 godine, ali u punom iznosu prije pojedine epohe. Nadalje, zbog prekida rada mareografa od ožujka 1939. godine do kolovoza 1949. godine (Međugorac i dr., 2022) te činjenice da za epohu 1949,0 u suštini ni ne postoje mareografska mjerenja, za tu epohu usvaja se kompromis u okviru kojega se u određivanje srednje razine mora uključuje i nekoliko godina nakon epohe 1949,0. Stoga, u skladu s dostupnim mareografskim podacima i metodologijom obrade, u ovom istraživanju za pojedinu su epohu definirani sljedeći intervali vremena za određivanje srednjih razina mora:

- epoha 1949,0 (INVT) – od 20. 10. 1933. do 26. 5. 1952. godine,
- epoha 1971,0 (IINVT) – od 27. 5. 1952. do 1. 1. 1971. godine,
- epoha 2023,9 (GEOF23) – od 10. 4. 2005. do 15. 11. 2023. godine.

U skladu s navedenim razmatranjem, u okviru određivanja srednje razine mora za epohu 1949,0 (INVT) nisu uključena kontinuirana mareografska mjerenja u razdoblju od 18,61 godine već u trajanju od ukupno 8,19 godina, ali raspoređena u razdoblju od 18,61 godine. Uslijed neminovnog nedostatka mareografskih podataka, u okviru ovog istraživanja navedeni pristup određivanja srednje razine mora za epohu 1949,0 usvaja se kao prihvatljiv.

Tablica 1: Izjednačene visinske razlike između repera i mareografa u okviru INVT-a, IINVT-a i GEOF23 (Galić, 2024)

Od repera	Do repera	INVT ΔH [m]	IINVT ΔH [m]	GEOF23 ΔH [m]
MCXVI	136/306	–42,1707	–42,1702	–42,1723
136/306	BV 15663	–16,7726	–16,7730	–16,7730
BV 15663	Mg. (oznaka „c“)	–0,2804	–0,2801	–0,2814

Tablica 2: Srednja razina Jadranskog mora na mareografu Bakar određena iz mareografskih mjerenja i iskazana u odnosu na lokalnu mareografsku nulu

Od datuma	Do datuma	Epoha	Srednja razina [cm]
20. 10. 1933.	26. 5. 1952.	1949,0	72,12
27. 5. 1952.	1. 1. 1971.	1971,0	73,20
10. 4. 2005.	15. 11. 2023.	2023,9	79,63

3.2. Rezultati

Temeljem dostupnih nivelmanskih podataka INVT-a i IINVT-a (Klak i dr., 1994) te neovisnih nivelmanskih mjerenja Sveučilišta u Zagrebu – Geodetskog fakulteta, u Tablici 1 prikazane su izjednačene visinske razlike između čvornog repera MCXVI i referentnog repera BV 15663 koji se nalazi u neposrednoj blizini Mareografske postaje Bakar s dodatkom visokog repera 136/306 koji je u svim epohama uključen u trasu niveliranja. Također, prikazane su i visinske razlike između BV 15663 i oznake visine „c“ mareografa Bakar.

Pregledom vrijednosti izjednačenih visinskih razlika danih u Tablici 1 može se uvidjeti visoka razina usklađenosti koja nedvojbeno ukazuje na geološku stabilnost područja izmjere. Promjena visinske razlike između visokog repera 136/306 i referentnog repera BV 15663 u apsolutnom iznosu 0,4 mm i razdoblju od gotovo 75 godina, uzimajući u obzir točnost primijenjenih metoda mjerenja (metoda nivelmana visoke točnosti i metoda preciznog nivelmana), objektivno se može smatrati zanemarivom.

U skladu s prethodno elaboriranom metodologijom obrade mareografskih podataka, za svaku analiziranu epohu, određena je vrijednost srednje razine Jadranskog mora (Tablica 2). Vrijednosti srednjih razina iskazane su u odnosu na lokalnu mareografsku nulu.

Nadalje, prema metodologiji ovog istraživanja, temeljem izjednačenih visinskih razlika određenih nivelmanskim mjerenjima (Tablica 1), srednjih razina mora određenih mareografskim mjerenima i iskazanih u odnosu na lokalnu mareografsku nulu (Tablica 2) te mareografske konstante mareografa Bakar iznosa 3,1180 m (Međugorac i dr., 2022) određena je nadmorska visina srednje razine Jadranskog mora na geografskoj lokaciji mareografa Bakar H_{SRM} za svaku analiziranu epohu. Vrijednosti su prikazane u tablici 3.

Rezultati ovog istraživanja i određivanja nadmorske visine srednje razine Jadranskog mora u Bakru pokazuju da se visinski položaj srednje razine mora promijenio, odnosno porastao u iznosu 1,12 cm od 1949. do 1971. godine i 6,10 cm od 1971. do studenoga 2023. godine. Ukupni porast srednje razine Jadranskog mora u Bakru od 1949. do studenoga 2023. godine iznosi 7,22 cm.

U skladu s metodologijom računske obrade i fiksiranjem visine čvornog repera MCXVI stabiliziranog u živoj stijeni, prethodni rezultati promjene visinskog položaja srednje razine mora u suštini iskazuju relativnu promjenu u odnosu na kopno, a ne na mareograf i lokalnu mareografsku nulu. Na taj način, predmetna analiza uključuje i moguće eventualne visinske pomake zgrade u kojoj se nalazi Mareografska postaja Bakar.

Tablica 3: Nadmorska visina srednje razine Jadranskog mora na geografskoj lokaciji mareografa Bakar

Epoha	H_{SRM}[cm]
1949,0 (INVT)	–1,72
1971,0 (IINVT)	–0,60
2023,9 (GEOF23)	5,50

4. Analiza promjene srednje razine mora

U cilju određivanja trenda promjene nadmorske visine srednje razine Jadranskog mora na geografskoj lokaciji Mareografske postaje Bakar obavljeno je regresijsko modeliranje primjenom jednostavne linearne regresije. Nadmorska visina srednje razine mora H_{SRM} (zavisna varijabla) definira se kao funkcija vremena t (nezavisna varijabla). Određen je regresijski pravac koji, u kontekstu metode najmanjih kvadrata, najbolje odgovara vrijednostima nadmorskih visina srednjih razina mora (Tablica 3). Parametri linearnoga regresijskog modela, određeni metodom najmanjih kvadrata, dani su u Tablici 4.

Tablica 4: Vrijednosti parametara linearnoga regresijskog modela s pripadnim standardnim odstupanjima

Parametar	Vrijednost	Standardno odstupanje
Parametar nagiba [cm/god]	0,0999	0,0146
Parametar presjeka [cm]	–196,8355	28,9581

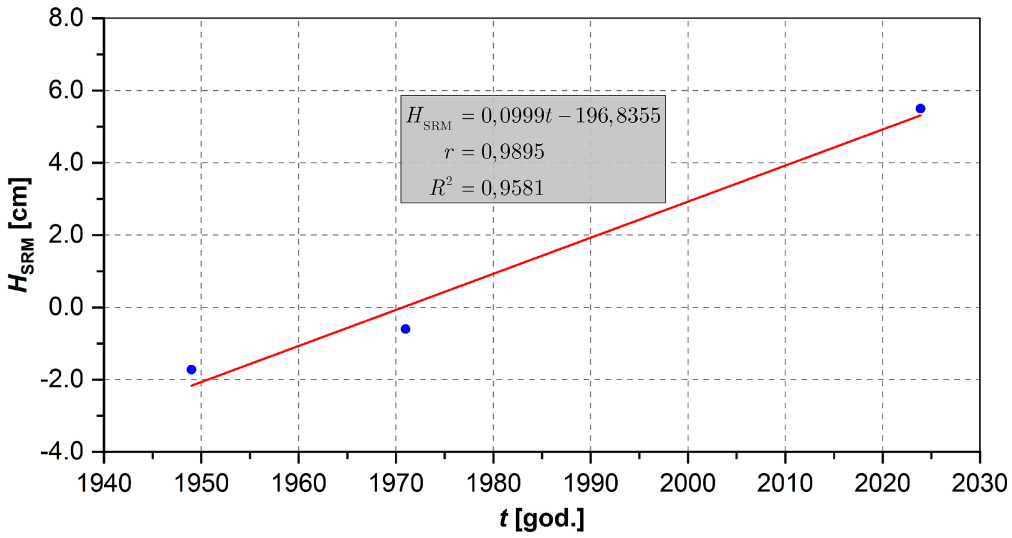
Na temelju rezultata regresijskog modeliranja slijedi jednadžba regresijskog pravca u eksplicitnom obliku:

$$H_{SRM} = 0,0999 \cdot t - 196,8355, \quad t \in [1949,0,\ 2023,9] \tag{1}$$

gdje su:

- H_{SRM} – nadmorska visina srednje razine mora izražena u centimetrima,
- t – vrijeme izraženo u godinama (epoha).

Na Slici 5 dan je dijagram raspršenosti predmetnog seta podataka (Tablica 3) i modeliranjem određeni regresijski pravac (Tablica 4).



Slika 5: Dijagram raspršenosti nadmorskih visina srednje razine mora i regresijski pravac

U cilju evaluacije definiranoga linearnoga regresijskog modela i određivanja reprezentativnosti regresije te utvrđivanja jakosti i smjera linearne ovisnosti kvantificirani su koeficijent determinacije R^2 i Pearsonov koeficijent korelacije r te iznose:

$$R^2 = 0,9581$$
$$r = 0,9895$$

U skladu s određenim vrijednostima koeficijenta determinacije R^2 i koeficijenta korelacije r izvode se sljedeći zaključci:

- postavljeni linearni regresijski model je reprezentativan i određeni regresijski pravac čvrsto modelira/procjenjuje nadmorsku visinu srednje razine mora,
- postoji čvrsta rastuća korelacija između nadmorske visine srednje razine mora i vremena.

Parametar (koeficijent) nagiba regresijskog pravca određen linearnim regresijskim modeliranjem primjenom teorije najmanjih kvadrata opisuje promjenu, odnosno porast nadmorske visine srednje razine mora po jednoj godini vremena te iznosi:

$$k = 1,0 \text{ mm/god}$$

Na temelju rezultata ovog istraživanja utvrđen je trend porasta nadmorske visine srednje razine Jadranskog mora na geografskoj lokaciji Mareografske postaje Bakar u iznosu 0,1 mm/god. Navedeni rezultati u skladu su s rezultatima prethodnih istraživanja (Orlić i Pasarić, 1998).

5. Zaključak

U skladu sa ciljevima ovog istraživanja obavljeno je određivanje nadmorske visine srednje razine Jadranskog mora na geografskoj lokaciji Mareografske postaje Bakar, a na temelju dostupnih nivelmanskih i mareografskih podataka. U računsku obradu i analizu uključeni su nivelmanski podaci I. nivelmana visoke točnosti (INVT), II. nivelmana visoke točnosti (IINVT) i neovisne nivelmanske izmjere obavljene od strane Sveučilišta u Zagrebu – Geodetskog fakulteta u studenome 2023. godine te mareografski podaci mareografa Bakar (izmjerene razine mora) dostupni u bazi podataka SEANOE. Stoga, definirane su ukupno tri epohe u kojima je određena i analizirana nadmorska visina srednje razine mora i to: 1949,0 godina (IVNT), 1971,0 godina (IINVT) i 2023,9 godina (GEOF23).

Rezultati ovog istraživanja pokazuju da je visinski položaj srednje razine Jadranskog mora u Bakru, u odnosu na kopno, porastao u iznosu 1,12 cm od 1949. do 1971. godine i 6,10 cm od 1971. do studenoga 2023. godine. Sumarno gledajući, srednja razina Jadranskog mora u Bakru, od 1949. do studenoga 2023. godine, porasla je 7,22 cm.

U skladu s navedenim rezultatima i analizom, utvrđuje se trend porasta nadmorske visine srednje razine Jadranskog mora u Bakru, određen linearnim regresijskim modeliranjem, u iznosu 0,1 mm/god s pripadnim standardnim odstupanjem od 0,15 mm/god.

Literatura

Galić, B. (2024): Određivanje i analiza visinskih pomaka na Mareografskoj postaji Bakar, diplomski rad, Sveučilište u Zagrebu – Geodetski fakultet, Zagreb.

Klak, S., Feil, L., Rožić, N. (1994): Podaci o reperima – Knjiga 1, Državna geodetska uprava Republike Hrvatske, Zagreb.

Međugorac, I., Pasarić, M., Orlić, M. (2022): Long-term measurements at Bakar tide-gauge station (east Adriatic), Geofizika, 39, 1, 149–162.

Međugorac, I., Pasarić, M., Orlić, M. (2024): Historical sea-level measurements at Bakar (east Adriatic), SEANOE, DOI: 10.17882/85171.

Orlić, M., Pasarić, M. (1998): Sedam desetljeća mareografskih mjerenja u Bakru, Prirodoslovna istraživanja riječkog područja, Prirodoslovna biblioteka, Rijeka, 1, 201–211.

Rezo, M., Špoljarić, D., Šljivarić, M. (2010): Promjene razine mora i varijacije Mjesečevih deklinacija u nutacijskom razdoblju na četiri mareografa u Hrvatskoj, Geodetski list, 64 (87), 4, 263–278.

Rezo, M., Pavasović, M., Šljivarić, M. (2014): Analiza mareografskih podataka o Jadranskome moru od 1953. do 2006. godine, Geodetski list, 68 (91), 4, 269–290.

Rožić, N. (2019): Hrvatski visinski referentni sustav, Sveučilište u Zagrebu – Geodetski fakultet, Zagreb.

Vilibić, I., Orlić, M., Čupić, S., Domijan, N., Leder, N., Mihanović, H., Pasarić, M., Pasarić, Z., Srdelić, M., Strinić, G. (2005): A new approach to sea level observations in Croatia, Geofizika, 22, 1, 21–57.

Volarić, B., Kempni, K., Lisac, I. (1990): Akademik Stjepan Škreb i Geofizički zavod u Zagrebu, Geofizika, 7, 5–54.

Zrinjski, M., Tupek, A., Špoljar, M. (2023): Određivanje visinskih odnosa na Mareografskoj postaji Bakar, elaborat, Sveučilište u Zagrebu – Geodetski fakultet, Zagreb.

Mean Sea Level Rise of the Adriatic at the Bakar Tide Gauge Station

Abstract

In this paper, the determination of the mean sea level of the Adriatic Sea at the geographical location of the Bakar Tide Gauge Station is presented. Additionally, changes in the mean sea level, relative to mainland, over a period of approximately 75 years are presented. For this analysis, levelling data from the First High Accuracy Levelling (INVT), Second High Accuracy Levelling (IINVT), and of the independent leveling campaign conducted by the University of Zagreb – Faculty of Geodesy in 2023, as well as mareographic data available in the SEANOE scientific marine data repository were used. The change, i.e., rise in mean sea level over a period of 75 years was modeled by linear regression.

Keywords: *INVT, IINVT, Adriatic Sea, Bakar tide gauge, mean sea level*

Earth Observation Data Cubes for Remote Sensing Analysis

Dino Dobrinić[1], Franka Knežević[1]

[1] Geodetski fakultet, Sveučilište u Zagrebu, Savska 144A, Zagreb, Hrvatska, ddobrinic@geof.unizg.hr, fknezevic@geof.unizg.hr

Abstract

Open-source data cubes are a powerful tool for organizing and analyzing large amounts of remote sensing data, providing researchers with access to a wealth of information for monitoring and understanding the dynamics of the Earth's surface. Open data cubes bring together various sources of remote sensing data, including satellite imagery, aerial photography, and ground-based measurements, into a unified and accessible framework. It enables users to efficiently manage, process, and analyze large spatio-temporal datasets, to gain valuable insights and knowledge about land cover, land use, environmental change, and natural resources. This study demonstrates the possibilities of open data cubes through a case study focused on a subset area in Croatia. Using open data sources such as Sentinel-2 satellite imagery and national-level datasets, we demonstrate the process of data acquisition, storage, pre-processing, and analysis in an open data cube environment. The use of advanced analysis techniques, including spectral indices, classification algorithms, and change detection methods will be used, to derive meaningful information about land cover and land use patterns in the study area. Furthermore, the potential applications of open data cubes at the national level in Croatia are discussed. These applications cover a wide range of sectors, including agriculture, forestry, environmental monitoring, urban planning, disaster management, and climate change adaptation. By harnessing the power of open data cubes, Croatia can improve its capacity for evidence-based decision-making, resource management, and sustainable development initiatives.

Keywords: *Big Data, Digital Earth, Earth Observation Data Cube, Remote Sensing.*

1. Introduction

Earth Observation (EO) data, acquired remotely via satellite or in-situ sensors, serves as a globally consistent source of information for monitoring Earth's condition and enhancing our comprehension of natural processes (Sudmanns et al., 2023). This data is vital for achieving long-term global coverage and monitoring land cover changes over extensive areas through time. The proliferation of spaceborne sensors enables near-continuous monitoring of the planet, offering daily global coverage at medium-to-high spatial and spectral resolutions. Open data policies, exemplified by initiatives such as the United States Geological Survey (USGS) (e.g., Landsat) and the European Space Agency (ESA) (e.g., Sentinel), facilitate access to satellite data (Zhu et al., 2019).

However, the handling of large volumes (e.g., terabytes to petabytes), diverse types (e.g., radar, optical), and rapid availability (e.g., daily updates) of EO data, as well as the associated costs and efforts in converting it into actionable information, pose challenges for systematic environmental monitoring. Consequently, developing large-scale analytical tools capable of retrieving information efficiently and effectively based on scientific inquiries, and generating decision-ready products, remains a significant challenge for the EO community (Giuliani et al., 2019). Therefore, Earth Observation Data Cubes (EODCs) have emerged as a transformative paradigm, facilitating interactions between data, applications, and users to manage, access, and utilize Analysis Ready Data (ARD) (Sudmanns et al., 2023). EODCs aim to enable scientists, researchers, and businesses to leverage vast EO data with minimal cost and effort. Several platforms, such as the Open Data Cube (ODC), EarthServer, and Google Earth Engine (GEE), demonstrate the implementation of EODC principles. However, interoperability issues among these platforms hinder effective data discovery, access, and sharing processes (Giuliani et al., 2019).

To address these challenges, the Earth Observation Data Cube paradigm has gained traction, aiming to transform the way researchers handle large EO data volumes. Although there is no universal definition of EODCs, these systems manage large time series of EO data using multidimensional array concepts, making Analysis Ready Data (ARD) accessible to users (Baumann et al., 2018). Platforms such as the Open Data Cube (ODC), Google Earth Engine (GEE), and Sentinel Hub adopt various data abstractions and technological solutions to provide similar functionalities.

Therefore, main objective of this paper is to present the efficiency of data cubes in handling complex datasets, performing change detection analysis and validating the usefulness of the openEO platform in supporting these analyzes.

2. Study area and data

Considering the climate, geography and ecology of the city, the research area chosen for data cube construction is Zagreb. The city of Zagreb, located along the Sava River, offers a mix of suburban and rural areas that create an ideal environment for environmental monitoring and change detection research. Considering Zagreb's continental climate, composed of four seasons, the city is subject to significant influences on vegetation and soil conditions, which makes it a suitable address for analyzing indicators such as normalized difference vegetation index (NDVI) and soil moisture levels. Also, Zagreb has a combination of forests, agricultural areas and urban areas. Such ecological diversity is essential for the study of processes and their effects on different types of land cover. Additional factors that appear when choosing the city of Zagreb for this research and analysis are the fact of the city's rapid urban growth and accompanying issues such as air pollution and changes in land use, which undoubtedly affects additional environmental pollution. The research aims to use the Zagreb settings for testing and confirming the effectiveness of spatio-temporal data cubes and the openEO platform, in the processing and examination of multidimensional geospatial data, for effective environmental monitoring and control.

Satellite imagery from the Copernicus Programme (i.e., datasets "SENTINEL2_L2A" and "SENTINEL1_GRD") within the openEO JupyterLab environment were used for this research. JupyterLab is a laptop application and editing environment that is part of the Jupyter Project, a large project focused on providing tools (and standards) for interactive computing. A notebook is a sharable document that combines computer code, plain language descriptions, data, wide variety of visualizations such as 3D models, diagrams, charts, images, and interactive controls.

Sentinel-2 is a European Copernicus mission that provides high-resolution multispectral imagery and enables monitoring of vegetation, soil and water, as well as observing inland waterways and coastal areas. Sentinel-2 Level-2A imagery consist of 13 spectral bands with a spatial resolution of 10 m, 20 m and 60 m, depending on the spectral band used. Furthermore, Sentinel-1 is also part of the Copernicus program, providing Synthetic Aperture Radar (SAR) imagery which are crucial for monitoring soil surface moisture, soil movement and soil cover changes, especially in cloudy conditions or at night. Sentinel-1 Ground Range Detected (GRD) imagery provide a spatial resolution of 10 meters and can be used for a variety of applications, including ground deformation (e.g., landslides, earthquakes) and disaster monitoring (Ghorbanzadeh et al., 2020).

Sentinel-1 and Sentinel-2 data were downloaded through the openEO platform, which enables access and (pre)processing of satellite imagery. This data is retrieved using an application programming interface (API), which is a set of definitions and protocols for building and integrating application software. Using the openEO API, data was automatically retrieved, filtered based on geographic coordinates, time periods, and spectral bands, and then integrated into data cubes for subsequent analysis.

3. Methods

3.1. NDVI Timeseries

The Normalized Difference Vegetation Index (NDVI) is a widely used remote sensing index that quantifies vegetation health by measuring the difference between near-infrared (which vegetation strongly reflects) and red light (which vegetation absorbs). The NDVI is calculated using the Equation (1):

$$NDVI = \frac{(NIR-Red)}{(NIR+Red)} \quad (1)$$

where NIR is the reflectance in the near-infrared band and Red is the reflectance in the red band.

For this study, NDVI time series will be conducted for the period from 01/01/2022 to 31/12/2023. Analyzing NDVI time series is crucial because it allows us to monitor changes in vegetation health over time, detect trends, and assess the impact of various environmental factors.

3.2. NDVI Analysis for Landslide detection

NDVI analysis can also be used to detect landslides. Landslides often result in significant changes in land cover and vegetation patterns. By analyzing NDVI time series data, sudden drops in NDVI values can be identified, which may indicate the occurrence of a landslide (Doan et al., 2023). This method is particularly useful for large-scale monitoring and early warning systems as it allows for the detection of changes in vegetation that are associated with landslide activity.

3.3. Surface Soil Moisture

The Surface Soil Moisture (SSM) is another critical parameter for understanding land surface conditions. SSM can be derived from radar data obtained from Sentinel-1 satellites. The calculation involves using backscatter coefficients from Sentinel-1, which are sensitive to soil moisture content (Balenzano et al., 2021). The information about Surface Soil Moisture is crucial for various applications, including agricultural monitoring, drought assessment, and hydrological studies. In the context of landslide detection, monitoring soil moisture is essential because high soil moisture levels can reduce soil stability and increase the likelihood of landslides. By combining NDVI and SSM, a more comprehensive understanding of the environmental conditions that precede landslides can be achieved, improving the ability to predict and mitigate such events.

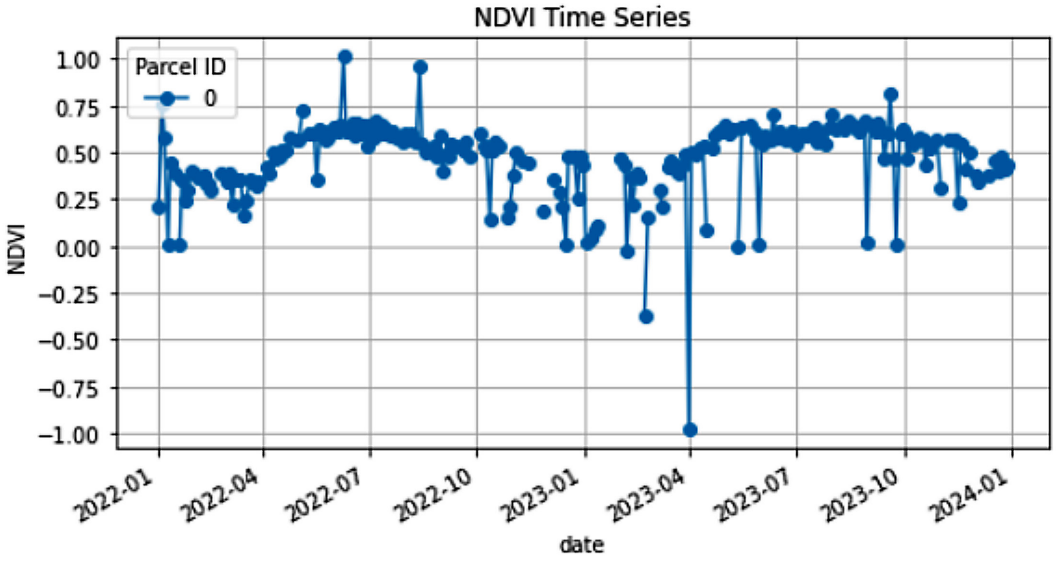


Figure 1: Time series values of NDVI for a chosen parcel in study area

4. Results and discussion

As stated before, the main objective of this paper is to show the efficiency of data cubes in handling complex datasets through the openEO platform. As such, in this Section various application cases will be presented (as described in Section 3).

Therefore, Figure 1 shows calculated NDVI index from January 2021 to December 2023 for a chosen parcel within a study area. This longitudinal approach provides insight into seasonal variations, long-term trends (e.g., lower NDVI values in winter season and higher NDVI values in spring and summer season), and responses to environmental change or human activity. By examining NDVI trends over months or years, researchers can better understand vegetation dynamics, predict future conditions, and assess the impact of climate events or land use changes (Pettorelli et al., 2005).

Furthermore, in order to understand the impact of the changes in vegetation for landslides, an NDVI analysis was carried out for the area of Zagreb, which includes the Kostanjek landslide. Sentinel-2 data were used to calculate NDVI for pre-event and post-event periods, and the difference in NDVI was calculated to identify landslide-affected areas. A statistical summary of the NDVI differences and time series data revealed several key pieces of information. The minimum NDVI difference was -0.10, while the maximum difference was 0.13. The mean NDVI difference was 0.01, which indicates a moderate impact of the vegetation for a landslide. For the NDVI time series, the mean value was 0.20. Beside most important landslide-conditioning factors (e.g., slope degree, slope aspect, altitude, rainfall, etc.), a positive correlation between landslide occurrence and NDVI was reported by Yilmaz and Keskin (2009).

On the other hand, the visualization of the NDVI difference (Figure 2) highlighted areas with significant changes in vegetation, where the red color indicat-

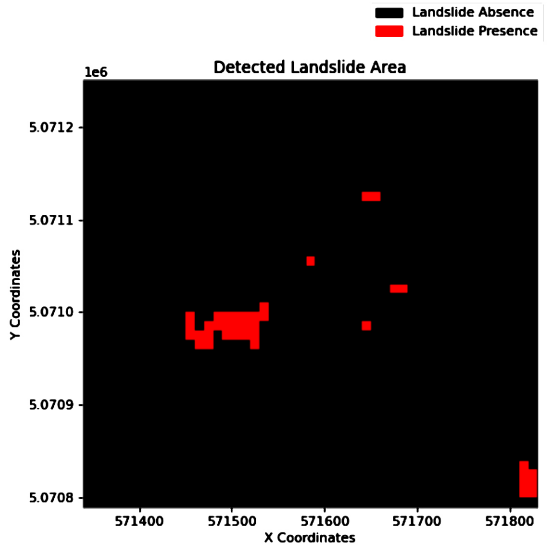


Figure 2: Overview of the NDVI difference values with potential landslide areas where red pixels indicate presence and black pixels indicate absence of the landslide

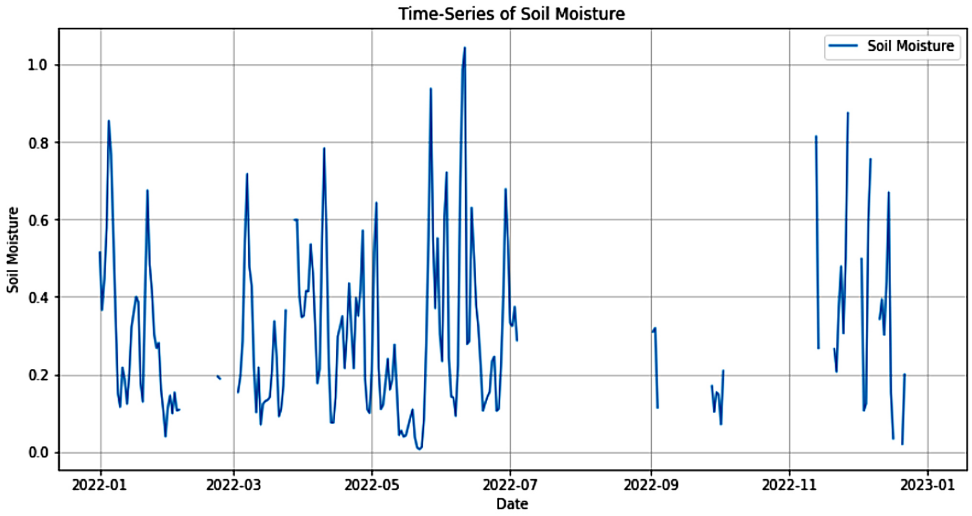


Figure 3: Time series values of soil moisture for a chosen parcel in study area

ed areas affected by landslides. This time series also made it possible to observe seasonal variations and recovery trends. Lastly, the NDVI analysis for landslide monitoring and detection provided valuable information on the impact of landslides on vegetation. A noticeable drop in NDVI values after the event clearly indicated the areas affected by the landslide. The analysis of time series made it possible to monitor changes in vegetation over time, which provided insight into the long-term effects of landslides.

Investigating soil moisture levels is key to understanding how water moves through the soil, especially when it comes to agriculture that manages water resources and cares about the environment. As opposed to the data required for NDVI analysis (i.e., Sentinel-2 multispectral imagery), Sentinel-1 imagery was used and accessed through the openEO platform to calculate soil moisture.

The output of the analysis is a NetCDF file named SoilMoisture.nc, which contains the calculation of Surface Soil Moisture (SSM) for the Zagreb region for the period from 31 December 2023 to 20 January 2024. Calculated SSM values are unitless and range between 0 and 1, representing relative moisture content from dry (0) to wet (1) conditions. Such normalization provides a standardized metric for comparing soil moisture at different times and locations (Figure 3).

An increase in the value indicates an increase in the moisture level in the soil, while a decrease in the value indicates drying of the soil. Regular fluctuations may correspond to seasonal weather patterns. Identification of any anomalies or unexpected changes in soil moisture values is crucial, where sudden drops or rises may be due to weather, irrigation or other factors. If synthetic dates are used, it ensures that the time range generated is suitable for analysis. Furthermore, Figure 4 shows average monthly SSM values derived from VV band of the available dates of S1 imagery. Bauer-Marschallinger et al. (2018) also employed data cube architectures and high-performance computing environments in order to retrieve surface soil moisture (SSM) from the Sentinel-1 (S-1) satellites. Their research yielded high agreement over plains and agricultural areas, with low agreement over forests and strong topography.

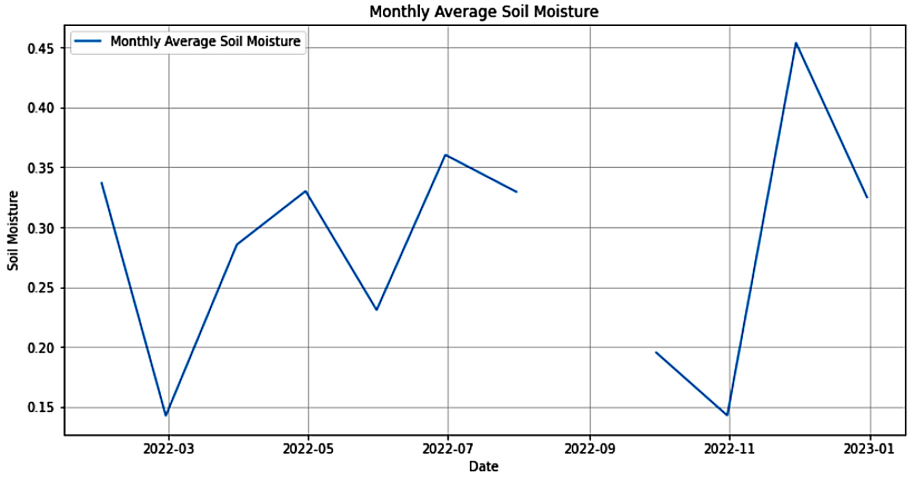


Figure 4: Monthly SSM averaged values derived from VV polarization band of S1 imagery

5. Conclusions

In this research, the powerful capabilities of open-source data cubes were demonstrated in managing and analyzing complex remote sensing datasets. Through case study in Croatia, the process of data import, storage, preprocessing, and analysis using radar (i.e., Sentinel-1) and optical (i.e., Sentinel-2) satellite imagery and national-level datasets within an open data cube environment.

Specifically, NDVI time series analysis for the period from 2022 to 2024 was conducted, which proved valuable in monitoring vegetation health and detecting environmental changes. Also, the use of NDVI analysis for landslide detection was demonstrated, illustrating how changes in vegetation patterns can indicate landslide occurrences. Additionally, the Surface Soil Moisture (SSM) from Sentinel-1 dana was derived, further enhancing our understanding of soil conditions and their implications for land stability and agriculture.

The application of these techniques within the openEO platform underscores its effectiveness in supporting complex data analyses and validating its usefulness for environmental monitoring and land use studies. The results of our study emphasize the significant potential of open data cubes for a wide range of sectors in Croatia, including agriculture, forestry, environmental monitoring, urban planning, disaster management, and climate change adaptation.

Acknowledgments: This research was funded by the Croatian Science Foundation for the ALCAR project: "Assessment of the long-term effect of climatic and anthropogenic influences on the spatio-temporal dynamics of vegetation cover in Croatia using satellite observations" (Grant No. IP-2022-10-5711).

References

Balenzano, A., Mattia, F., Satalino, G., Lovergine, F. P., Palmisano, D., Peng, J., ..., Jackson, T. J. (2021): Sentinel-1 soil moisture at 1 km resolution: a validation study. Remote Sensing of Environment, 263, 112554.

Bauer-Marschallinger, B., Freeman, V., Cao, S., Paulik, C., Schaufler, S., Stachl, T., ... Wagner, W. (2018): Toward global soil moisture monitoring with Sentinel-1: Harnessing assets and overcoming obstacles. IEEE Transactions on Geoscience and Remote Sensing, 57(1), 520-539.

Baumann, P., Rossi, A. P., Bell, B., Clements, O., Evans, B., Hoenig, H., ..., Wagemann, J. (2018): Fostering cross-disciplinary earth science through datacube analytics. Earth Observation Open Science and Innovation, 91-119.

Doan, V. L., Nguyen, B. Q. V., Pham, H. T., Nguyen, C. C., Nguyen, C. T. (2023): Effect of time-variant NDVI on landside susceptibility: A case study in Quang Ngai province, Vietnam. Open Geosciences, 15(1), 20220550.

Ghorbanzadeh, O., Didehban, K., Rasouli, H., Kamran, K. V., Feizizadeh, B., Blaschke, T. (2020): An application of Sentinel-1, Sentinel-2, and GNSS data for landslide susceptibility mapping. ISPRS international journal of geo-information, 9(10), 561.

Giuliani, G., Masó, J., Mazzetti, P., Nativi, S., Zabala, A. (2019): Paving the way to increased interoperability of earth observations data cubes. Data, 4(3), 113.

Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J. M., Tucker, C. J., Stenseth, N. C. (2005): Using the satellite-derived NDVI to assess ecological responses to environmental change. Trends in ecology & evolution, 20(9), 503-510.

Sudmanns, M., Augustin, H., Killough, B., Giuliani, G., Tiede, D., Leith, A., ..., Lewis, A. (2023): Think global, cube local: an Earth Observation Data Cube's contribution to the Digital Earth vision. Big Earth Data, 7(3), 831-859.

Yilmaz, I., Keskin, I. (2009): GIS based statistical and physical approaches to landslide susceptibility mapping (Sebinkarahisar, Turkey). Bulletin of Engineering Geology and the Environment, 68, 459-471.

Zhu, Z., Wulder, M. A., Roy, D. P., Woodcock, C. E., Hansen, M. C., Radeloff, V. C., ..., Scambos, T. A. (2019): Benefits of the free and open Landsat data policy. Remote Sensing of Environment, 224, 382-385.

Podatkovne kocke otvorenog koda u daljinskim istraživanjima

Sažetak

Podatkovne kocke otvorenog koda pružaju mogućnost organiziranja i analize velikih količina podataka daljinskog istraživanja, pružajući znanstvenicima pristup mnoštvu informacija za praćenje i razumijevanje dinamike Zemljine površine. Podatkovne kocke otvorenog tipa pružaju skup različitih izvora podataka daljinskog istraživanja, uključujući satelitske snimke, aero snimke i mjerenja obavljena na terenu u jedinstven i pristupačan okvir. Također omogućuju korisnicima učinkovito upravljanje, obradu i analizu velikih prostorno-vremenskih skupova podataka, pružajući uvid i znanja o zemljišnom pokrovu, korištenju zemljišta, promjenama u okolišu i prirodnim resursima. Ovo istraživanje prikazuje mogućnosti podatkovne kocke otvorenog koda kroz analizu slučaja usmjerenu na podskup područja u Hrvatskoj. Koristeći otvorene izvore podataka kao što su satelitske slike (npr., Sentinel-2) i skupove podataka na nacionalnoj razini, prikazati će se proces unosa, pohranjivanja, predobrade i analize podataka unutar okruženja podatkovne kocke otvorenog koda. Istražiti će se korištenje naprednih analitičkih tehnika, uključujući spektralne indekse, algoritme klasifikacije i metode otkrivanja promjena, kako bi se dobile značajne informacije o zemljišnom pokrovu i trend korištenja zemljišta u području istraživanja. Nadalje, prikazati će se i potencijalne primjene podatkovnih kocki otvorenog koda na nacionalnoj razini. Ove aplikacije obuhvaćaju širok raspon sektora, uključujući poljoprivredu, šumarstvo, praćenje okoliša, urbano planiranje, upravljanje katastrofama i prilagodbu klimatskim promjenama. Iskorištavanjem mogućnosti podatkovnih kocki otvorenog koda, Hrvatska može unaprijediti svoje kapacitete za donošenje odluka, upravljanje resursima i inicijativa za održivi razvoj.

Ključne riječi: *daljinska istraživanja, digitalna zemlja, istraživanje zemlje, podatkovna kocka, veliki podaci.*

Hiperspektralna tehnologija i mogućnosti primjene

Vanja Miljković[1], Iva Odak[2], Luka Babić[3], Ivana Hećimović[1]

[1] Sveučilište u Zagrebu Geodetski fakultet, Savska cesta 144A, Zagreb, Hrvatska, vmiljkovic@geof.unizg.hr, ivana.hecimovic@geof.unizg.hr

[2] Oikon, Trg senjskih uskoka 1, Zagreb, Hrvatska, iodak@oikon.hr

[3] Grad Zagreb, Ulica Dragutina Golika 63, Zagreb, Hrvatska, luka.babic@zagreb.hr

Sažetak

Hiperspektralna tehnologija razvijala se više od 30 godina te predstavlja naprednu metodu prikupljanja podataka o svjetlu koje se reflektira od ili emitira sa opažanih objekata, omogućujući detaljne analize materijala na osnovu njihovog spektralnog potpisa. Tradicionalne metode detekcije i analize materijala su vremenski zahtjevne, traže puno rada i mogu uništiti uzorke. U posljednjih nekoliko godina, hiperspektralna tehnologija koristi se sve više jer omogućava brzu i nedestruktivnu detekciju s niskim zahtjevima za eksperimentalnim uvjetima te visoku operativnost. Hiperspektralno snimanje omogućava dobivanje detaljnih informacija o objektu koje nisu vidljive golim okom ili konvencionalnim metodama snimanja. Može se koristiti na mikro razini za detekciju mikrometarskih čestica u laboratorijskim uzorcima, ali i na makro razini čak i za detekciju promjena na globalnoj razini. Kada se koristi za prikupljanje prostornih informacija, ova tehnologija ide korak dalje od klasične fotogrametrije i standardne RGB snimke. Njena primjena pomaže u istraživanju i analizi različitih materijala i okruženja na Zemlji, pružajući dublje razumijevanje prirodnih procesa, ekosustava te geoloških fenomena. Svestranost ove tehnologije je njena najveća prednost, a u ovom radu je kratko predstavljena sama tehnologija te njena primjena u raznim segmentima društvenih i prirodnih istraživačkih aktivnosti - od agronomije, šumarstva, zaštite okoliša, do arheologije, urbanizma, geologije, ali i polja kao što su medicina, industrija hrane, forenzika i druga.

Ključne riječi: *hiperspektralna tehnologija, metode prikupljanja hiperspektralnih podataka, područja primjene*

1. Uvod

Hiperspektralno snimanje je proces snimanja objekata u širokom pojasu elektromagnetskog spektra. Budući da svaki materijal ima vlastiti spektralni potpis, snimanje objekata različitim valnim duljinama omogućuje detekciju materijala od kojeg su građeni. Hiperspektralni skeneri spadaju u moderne progresivne tehnologije koje omogućuju dobivanje dodatnih informacija o objektima na temelju interpretacije spektralnih svojstava elektromagnetskog zračenja reflektiranog s površine objekta. Dodavanjem hiperspektralne analize prostornim podacima objekta dobivaju se prostorno geokodirane hiperspektralne kocke, a samim time i puno više informacija o objektu bez kontakta s njim i bez bojazni od njegova oštećenja ili uništenja. Razlika između poznatih i desetljećima korištenih optičkih senzora i hiperspektralnih senzora može se vidjeti na Slici 1 (Miljković, 2017).

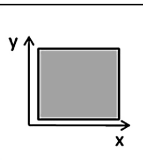
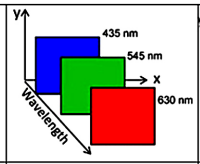
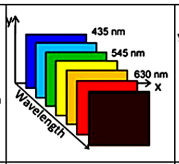
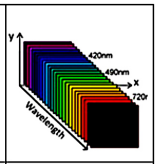
U Hrvatskoj se s periodičnim multispektralnim i hiperspektralnim snimanjima počelo 2002. godine u okviru projekta ARC (engl. Airborne Minefield Area Reduction) Europske komisije, a intenzivno su se hiperspektralna snimanja iz zraka provodila u okviru tehnološkog projekta Ministarstva znanosti i tehnologije TP-06/0007-01 pod naslovom "Multisenzorsko zrakoplovno izviđanje i nadzor u izvanrednim situacijama i zaštiti okoliša" (Šemanjski i dr., 2008). U okviru projekta, hiperspektralna i multispektralna snimanja provodila su se isključivo iz zraka.

U okviru projekta "Multisenzorsko zračno snimanje Republike Hrvatske za potrebe procjene smanjenja rizika od katastrofa – KK.05.2.1.10.0001" nabavljene su hiperspektralne kamere HySpex VNIR-1800 i SWIR -384. Specifikacije tih kamera prikazane su na Slici 2.

Osim kamera, nabavljena je i kompletna oprema za laboratorijsko, terestričko i snimanje iz zraka (Slika 3).

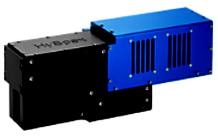
2. Laboratorijsko hiperspektralno snimanje

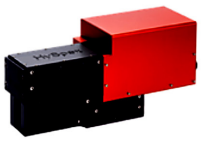
Laboratorijsko hiperspektralno snimanje je tehnika koja se koristi za analizu spektralnih svojstava uzoraka u kontroliranim laboratorijskim uvjetima. Ova metoda omogućava prikupljanje detaljnih spektralnih informacija koje se mogu koristiti za identifikaciju, klasifikaciju i kvantifikaciju različitih materijala.

SVOJSTVA				
	MONOKROMATSKI	RGB	MULTISPEKTRALNI	HIPERSPEKTRALNI
PROSTORNE INFORMACIJE	DA	DA	DA	DA
BROJ KANALA	1	3	3-10	NEKOLIKO DESETAKA DO TISUĆA
SPEKTRALNE INFORMACIJE	NE	NE	LIMITIRANO	DA
VIŠEKOMPONENTNE INFORMACIJE	NE	LIMITIRANO	LIMITIRANO	DA
OSJETLJIVOST NA MALE PROMJENE	NE	NE	LIMITIRANO	DA

Slika 1: Usporedba monokromatskih, RGB, multispektralnih i hiperspektralnih senzora (Miljković, 2017)

HySpex by neo





	VNIR - 1800	SWIR - 384
Spectral range	400 – 1000 nm	930-2500 nm
Spatial pixels	1800	384
Spectral channels	186	288
Spectral sampling	3.26 nm	5.45 nm
FOV*	17°	16°
Pixel FOV across/along*	0.16/0.32 mrad	0.73/0.73 mrad
Bit resolution	16 bit	16 bit
Noise floor	2.4 e-	150 e-
Dynamic range	20000	7500
Peak SNR (at full resolution)	> 255	> 1100
Max speed (at full resolution)	260 fps	400 fps
Keystone	less than 5%	less than 5%
SMILE	less than 10%	less than 10%

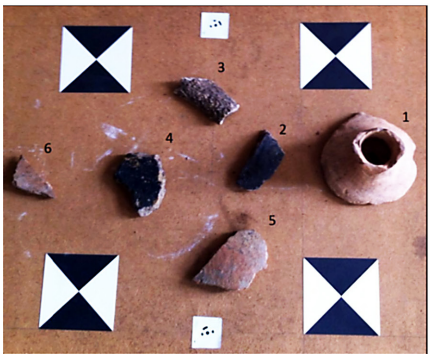
Slika 2: Specifikacije HySpex kamera



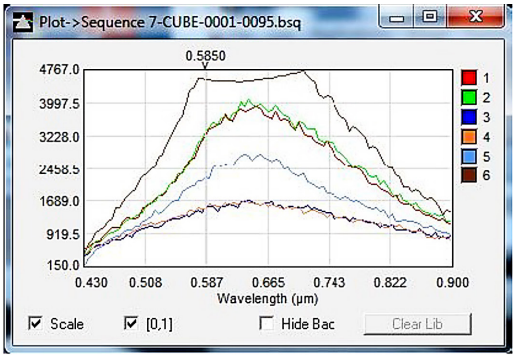
Slika 3: Oprema za laboratorijsko, terestričko i snimanje iz zraka

Oprema koja je potrebna za laboratorijsko hiperspektralno snimanje sastoji se od hiperspektralnog senzora, izvora svjetlosti, opreme za montažu i pozicioniranje, računalnog sustava i kalibracijske opreme. Metodologija snimanja sastoji se od pripreme uzoraka, postavljanja opreme, kalibracije sustava, prikupljanja podataka te obrade i analize podataka.

Primjer: Dokumentiranje keramike jedan je od glavnih zadataka u arheologiji jer se keramika najčešće pronalazi na arheološkim nalazištima. Zadatak je bio otkriti krhotine keramike iste posude. Snimanje je provedeno na keramici pronađenoj na nekoliko arheoloških lokaliteta koristeći hiperspektralni skener ImSpectorV9 koji pokriva valne duljine od 430 do 900 nm.



Slika 4: Primjeri snimaka keramike pronađene na arheološkim lokalitetima (Miljković i Gajski, 2016)



Slika 5: Spektralni dijagrami uzoraka (Miljković i Gajski, 2016)

Nakon analize spektralnih dijagrama vidljive su sličnosti i razlike u spektralnim otiscima pojedinih uzoraka (Miljković i Gajski, 2016).

3. Terestričko hiperspektralno snimanje

Terestričko hiperspektralno snimanje odnosi se na upotrebu hiperspektralnih senzora koji su postavljeni na zemaljske platforme, najčešće tronožac. Tehnologija se koristi za detaljnu analizu različitih površinskih karakteristika u poljoprivredi, ekologiji, geologiji, zaštiti okoliša i dr.

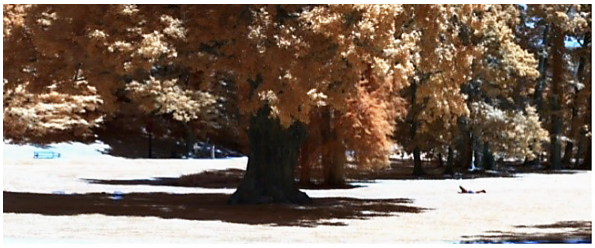
Primjer: Prikaz terestričkog hiperspektralnog snimanja sa preliminarnim rezultatima prikazan je u članku "Hyperspectral Imaging in Preservation of Croatia's Historic Trees: A Case Study of Dedek Oak in Maksimir Park" (Babić i dr., 2023). Sniman je zaštićeni hrast lužnjak Dedek u Park šumi Maksimir i njegovi klonovi koji se nalaze u Šumarskom institutu. Provedeno istraživanje trebalo je utvrditi podudaraju li se spektralni potpisi hrasta sa njegovim klonovima. Zbog zakonske zaštite nije bilo moguće uzeti uzorke i snimiti ih u laboratorijskim uvjetima te je stoga snimanje obavljeno na terenu hiperspektralnim kamerama HySpex VNIR-1800 I SWIR-384.

Eksperimentalni rezultati prikazani su samo sa analizom radijance ali ne i reflectance te su na osnovu toga dobiveni sljedeći rezultati:

Rezultati ukazuju na sličnosti Dedeka i njegovih klonova u VNIR spektru, ali postoje odstupanja u SWIR spektru, posebno u rasponima 1350-1500 nm i 1800-2000nm (Babić i dr., 2023).

4. Hiperspektralno snimanje iz zraka

Hiperspektralno snimanje iz zraka je tehnika daljinskog istraživanja koja kao platformu za hiperspektralna snimanja koristi avione, dronove ili satelite. Koristi se za prikupljanje detaljnih spektralnih podataka o površini Zemlje, omogućava analizu širokog spektra elektromagnetnog zračenja koje se reflektira od različitih objekata pružajući visoku rezoluciju i detaljne informacije o njihovim spektralnim svojstvima. Oprema potrebna za hiperspektralno snimanje iz zra-



Slika 6: SWIR snimka hrasta Dedek



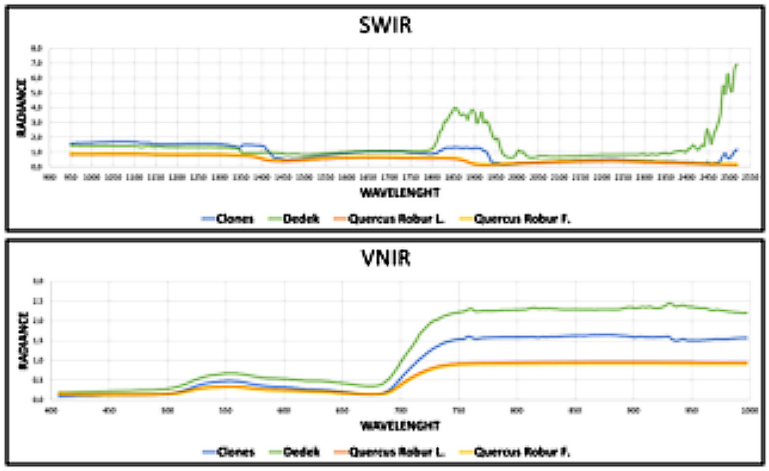
Slika 7: SWIR snimka klonova



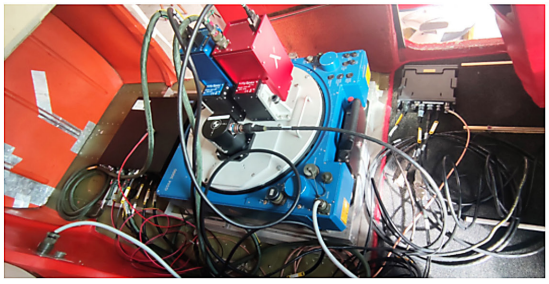
Slika 8: VNIR snimka hrasta Dedek



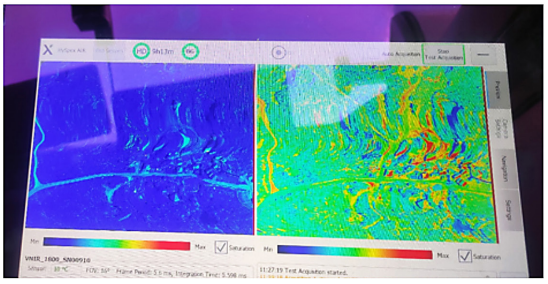
Slika 9: VNIR snimka



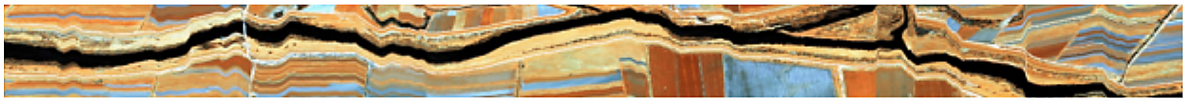
Slika 10: Dobiveni spektralni potpisi u SWIR i VNIR rasponu



Slika 11: Hiperspektralni senzor na platformi za snimanje



Slika 12: Računalni sustav



Slika 13: SWIR snimka



Slika 14: VNIR snimka

ka sastoji se od hiperspektralnog senzora, platforme za snimanje (Slika 11), navigacijske i kontrolne opreme, računalnog sustava (Slika 12) i izvora napajanja. Kao rezultat dobiju se SWIR i VNIR snimke prikazane na Slikama 13 i 14.

5. Upotreba

Upotreba hiperspektralnih senzora pruža novu metodu za praćenje onečišćenja okoliša u okolici rudnika kvantitativnim otkrivanjem spektralnih varijacija i abnormalnosti biljaka. Identifikacije zagađivača može se provesti i iz satelitskih podataka (Hyperion) (Gan i dr., 2004).

Nadalje, dokumentacija i analiza dokaza s mjesta zločina od velike su važnosti u svakoj forenzičkoj istrazi. Analize hiperspektralnih snimki mogu se koristiti za detekciju krvi na mjestu zločina (Romaszewski i dr., 2021), u forenzičkoj analizi dokumenata za otkrivanje krivotvorenih papira u dokumentima s više stranica (Francis i dr., 2021), za otkrivanje i analizu mrlja od pića na papirnatim ručnicima (Melit Devassy i George, 2021), za analizu ostataka eksploziva na ljudskim otiscima ruku (MÁF de la Ossa i dr., 2014) i dr.

Identifikacija tipa minerala jedna je od najuspješnijih primjena hiperspektralnih podataka u geologiji. Fina identifikacija minerala pomoću hiperspektralnih podataka uključuje identifikaciju podklase minerala, istraživanje sastava minerala, izdvajanje bo-

gatstva minerala i detekciju drugih mikroskopskih informacija u mineralu (Zhizhong i dr., 2012; Krupnik i Khan, 2019).

Poljoprivreda je još jedno od područja u kojima upotreba spektralnih senzora daje jako dobre rezultate. Hiperspektralna tehnologija postigla je napredak u prikupljanju poljoprivrednih informacija i otkrivanju vanjskih ili unutarnjih svojstava kvalitete poljoprivrednog proizvoda (Wang i dr., 2021). Na primjer, podaci se mogu koristiti za za određivanje sadržaja dušika, sadržaj klorofila, indeksa lisne površine, sadržaja vode u usjevima te za predviđanje rasta usjeva i prinosa za potrebe precizne poljoprivrede (Awad, 2019). Nadalje, hiperspektralnom analizom može se otkriti sadržaj kofeina u zrnima kave (Zhang i dr., 2017) te procijeniti kvalitetu, sigurnost, oštećenja (defekata i gljivica), čistoću i sastav sjemena (Feng i dr., 2019).

U industriji hrane, hiperspektralne snimke koriste se za dobivanje informacija o pojedinačnim pladnjevima s hranom u svrhu otkrivanja neispravnih pladnjeva s kontaminiranim predmetima (Medus i dr., 2021).

Upotreba spektralnih senzora vrlo je raširena i u medicini. Tako, npr., „State-of-the-art" metoda za procesuiranje slika daje nove mogućnosti u dijagnozi bolesti. Takav primjer je poboljšanje dijagnoze reumatoidnog artritisa korištenjem preklapanja snimaka različitih valnih duljina (Minet i dr., 2009). Hiperspektralni senzori se, nadalje, mogu naći i u operacijskim salama gdje mogućnost detekcije malih valnih duljina omogućava kirurgu razlikovanje tkiva (Nouri i dr., 2013).

6. Zaključak

Hiperspektralna tehnologija pokazuje veliki potencijal u različitim područjima primjene, pružajući mogućnosti za detaljnu analizu materijala i površina koje nisu dostupne tradicionalnim metodama. Njena svestranost i sposobnost prikupljanja preciznih podataka čine je nezamjenjivim alatom u istraživanjima prirodnih i društvenih pojava. Kroz daljnji razvoj i primjenu ove tehnologije, možemo očekivati značajan doprinos u mnogim znanstvenim i praktičnim disciplinama.

Literatura

Awad, M. M., Alawar, B., Jbeily, R. (2019): A new crop spectral signatures database interactive tool (CSSIT). Data, 4(2), 77.

Babić, L., Miljković, V., Odak, I., Đapo, A. (2023): Hyperspectral Imaging in Preservation of Croatia's Historic Trees: A Case Study of Dedek Oak in Maksimir Park. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 48, 1853-1859.

Feng, L., Zhu, S., Liu, F., He, Y., Bao, Y., Zhang, C. (2019): Hyperspectral imaging for seed quality and safety inspection: A review. Plant methods, 15(1), 1-25.

Francis, J., Madathil, B., George, S. N., George, S. (2021): A comprehensive tensor framework for the clustering of hyperspectral paper data with an application to forensic document analysis. IEEE Access, 10, 6194-6207.

Gan, F.P., Liu, S.W., Zhou, Q. (2004): Identification of Mining Pollution Using Hyperion Data at Dexing Copper Mine in Jiangxi Province, China. Earth Science (Journal of China University of Geosciences), 29(1), 119-126.

Krupnik, D., & Khan, S. (2019): Close-range, ground-based hyperspectral imaging for mining applications at various scales: Review and case studies. Earth-Science Reviews, 198, 102952.

MÁF de la Ossa, M. Á. F., Amigo, J. M., García-Ruiz, C. (2014): Detection of residues from explosive manipulation by near infrared hyperspectral imaging: A promising forensic tool. Forensic Science International, 242, 228-235.

Medus, L. D., Saban, M., Frances-Villora, J. V., Bataller-Mompean, M., Rosado-Muñoz, A. (2021): Hyperspectral image classification using CNN: Application to industrial food packaging. Food Control, 125, 107962.

Melit Devassy, B., George, S. (2021): Forensic analysis of beverage stains using hyperspectral imaging. Scientific reports, 11(1), 6512.

Miljković, V., Gajski, D. (2016): Adaptation of industrial hyperspectral line scanner for archaeological applications. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 41, 343-345.

Miljković, V. (2017): Prostorna kalibracija multispektralnih i hiperspektralnih senzora u blizupredmetnoj fotogrametriji. Doktorski rad. Zagreb: Sveučilište u Zagrebu Geodetski fakultet.

Minet, O., Scheibe, P., Beuthan, J., Zabarylo, U. (2009): Correction of motion artefacts and pseudo colour visualization of multispectral light scattering images for optical diagnosis of rheumatoid arthritis. Saratov Fall Meeting 2009: International School for Junior Scientists and Students on Optics, Laser Physics, and Biophotonics, 7547, 81-88.

Nouri, D., Lucas, Y., Treuillet, S. (2013): Calibration and test of a hyperspectral imaging prototype for intra-operative surgical assistance. International Society for Optics and Photonics, SPIE Medical Imaging, 8676, 229-237.

Romaszewski, M., Głomb, P., Sochan, A., Cholewa, M. (2021): A dataset for evaluating blood detection in hyperspectral images. Forensic Science International, 320, 110701.

Šemanjski, S., Gajski, D., Bajić, M. (2008): Transformation of the hyperspectral line scanner into a strip imaging system. First international conference on remote sensing techniques in disaster

management and emergency response in the mediterranean region, Zadar, Croatia, 369-375.

Wang, C., Liu, B., Liu, L., Zhu, Y., Hou, J., Liu, P., Li, X. (2021): A review of deep learning used in the hyperspectral image analysis for agriculture. Artificial Intelligence Review, 54(7), 5205-5253.

Zhang, C., Jiang, H., Liu, F., He, Y. (2017): Application of near-infrared hyperspectral imaging with variable selection methods to determine and visualize caffeine content of coffee beans. Food and Bioprocess Technology, 10, 213-221.

Zhizhong, L., Rihong, Y., Fuxing, D., Peijun, D., Xianfeng, Z., Bingxiang, T., ... Hongjun, S. (2012): A review on the geological applications of hyperspectral remote sensing technology. In 2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS),1-4.

Hyperspectral Technology and Application Possibilities

Abstract

Hyperspectral technology has been developing for over 30 years and represents an advanced method of collecting data on light reflected from or emitted by observed objects, enabling detailed analyses of materials based on their spectral signatures. Traditional methods of material detection and analysis are time-consuming, labor-intensive, and can destroy samples. In recent years, hyperspectral technology has been increasingly used because it allows rapid and non-destructive detection with low experimental requirements and high operability. Hyperspectral imaging allows obtaining detailed information about an object that is not visible to the naked eye or with conventional imaging methods. It can be used on a micro level to detect micrometer-sized particles in laboratory samples, but also at the macro level for detecting changes on a global scale. When used to collect spatial information, this technology goes a step further than classical photogrammetry and standard RGB imaging. Its application helps in the research and analysis of various materials and environments on Earth, providing a deeper understanding of natural processes, ecosystems, and geological phenomena. The versatility of this technology is its greatest advantage. This paper briefly presents the technology itself and its application in various segments of social and natural research activities – from agronomy, forestry, and environmental protection to archaeology, urban planning, geology, as well as fields such as medicine, the food industry, forensics, and others.

Keywords: *application areas, hyperspectral technology, methods of collecting hyperspectral data*

Mogućnosti primjene jeftinog LiDAR sustava za geodetsku izmjeru

Loris Redovniković[1], Antun Jakopec[2]

[1] Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, lredovnikovic@geof.hr

[2] SLAM Geodezija d. o. o., Ulica Bože Težaka 1A, Varaždin, Hrvatska, ajakopec@geof.hr

Sažetak

U današnje vrijeme, LiDAR tehnologija je sve prisutnija u svakodnevnoj geodetskoj praksi. Od nedavno su nam besplatno dostupni LiDAR podaci snimanja iz zraka za područje cijele Republike Hrvatske (RH). Iako su ti podaci vrlo značajni za veliki broj korisnika, često se javlja potreba za trodimenzionalnim podacima veće gustoće. Na tržištu postoji veliki broj skenera i uređaja za mobilno kartiranje, ali je njihova cijena i dalje prilično visoka te se većina geodetskih firmi još nije odlučila za nabavku takve opreme. Razvojem tehnologije cijene samog hardvera postaju sve povoljnije, ali integracija hardvera u funkcionalnu cjelinu i razvoj softvera koji omogućuje kvalitetnu obradu prikupljenih podataka i dalje predstavlja izazovi. U ovom radu, naglasak je na sustavu za mobilno lasersko kartiranje koji je temeljen na hardveru i softveru otvorenog koda. Na temelju provedenih mjerenja i obrade podataka iznijeli bi se dobiveni rezultati i dali zaključci vezani uz buduću primjenu slične tehnologije.

Ključne riječi: *LiDAR, mobilno kartiranje, skeniranje, SLAM, softver otvorenog koda*

1. Uvod

Terenski dio posla uglavnom je skuplji od uredskog. Iz toga razloga se nastoji proces prikupljanja terenskih podataka na terenu što više ubrzati. Klasična izmjera ima neke prednosti u odnosu na, danas sve prisutnije, masovno prikupljanje podataka. Te prednosti se očituju u točnosti i maloj količini prikupljenih bitnih podataka, što za posljedicu ima malu količinu podataka koje treba pohraniti. Za masovno prikupljanje podataka u geodeziji se danas najčešće koristi fotogrametrija i/ili lasersko skeniranje. Prednost fotogrametrije je dobivanje 3D modela u boji koji se mogu koristiti u razne svrhe. Nedostatak fotogrametrije je potreba za snažnim računalima koja bi omogućila procesiranje velikog broja fotografija, velika količina memorije potrebne za pohranu i nemogućnost dobivanja kvalitetnih podataka u nekim situacijama kao npr. u loše osvjetljenim prostorima ili za izmjeru ispod krošnji drveća i slično. Lasersko skeniranje manje je zahtjevno za procesiranje od fotogrametrije, može u većoj mjeri prodrijeti kroz vegetaciju i ne treba dodatnu rasvjetu za slabo osvjetljene prostore. Geometrija 3D modela na velikim područjima uglavnom je nešto kvalitetnija ukoliko koristimo lasersko skeniranje, a količina podataka za pohranu i zahtjevi za računalnim resursima su nešto manji. Mobilno lasersko skeniranje omogućava brzo i učinkovito prikupljanje velike količine podataka uz malo slabiju točnost u odnosu na statičko skeniranje. Glavni nedostatak mobilnog laserskog skeniranje uglavnom je do sada bila visoka cijena takve tehnologije. Sustavi za mobilno lasersko skeniranje do nedavno su bili prilično skupi, ali sa napretkom tehnologije to se polako mijenja i danas je na tržištu moguće naći prilično jeftine sustave. U ovom radu ispitan je jedan takav sustav i dani su rezultati njegove primjene u praksi.

2. Sustavi za mobilno lasersko kartiranje

Laserski daljinomjeri se već dugo vremena koriste u geodeziji kao i u mnogim drugim srodnim granama. Odašiljanjem laserske zrake i mjerenjem vremena potrebnog da se ona odbije od objekta i vrati do prijemnika može se odrediti udaljenost do objekta. Taj postupak na engl. se nazva Light Detection And Ranging ili skraćeno LiDAR.

Ako se jedna laserska zraka konstantno rotira oko vertikalne osi u prostoru, dobivamo dvodimenzionalni laserski skener, kakav se danas često koristi u pametnim usisavačima prašine. Ako se umjesto jedne zrake u sustav uključi više laserskih zraka na različitim visinama onda dobivamo rotacijski 3D LiDAR.

Tradicionalni rotacijski 3D LiDAR-i su do nedavno bili vrlo skupi, prvenstveno zbog mehaničkih rotacijskih dijelova, koji su bili prilično zahtjevni za izradu, što je rezultiralo njihovom visokom cijenom. Također zbog ugrađenih elektromehaničkih sustava bili su osjetljiviji na vibracije. Među najpoznatije proizvođače rotacijskih laserskih skenera spadaju Velodyne, RIEGL i Ouster. Od rotacijskih skenera u praksi se najčešće koristio Velodyne-ov VLP-16 senzor, zbog svoje relativno niske cijene od 4000 $.

Razvoj solid-state LiDAR-a to polako mijenja jer je njihova cjelokupna proizvodnja bazirana na čipu, što značajno smanjuje cijenu njihove izrade i povećava njihovu otpornost na rad u otežanim uvjetima (URL 1).

Mnoge startup kompanije diljem svijeta počinju razvijati solid-state LiDAR-e i ulažu se značajna materijalna sredstva u njihovu proizvodnju. Neki od poznatijih proizvođača solid-state LiDAR-a su Livox,



Slika 1: Solid-state LiDAR Livox Mid 360 (prema URL 2)

Robosense, Quanergy, Innoviz, Blickfeld i Velodyne. Od solid-state LiDAR-a trenutno se u praksi najčešće koristi Livox Mid360 senzor (Slika 1).

Iako se solid-state LiDAR-i već nekoliko godina mogu pronaći na tržištu, uglavnom je postojao problem sa softverima, koji su potrebni da bi se iz samog LiDAR-a mogao dobiti povezani oblak točaka. Razne firme su koristile različite solid-state LiDAR-e i za njih razvijale specijalizirane softvere te bi na kraju prodavali gotove sustave za mobilno lasersko skeniranje, koji su opet imali prilično visoke cijene.

Sustav za mobilno lasersko skeniranje može se sastojati samo od LiDAR-a, tada pričamo o laserskoj odometriji, gdje se putanja sustava dobiva samo na temelju mjerenja duljina od LiDAR-a do objekta. Takvi sustavi uglavnom nisu dovoljno pouzdani i često se nadopunjuju sa inercijalnom mjernom jedinicom (IMU) koja sustav čini otpornijim na nagle promjene smjera i ubrzanja. Da bi se dobio oblak točaka u boji sustavu se može dodati RGB kamera, a da bi se povećala točnost apsolutnog pozicioniranja na većim otvorenim područjima, u sustav se može implementirati i GNSS senzor. Gore nabrojani senzori su oni koji se danas najčešće koriste u sustavima za mobilno kartiranje, ali se njima po potrebi mogu dodavati i razni drugi senzori.

Na našem tržištu postoji već puno gotovih sustava za mobilno lasersko kartiranje kao što su Faro i GeoSLAM (URL 3), DJI Zenmuse L2 (URL 4), Stonex (URL 5) i GreenWaley (URL 6).

U svijetu se pojavljuju sustavi za mobilno kartiranje čiji se hardver i/ili softver bazira na otvorenim (besplatno dostupnim) podacima. Najpoznatiji takav primjer je Open MMS (URL7) koji je bio vrlo popularan 2021. godine, ali je na žalost u međuvremenu njegov razvoj stao.

U novije vrijeme na internetu se pojavio LiDAR MandEye projekt koji nudi integrirano rješenje otvorenog hardvera (URL 8) i softvera (URL 9). Prednost ovakvog pristupa je u tome da krajnji korisnik može sam sagraditi svoj sustav za prikupljanje podataka, koji teži manje od 1 kg, za manje od 1000 €, što je znatno niža cijena od postojećih sustava na tržištu.

3. Softveri za prikupljanje i obradu podataka

U prethodnom poglavlju je spomenuto da softver ima vrlo bitnu ulogu u sustavima za mobilno kartiranje. Postoji mnoštvo softvera za mobilno lasersko kartiranje. Neki od njih rade u realnom vremenu što ima određene prednosti jer je odmah na terenu moguće vidjeti rezultat skeniranja, ali takav sustav ima i određenih nedostataka jer je za prikaz rezultata potrebno brzo procesiranje prikupljenih podataka, što ima za posljedicu ili veće zahtjeve za računalnim resursima ili odbacivanje nekih informacija da bi se dobilo na brzini, što često rezultira lošijom točnošću.

Softveri u realnom vremenu se češće primjenjuju u robotici i samovozećim automobilima, dok softveri koji rade u naknadnoj obradi mogu dati točnije rezultate i češće se koriste u geodeziji.

Moguće je napraviti kompaktan sustav temeljen na GNSS-u, IMU-u, LiDAR-u i/ili kameri, koji mora biti kvalitetno kalibriran da bi davao dobre rezultate i koji uglavnom ima visoku cijenu i dobro radi na otvorenim područjima, kao što je slučaj prilikom skeniranja iz zraka.

Ako se želi dobiti dobre rezultate u zatvorenim prostorima ili u područjima gdje je slab GNSS signal, danas se uglavnom koriste algoritmi za istovremeno određivanje pozicije i kartiranje (SLAM). Postoji mnoštvo literature vezane uz SLAM, a nedavno je i u Geodetskom listu izašao članak o povezanosti SLAM-a i geodezije (Jakopec i dr., 2023.)

U prethodnom poglavlju su spomenute firme koje su razvijale specijalizirane sustave za mobilno lasersko skeniranje kao i softver koji su ti sustavi koristili. Među poznatije takve firme ubrajaju se već spomenuti GeoSLAM, Stonex i GreenWaley koji koriste SLAM algoritme. Za mobilno lasersko kartiranje iz zraka također postoje specijalizirane kompanije kao što su YellowScan, Emesent, LiDAR USA, Phoenix i mnoge druge.

Osim komercijalnih softvera, pojavljuju se i besplatni softveri za prikupljanje podataka kao i za naknadnu

obradu dobivenih rezultata. Od besplatnih softvera za prikupljanje terenskih podataka zanimljivi su softveri sa sveučilišta u Hog Kong-u (URL 10) koji uglavnom rade s Livox-ovim LiDAR senzorima i nude dosta mogućnosti za odometriju u realnom vremenu, ali su uglavnom vezani uz Ubuntu operativni sustav i njihova instalacija je prilično zahtjevna. Softver *r3live* ima mogućnost spajanja sa kamerom i kalibracije sustava pomoću također besplatnog softvera *livox_camera_calib*, što omogućava dobivanje obojenog oblaka točaka. Glavni nedostatak ovih softvera prilikom primjene u geodetske svrhe je nemogućnost zatvaranja figura i izjednačenja, što za posljedicu ima nedovoljnu točnost odnosno homogenost dobivenih rezultata.

3.1. MandEye sustav za mobilno kartiranje

Od besplatnih softvera koji imaju potencijala za primjenu u geodetske svrhe zanimljiv je i već spomenuti MandEye koji radi na Windows okruženju, ima riješeno izjednačenje i zatvaranje figura, kao i mogućnost georeferenciranja. Nedostatak je što trenutno podržava samo Livox-ove LiDAR-e zadnje generacije.

Tvorac softvera dr. sc. Janusz Będkowski i njegov tim neprestano rade na njegovom usavršavanju. Za razvoj softvera otvorenog koda vrlo je bitna uključenost zajednice, što podrazumijeva iskazivanje potreba, ukazivanje na probleme i nedostatke kod aplikacije kao i aktivno sudjelovanje na poboljšanju bilo hardverskog ili softverskog dijela.

Hardver nudi dvije mogućnosti, statično i mobilno skeniranje. Podaci se pohranjuju na USB memoriju. Softver se sastoji od tri osnovna dijela. Prvi dio je LiDAR odometrija. Drugi dio služi za zatvaranje figura, učitavanje georeferenciranih skenova i razbijanje većih trajektorija na manje. Treći dio služi za povezivanje više različitih sesija u jedinstvenu cjelinu. Postoji još i dodatni softver za bojanje statičkog oblaka točaka, a intencija je da se u budućnosti nešto slično napravi i s mobilnim skenom. Više o teorijskoj pozadini softvera može se saznati u dostupnoj literaturi (Będkowski, 2022.)

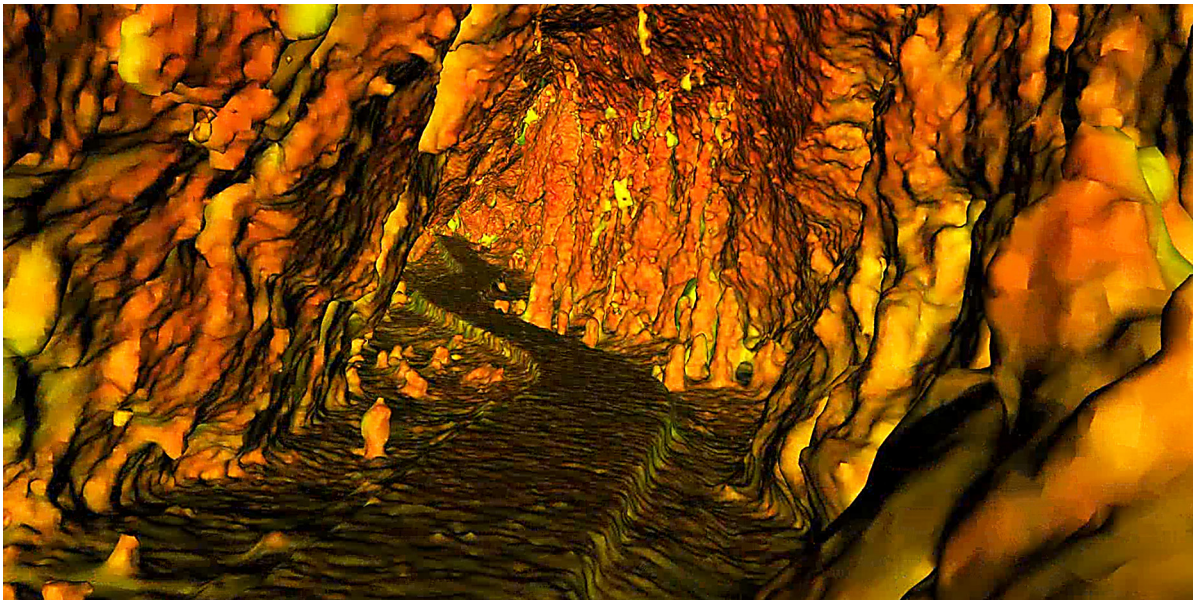
Da bi pridonijeli zajednici krenuli smo sa sastavljanjem i korištenjem spomenutog sustava i u nastavku će biti izneseni neki od dobivenih rezultata.

4. Praktična primjerna MandEye sustava za mobilno kartiranje

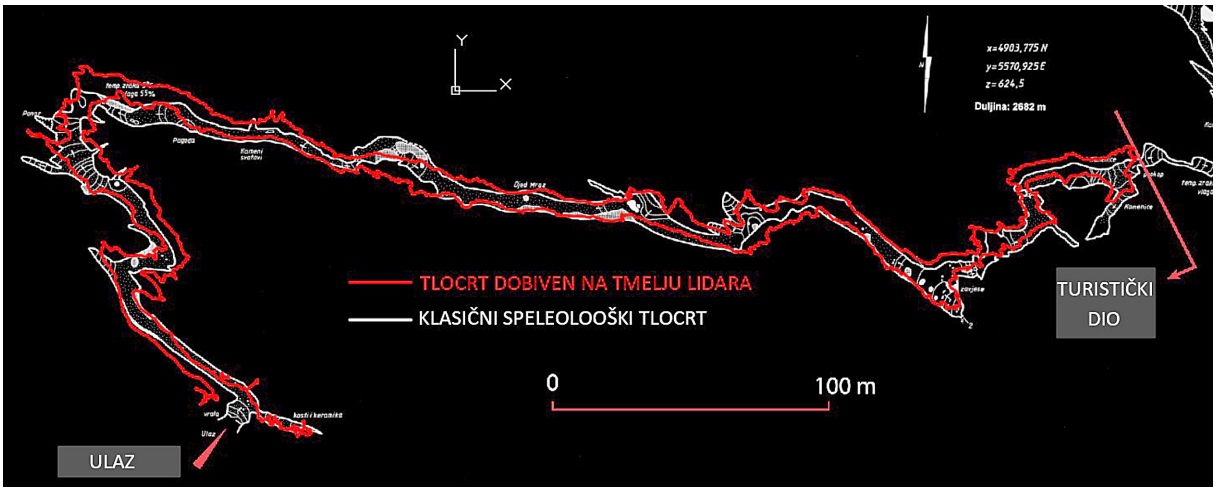
Kako se radi o relativno novoj tehnologiji, koja je još u početnom stadiju svog razvoja, ne treba imati previsoka očekivanja po pitanju homogenosti i točnosti dobivenih podataka, ali se u budućnosti svakako očekuje značajno poboljšanje i puno vreća upotreba nego što je to danas slučaj. U nastavku će biti opisana dva slučaja konkretne primjene MandEye sustava za mobilno kartiranje. U oba slučaja zahtjevi za točnošću nisu bili visoki.

4.1. Primjena za izmjeru i kartiranje speleoloških objekata

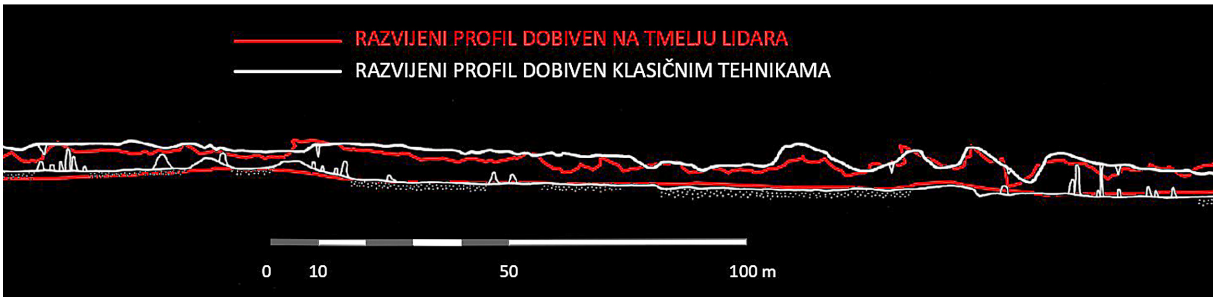
Prvi slučaj primjene MandEye sustava za mobilno lasersko kartiranje bila je izmjera speleoloških objekata. Laserski sustavi za mobilno kartiranje odlični su za izmjeru speleoloških objekata jer ne trebaju dodatnu rasvjetu. Zahtijevana točnost pri izmjeri speleoloških objekata nije visoka jer je glavni rezultat speleoloških istraživanja nacrt špilje sa kojega je potrebno vidjeti na kojim mjestima je špilja uska ili niska i kako se proteže u položajnom i visinskom smislu. Ukoliko nema drugih speleoloških objekata u blizini točnost apsolutnog pozicioniranja nije od velike važnosti. Budući da se speleologija uglavnom bazira na volonterskom djelovanju njezinih članova i da je neprofitna djelatnost, speleološka društva do sada nisu bila u mogućnosti koristiti LiDAR tehnologiju, a MandEye sustav svojom cijenom omogućuje speleološkim društvima



Slika 2: Trodimenzionalni model unutrašnjosti špilje dobiven pomoću Mandeye sustava



Slika 3: Usporedba tlocrta turističkog dijela Donje Cerovačke špilje



Slika 4: Usporedba razvijenog profila dijela Donje Cerovačke špilje

da ga mogu priuštiti. Druga bitna stavka je već spomenuti softver koji radi na Windows okruženju i kojega je puno lakše instalirati i koristiti zato što ima i grafičko sučelje.

U konkretnom slučaju MandEye sustav je korišten za izmjeru turističkog dijela Donje Cerovačke špilje. Za izmjeru oko 700 m špilje jednom čovjeku je bilo potrebno 15-tak minuta. Klasičnim speleološkim tehnikama za izmjeru istog dijela špilje trebalo bi barem dvoje do troje ljudi i ona bi trajala danima, a često i tjednima. Obrada podataka prikupljenih pomoću MandEye sustava traje otprilike koliko i izmjera na terenu, a obrada podataka prikupljenih klasičnim načinom crtanja traje opet danima ili tjednima, a kako se radi o volonterskoj djelatnosti često se ovaj konačni nacrt „u fino" nikada ni ne napravi.

Zbog velikog broja točaka prikupljenih pomoću mobilnog laserskog skeniranja moguće je dobiti vjeran trodimenzionalan model špilje (Slika 2), dok se pomoću klasičnog speleološkog kartiranja dobivaju samo dvodimenzionalni podaci.

Kao što je već spomenuto, glavni rezultat speleološke djelatnosti je izrada speleološkog nacrta. Speleološki nacrt se sastoji od tlocrta špilje na kojem se vidi pružanje špilje projicirano na horizontalnu ravninu i razvijenog profila špilje, na kojem se može vidjeti duljina špilje i njeno pružanje u visinskom smislu.

Na Slici 3 je prikazana usporedba tlocrta turističkog dijela Donje Cerovačke špilje dobivenog na temelju mobilnog laserskog skeniranja sa postojećim tlocrtom špilje koji je izrađen klasičnim speleološkim tehnikama.

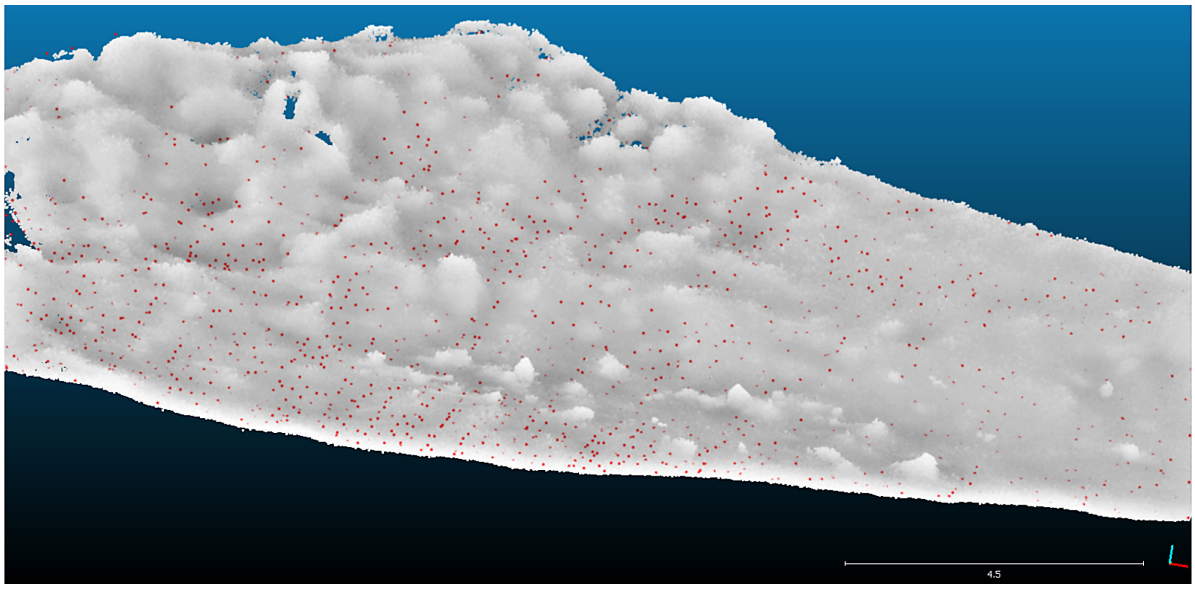
Iz slike je vidljivo da se tlocrti međusobno podudaraju, a razlike koje postoje uglavnom su nastale zato što se prilikom mobilnog laserskog kartiranja nismo zavlačili u neke uske i niske kanale, kao i zbog mogućih pogrešaka prilikom klasične speleološke izmjere.

Na Slici 4 prikazana je usporedba razvijenog profila za jedan dio istoga kanala, na kojoj je također vidljiva podudarnost, a razlike koje se pojavljuju nastale su uglavnom radi toga što se u klasičnom nacrtu crta najviši i najniži dio špilje, dok se kod LiDAR podataka razvijeni profil dobio automatiziranim postupkom na temelju trajektorije po kojoj se hodalo prilikom izmjere.

Važno je naglasiti da u slučaju korištenja LiDAR-skih podataka cijeli postupak dobivanja tlocrta i razvijenog profila može biti automatiziran u besplatnom softveru CloudCompare (URL 11), što uvelike ubrzava i olakšava posao speleolozima.

4.2. Primjena za kartiranje reliktne sedre na području Plitvičkih jezera

Jedan od projekata koji je Geodetski fakultet iz Zagreba radio u suradnji sa Geografskim odsjekom PMF-a bio je kartiranje reliktnih sedrenih barijera na području Plitvičkih jezera. Za potrebe projekta trebalo je snimiti izdanke reliktnih sedrenih barijera koji su se uglavnom nalazili u gustoj crnogoričnoj šumi.



Slika 5: Razlika u gustoći oblaka točaka

Uporaba GNSS-a u takvim uvjetima nije davala zadovoljavajuće rezultate. Fotogrametrija se pokazala kao prilično dobra metoda, ali za izmjeru tako velikog područje trebalo bi uložiti jako puno vremena i truda. Klasična izmjera u takvim uvjetima također bi bila vrlo zahtjevna i dugotrajna.

Kako zahtjevi za točnost na ovome projektu također nisu bili visoki (tražila se točnost od pola metra u položajnom i visinskom smislu) izmjera je provedena pomoću MandEye sustava za mobilno lasersko kartiranje. Za izmjeru je i u ovom slučaju bio dovoljan jedan čovjek. Za manje od jednog sata snimljene su dvije lokacije koje su zajedno imale površinu od oko 2 ha. Obrada podataka u uredu također nije iziskivala puno vremena ni truda.

Na Slici 5 crveno su označene točke dobivene na temelju laserskog skeniranja iz zraka, a bijelom bojom su označene točke dobivene pomoću MandEye sustava. Oblak točaka dobiven pomoću MandEye sustava je nekoliko tisuća puta gušći i na njemu je moguće vidjeti sedrene izdanke, za razliku od zračnih LiDAR podataka na kojima to nije moguće.

U ovom slučaju LiDAR podaci iz zraka poslužili su za georeferenciranje MandEye oblaka točaka, koji je prethodno približno smješten u prostor na temelju GNSS opažanja dobivenih pomoću jeftinog Ublox-ovog F9P prijemnika i ANN-MB antene. Na terenu je korištena SW Maps aplikacija u kombinaciji s android telefonom, a slično se moglo dobiti direktnim povezivanjem GNSS-a s MandEye sustavom, ali to autori tek planiraju implementirati.

5. Zaključak

Iz svega navedenog može se zaključiti da sustavi za mobilno lasersko kartiranje mogu naći svoju primjenu u geodeziji. Treba naglasiti da je potreban oprez prilikom davanja rezultata, posebno kada se radi o projektima koji zahtijevaju visoku točnost. Budući da sustavi za mobilno lasersko kartiranje nisu toliko točni i homogeni kao statični skeneri njihova primjena još uvijek je više vezana za zadatke kod kojih se traži manja točnost. Velika prednost koju pružaju sustavi za mobilno kartiranje je njihova mobilnost i efikasnost prilikom prikupljanja velike količine podataka u kratkom vremenu. Kako su nam od nedavno besplatno dostupni podaci laserskog zračnog skeniranja za područje cijele RH u budućnosti će često biti potrebno progustiti te podatke, a u tu svrhu vrlo je praktično i primjenjivo korištenje sustava za mobilno lasersko skeniranje. Također pomoću njih se vrlo brzo i lako mogu pratiti promjene u prostoru koje nastaju kroz vrijeme. Nije zanemariva ni mogućnost dobivanja trajektorije u prostorima u kojima nemamo podršku GNSS-a, što se također može primjenjivati u razne svrhe. U radu su opisana dva primjera korištenja MandEye sustava. Navedeni sustav moguće je sastaviti za manje od 1000 €, a za očekivati je da će cijene takvih sustava i dalje padati. Također se može očekivati da će primjena sustava za mobilno lasersko kartiranje u budućnosti biti puno zastupljenija nego što je to do sada bio slučaj. Kolegama geodetima ostavljamo da razmisle gdje bi sve mogli primijeniti ovakvu tehnologiju.

Literatura

Będkowski J. (2022). Large-Scale Simultaneous Localization and Mapping, Springer, Singapore

Jakopec, A., Redovniković, L., Barković, Đ., Zrinjski, M. (2023). SLAM i geodezija, Geodetski list, 77 (100), 3, 235-271.

URL 1: https://www.allaboutcircuits.com/news/solid-state-lidar-faster-cheaper-better/ , (15. 6. 2024.).

URL 2: Livox MID-360, https://www.livoxtech.com/mid-360 , (15. 6. 2024.).

URL 3: Faro i Geoslam, https://geocentar.com/laserski-skeneri/, (15. 6. 2024.).

URL 4: Zenmuse L2, https://geocentar.com/bespilotne-letjelice/, (15. 6. 2024.).

URL 5: Stonex, https://stonex.hr/product-category/3d-skeneri/, (15. 6. 2024.).

URL 6: Greenvalley, https://www.tehnomehanik.com/proizvodi/, (15. 6. 2024.).

URL 7: OpenMMS, https://www.openmms.org/, (15. 6. 2024.).

URL 8: Mandeye Controller, https://github.com/JanuszBedkowski/mandeye_controller, (15. 6. 2024.).

URL 9: Mandeye software, https://github.com/MapsHD/HDMapping, (15. 6. 2024.).

URL 10: HKU-Mars-Lab, https://github.com/hku-mars, (15. 6. 2024.).

URL 11: CloudCompare, https://www.danielgm.net/cc/. (15. 6. 2024.).

Possibilities of Applying a Low-Cost LiDAR System for Geodetic Surveying

Abstract

Nowadays, LiDAR technology is increasingly present in everyday geodetic practice. Since recently, LiDAR aerial survey data for the whole of the Republic of Croatia has been freely available to us. Although this data is very useful for many users, there is often a need for higher density three-dimensional data. There are many scanners and devices for mobile mapping on the market, but their price is still quite high, and most geodetic companies have not yet decided to purchase such equipment. With the development of technology, the prices of the hardware itself are becoming more and more favorable, but the integration of the hardware into a functional unit and the development of software that enables high-quality processing of the collected data are still challenges. In this paper, the emphasis is on a mobile mapping system based on open-source hardware and software. Based on the measurements and data processing, the obtained results would be presented, and conclusions related to the future application of similar technology would be given.

Keywords: *LiDAR, scanning, SLAM, mobile mapping, open-source software*

5.

EDUKACIJA I ZAKONSKE SMJERNICE U GEODETSKO-GEOINFORMATIČKOJ PRAKSI

Svemir – novi sadržaj studijskih programa geodezije i geoinformatike

Željko Bačić[1], Vesna Poslončec-Petrić[1], Danijela Ignjatović[2]

[1] Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, zbacic@geof.hr, vesna.posloncec@geof.hr

[2] International Space University, 1 rue Jean-Dominique Cassini, Parc d'Innovation 67400 Illkirch-Graffenstaden, Francuska, danijela.stupar@isunet.edu

Sažetak

Osnovne postavke geodezije kao struke zasnivaju se na mjerenju, propisanim postupcima, točnosti, preciznosti, određivanju pogrešaka, vođenju i čuvanju, što determinira struku kao konzervativnu u pogledu pristupa rješavanju zadataka koji se stavljaju pred nju. Takav pristup je donekle u raskoraku s današnjim trendovima modernog svijeta, što se održava i na konceptu i sadržaju studijskih programa geodezije i geoinformatike koji se danas izvode u Hrvatskoj. Studijski programi geodezije i geoinformatike danas u Hrvatskoj osmišljeni su prije 20-tak godina i može se argumentirati, uz sve modernizacije koje su proveden proteklih godina, da isti ne odgovaraju u potpunosti potrebama korisnika. Nove znanstvene spoznaje i tehnologije oslikavaju se kroz razvoj digitalnog društva koje potiče nestanak klasičnih i pojavu novih profesija, interdisciplinarnost, ubrzanje svekolikih procesa i nove pravce razvoja čovječanstva, nameću potrebu redefinicije poslova i struka, a time i sadržaja i forme izvođenja obrazovnih programa. Jedno od područja ljudske aktivnosti od posebnog interesa danas je osvajanje i iskorištavanje resursa Svemira koje je u proteklih 10-tak godina dobilo izuzetno na važnosti. Danas se ulažu enormne sume u razvoj tehnologija koje imaju za cilj naseljavanje Mjeseca i ljudsku misiju na Mars do 2030. godine. Pitanje uspostave ljudskih nastambi, rudarenja i pozicioniranja na Mjesecu danas je primjer razvoja praktičnih rješenja za skoru uporabu, npr. Moonlight projekt (ESA, 2024) ili pozicioniranje za rudarenje na Mjesecu (Ignjatović, 2024). Opravdano se u tom kontekstu postavlja pitanje studijskih programa i sadržaja geodezije i geoinformatike koji će zadovoljiti potrebe prakse za stručnjacima koji raspolažu potrebnim znanjima i vještinama za potrebe svemirskih operacija.

Ključne riječi: *Mjesec, osvajanje i iskorištavanje, studijski programi, Svemir*

1. Studijski programi Geodezija i geoinformatika u Hrvatskoj i tema Svemir

Danas se u Hrvatskoj prijediplomski studij Geodezije i geoinformatike izvodi na tri sveučilišta (Sveučilište u Zagrebu Geodetski fakultet, Sveučilište u Splitu Fakultet građevinarstva, arhitekture i geodezije i Sveučilište Sjever), dok se diplomski i doktorski studiji izvode samo na Geodetskom fakultetu Sveučilišta u Zagrebu. Upisna kvota na sva tri sveučilišta za prijediplomski studij u akademskoj godini 2024./2025. iznosi 210 studenata, a za diplomski studij iznosi 90 studenata. Važeći studijski programi geodezije i geoinformatike na Geodetskom fakultetu Sveučilišta u Zagreb datiraju s početka stoljeća, te su nastavno kontinuirano modernizirani aktualizacijom sadržaja predmeta, s najvećim zahvatom 2015. godine kada je povećan broj izbornih predmeta na prijediplomskom i diplomskom studiju. Studijski program Geodezija i geoinformatika na Sveučilištu u Splitu datira iz 2010. godine, dok je sadašnji program rezultat modernizacije programa 2018. godine. Prijediplomski studijski program Geodezija i geomatika na Sveučilištu Sjever izvodi se od akademske godine 2021/2022. Osim što se taj studij razlikuje od ostalih u nazivu, u određenoj mjeri se razlikuje i po sadržaju, koji je interdisciplinarniji.

Kao zajedničke karakteristike sva tri prijediplomska studijska programa mogu se istaknuti:

- po strukturi i sadržaju riječ je o objedinjenim studijima geodezije i geoinformatike,
- sadržaj programa je tradicionalan (geodetski, obogaćen sadržajima geoinformatike),
- izvođenje nastave je klasično (predavanja, vježbe),
- sudjelovanje dionika u nastavi je ograničeno.

Diplomski studijski program na Geodetskom fakultetu organiziran je u dva sadržajno potpuno različita usmjerenja (Geodezija i Geoinformatika) za koja vrijede iste karakteristike kao i za prijediplomske studije. Otežavajuća okolnost je preveliki broj studenata po usmjerenjima (43-48) što realno onemogućuje kvalitetnu individualnu nastavu.

Izučavanje svemira i primjena geodezije eksplicite je sadržano samo u studijskim programima Geodetskog

fakulteta Sveučilišta u Zagrebu kroz tri izborna predmeta:

- Geodetska astronomija, VI semestar prijediplomskog studija,
- Svemirska geodezija, I semestar diplomskog studija i
- Geodetska astronomija – projekt , III semestar diplomskog studija.

2. Novi ciklus istraživanja Svemira i potreba za novim profilima stručnjaka

Potkraj prošlog i početkom ovog desetljeća započeo je novi ciklus istraživanja Svemira kojeg ponovno karakterizira utrka između različitih država. Za razliku od 20. stoljeća kada je bila riječ o nadmetanju između dvije države (SAD-a i SSSR-a (Rusije)), danas veći broj država raspolaže resursima i znanjima za sudjelovanje u istraživanjima Svemira. Razlog tome su globalne ekonomske, demografske i političke promjene u svijetu te tehnološki razvoj u proteklih 20-tak godina. Glavni pokretač svekolikog tehnološkog razvoja društva je razvoj novih digitalnih tehnologija. Međutim nove tehnologije, pogotovo nano i zelene tehnologije, traže i nove materijale, što je rezultirao velikom potražnjom za rijetkim metalima i pogotovo rijetkim zemljinim elementima koji na našem planetu ima u ograničenim količinama (LePan, 2021). Nedostataka rijetkih zemljinih elemenata u odnosu na potrebe i distribucija njihovih nalazišta, kao i nove spoznaje o postojanju rijetkih metala, rijetkih zemljinih elemenata, ali i vode (leda) na Mjesecu i Marsu, potaknuli su novi ciklus istraživanja i osvajanja Svemira kojem je jedan od ciljeva uspostava stalnih ljudskih nastambi na Mjesecu i Marsu te rudarenje vrijednih minerala na tim planetima i asteroidima čije su putanje bliske Zemlji (McLeod and Krekeler, 2017; Glibert, 2021).

Kao reakcija na navedenu situaciju šest država ili zajednica država koje trenutno raspolažu potrebnim znanjima i resursima planiraju do 2030 godine lansirati više od 100 misija prema Mjesecu i više od misija prema Marsu (Statista, 2024). Cilj tih napora je stvaranje pretpostavki za uspostavu mogućnosti dužeg/stalnog boravka na Mjesecu, početak rudarenja i korištenja Mjesečevih resursa za opskrbu stalne postaje, koja bi u budućnosti trebala postati „odskočna daska" za istraživanje Svemira (Ignjatović, 2024). Da bi se spomenuti ciljevi ostvarili, obzirom na uvjete boravka i života na Mjesecu potrebno je riješiti čitav niz problema i osigurati servise koji će omogućiti boravak na Mjesecu. Iz geodetsko-geoinformatičke perspektive potrebno je:

- uspostaviti sustav za pozicioniranje i navigaciju na površini Mjeseca koji će biti dovoljno točan i pouzdan da omogući precizna slijetanja i kretanje robotiziranih naprava na površini Mjeseca za rudarenje i transport dobara i ljudi,
- uspostaviti sustave efikasnog kartiranja površine Mjeseca u krupnom mjerilu za potrebe navigacije, rudarenja i svih drugih zahvata na površini Mjeseca
- izgraditi nastambe na površini koje će biti otporne na radijaciju Sunca koja je puno snažnija na Mjesecu, odnosno nastambe ispod površine Mjeseca u podzemnim kanalima lave koji će štititi ljude od radijacije,
- uspostaviti (drugačije) sustave navigacije i kartiranja u nastambama ispod površine Mjeseca,
- uspostaviti sustave praćenja seizmičkih pojava, potresa izazvanih udarima svemirskih tijela u Mjesec ili izazvanih rudarenjem na i ispod površine Mjeseca i
- uspostavi GIS ili digitalne dvojnike dijelova Mjeseca u svrhu praćenja stanja, promjena i za upravljanje kompletnim operacijama na Mjesecu.

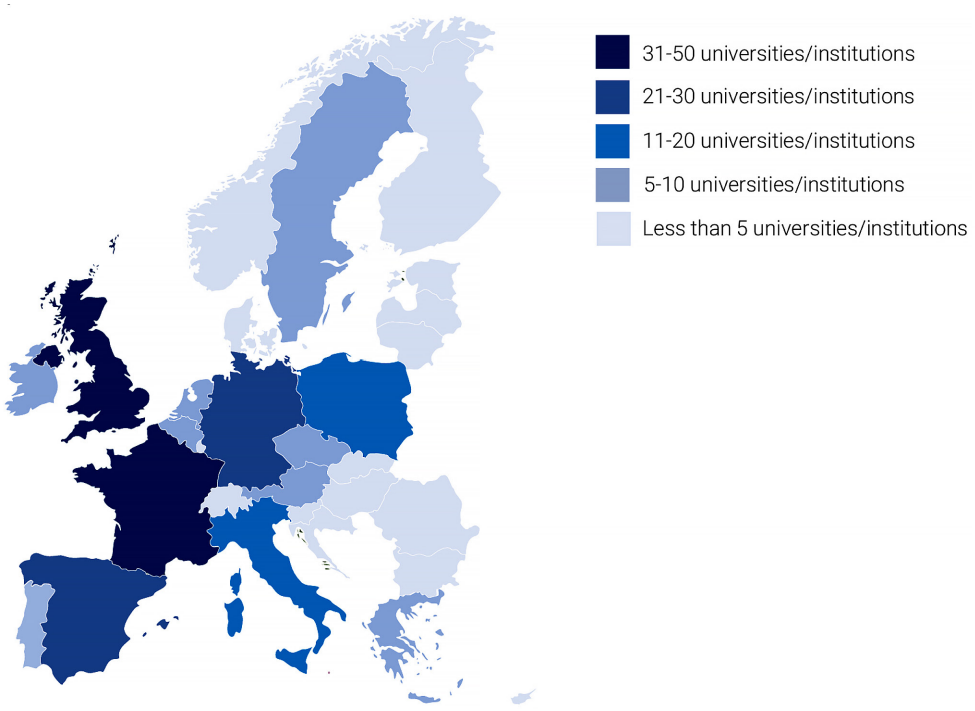
Pored navedenih, još je čitav niz geodetsko-geoinformatičkih zadataka koje će trebati rješavati kako na Mjesecu, potom na Marsu, a u daljoj budućnosti i na drugim svemirskim tijelima i planetima Sunčevog sustava pri čemu će uvjeti uspostave servisa i obavljanja poslova biti znatno kompliciraniji nego na Zemlji.

Sve navedeno jasno ukazuje da znanja i vještine stručnjaka koji se obrazuju za rješavanje problema na Zemlji nisu adekvatna niti dostatna za izazove koje donosi Svemir i osvajanje svemirskih tijela. Stoga je već sada u Europi pokrenut niz inicijativa da se ustroje studijski programi koji će osigurati stručnjake svih potrebnih profila za sve aspekte istraživanja Svemira. Tako Europska svemirska agencija (ESA) u svojoj Agendi 2025 naglašava ulogu obrazovanja za budućnost svemirskog sektora nastojeći "europskim talentima ponuditi privlačne mogućnosti unutar Europe i prilagoditi kurikulume visokog obrazovanja vještinama potrebnim za budućnost". Agenda poziva i na snažnije inspirativno informiranje ESA-e, u suradnji s drugim organizacijama, radi povećanja udjela europskih studenti iz STEM područja za 20% (ESA, 2021).

U 2022. godini, na osnovu podataka za akademsku godinu 2021/2022 European Space Policy Institute (ESPI) je prikupio podatke i kreirao bazu podatak o studijskim programima posvećenih svemiru koji obuhvaća sve razine visokog obrazovanja kao i druge oblike obrazovanja kao što su kratki tečajevi, on-line tečajevi ili ljetne škole (ESPI, 2022). Iako širok raspon obrazovnih pozadina može dovesti do karijere u svemirskom sektoru, baza podataka se usredotočuje isključivo na kurikulume specijalizirane za svemir. Ti su kurikulumi organizirani su u pet makro područja kako bi se omogućilo sustavno grupiranje i analiza:

- zrakoplovno inženjerstvo,
- svemirske znanosti,
- pravne, ekonomske, društvene znanosti i prostor,
- svemirske aplikacije i
- multidisciplinarni programi.

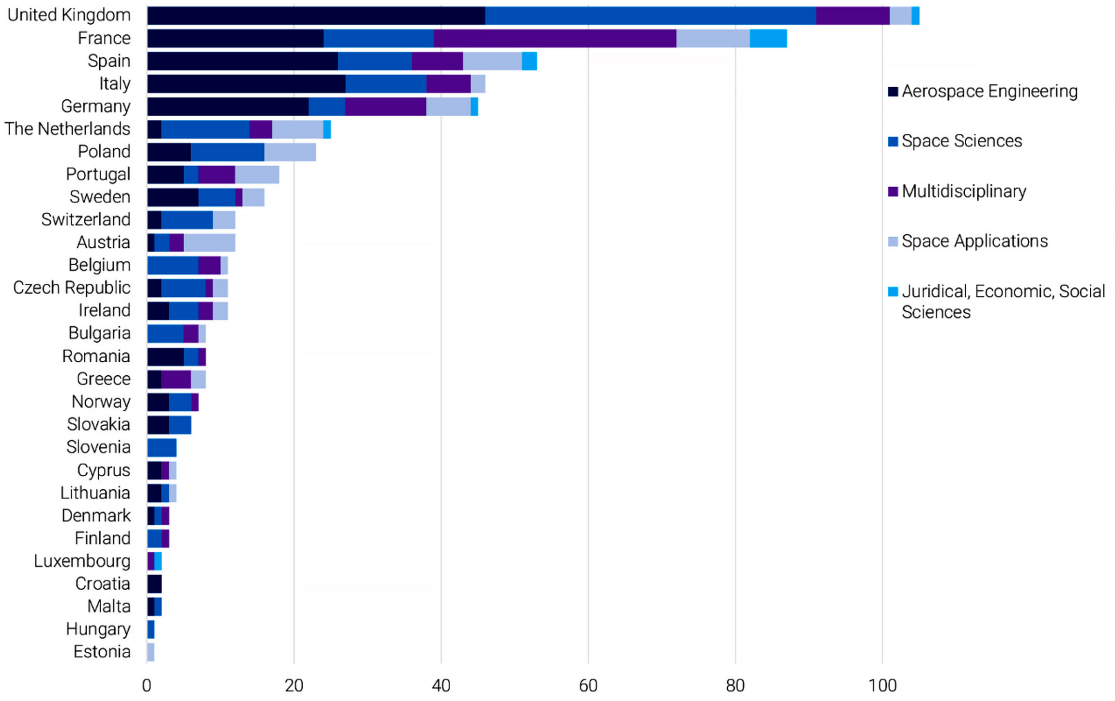
Analiza je zaključila da je u akademskoj godini 2021/2022 30 Europskih zemalja na 325 sveučilišta i viših škola nudilo 866 studijskih programa sadržajem usmjerenih svemiru. Distribucija tih sveučilišta i studijskih programa u Europi je neujednačena i pokazu-



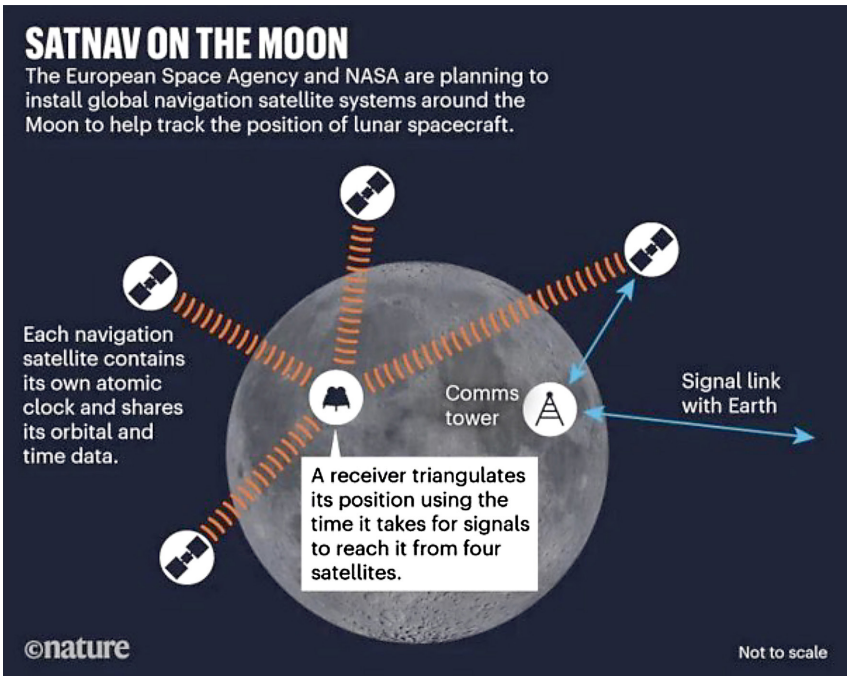
Slika 1: Distribucija sveučilišta koje nude svemirske kurikulume po zemljama (ESPI, 2022)

je da prednjače zemlje koje su i inače najaktivnije u Europskom svemirskom programu, vidi sliku 1.

Podjela kurikuluma prema tematskim skupinama po državama prikazana je na slici 2 sa koje je vidljivo da osim prijediplomskog i diplomskog Studija zrakoplovnog inženjerstva i svemirske tehnike na Fakultetu strojarstva i brodogradnje nema drugih studija usmjerenih svemiru.



Slika 2: Distribucija prijediplomskih i diplomskih studija po tematskim područjima i državama (ESPI, 2022)



Slika 3: Satelitska navigacija na mjesecu (Gibney, 2023)

3. Svemir u studijskom programu Geodezija i geoinformatika

Razmatrajući pitanje do koje mjere, kako i kada treba modernizirati, uvesti ili proširiti sadržaj materije vezane za Svemir koji će biti uključen u studijske programe Geodezija i geoinformatika potrebno je naglasiti da su polazna osnova sadašnji studijski programi na tri sveučilišta u Hrvatskoj. Obzirom da Sveučilište u Splitu i Sveučilište Svemir nemaju sadržaja vezanih za Svemir u svojim kurikulumima, to nam preostaje razmotriti prijediplomski i diplomski studijski program na Geodetskom fakultetu Sveučilišta u Zagrebu. Dva postojeća izborna predmeta, Geodetska astronomija na VI semestru prijediplomskog studija i Svemirska geodezija na I semestru diplomskog studija daju osnovna teorijska i praktična znanja vezana za referentne sustave u Svemiru, opažanje svemirskih tijela i mjerenja pomoću svemirskih tijela, odnosno moderne sustave čija mjerenja se odnose na Zemlju. Odmah se može zaključiti da sadržaji navedenih predmeta ne obuhvaćaju problematiku svemirskih istraživanja koja je apostrofirana u prethodnom poglavlju. Koliko je međutim navedena problematika povezana s geodezijom može se sagledati na problematici uspostave sustava pozicioniranja i navigacije na Mjesecu. Jedina javno publicirana inicijativa je prije spomenuti projekt Moonlight ESA-e, koji želi uspostaviti jedinstveni sustava za pozicioniranje, navigaciju i komunikaciju na i sa Mjesecom. Moonlight projekt trebao bi pružiti podršku Europskim tvrtkama da uspješno sudjeluju u istraživanju svemira i ostvare gospodarsku dobit. Za sada, iz dostupne literature detalji sustava nisu poznati, ali je prilično razvidno da će se sustav uspostavljati u fazama kako će se razvijati uspostava nastambi na Mjesecu. Za sada je sustav zamišljen s ograničenim brojem satelita u orbiti oko mjeseca koji i trebali osigurati servis na i oko južnog Mjesečevog pola, na kojem se planiraju prve trajne nastambe (Schackelton krater) zbog zaliha leda, koje osiguravaju kisik za disanje i vodik za gorivo, vidi sliku 3.

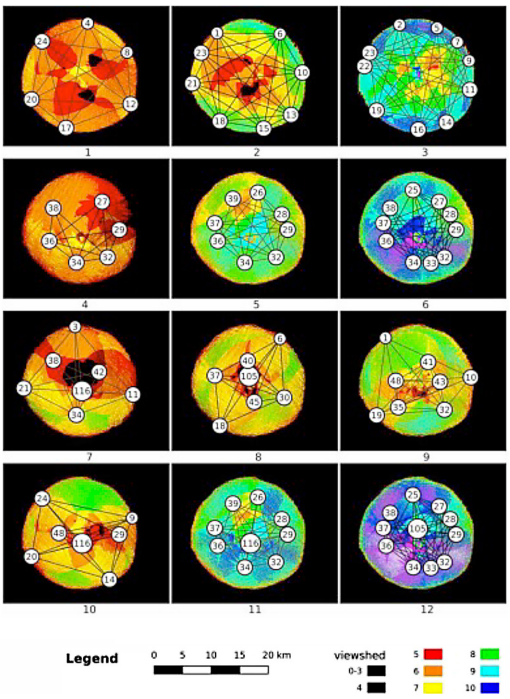
Međutim, sa ograničenim brojem satelita i topografijom Mjesečevih krater čije stijenke se vertikalno dižu više od 4 km iznad platoa kratera, teško će biti osigurati mogućnost stalne pouzdane navigacije koja je neophodna za robotizirana vozila. Stoga se razmatraju i druga rješenja, kao što je Mjesečev regionalni navigacijski sustav odašiljača (Lunar Regional Navigation Transciever System – LRNTS) (Ignjatović, 2024). Riječ je o sustavu pseudolita, sličnom Locati prilagođenom uvjetima na Mjesecu, vidi sliku 4. To je sustav temeljen na pseudosatelitima koji prenosi navigacijsku poruku sličnu načinu rada zemaljskog GNSS-a. Sustav je autonoman i sposoban za samo-kalibraciju, postavljanje primopredajnika raspoređenih kroz krater. LRNTS se implementira kao koordinatni okvir koji materijaliziraju primopredajnici koji djeluju istovremeno s odašiljačima i prijemnicima. LRNTS može samostalno ili kao u sinergiji s Moonlight sustavom riješiti sve izazove navigacije, komunikacije i prijenosa vremena. Provedena ispitivanja različitih konfiguracija pseudolita na modelu Schackleton kratera pokazala su da su ostvarive centimetarske točnosti s konfiguracijom od 12 pseudolita, vidi sliku 5. Imajući ovu sposobnost prijenosa i primanja navigacijske poruke, složeni uređaji primopredajnika su:

(i) pseudolit koji se koristi za generiranje "GNSS" navigacijske poruke koja se prenosi putem odašiljačke antene,

(ii) „GNSS-u" sličan prijamnik koji prima signal od drugih primopredajnika u mreži.



Slika 4: Umjetnička ilustracija LRNTS-a (Ignjatović, 2024)



Slika 5: Vidljivost signala na testiranim konfiguracijama pseudolita (Ignjatović, 2024)

Prezentirana problematika navigacije na Mjesecu samo je jedan od primjera potrebe za geodetsko-geoinformatičkim stručnjacima opremljenim dodatnim znanjima vezani za istraživanje svemira.

4. Zaključak

Ubrzani napredak svemirskih istraživanja povećava potražnju za visoko školovanim stručnjacima koji su opremljeni znanjima i vještinama potrebnim za rješavanje problema svemirskog istraživanja. U ovom radu je prikazano da će razvoj svemirskih istraživanja tražiti i geodetski-geoinformatičke stručnjake opremljene specifičnim znanjima i vještinama. Stoga je za razmotriti, pri očekivanoj reformi studijskih programa Geodezija i geoinformatika na Geodetskom fakultetu, ali i drugim sveučilištima koja obrazuju geodete, da se na adekvatan način odgovori ovim potrebama. U protivnom, prijeti opasnost, da će geodetsko-geoinformatička struka izgubiti još jedno područje potencijalnog djelovanja.

Literatura

ESA (2021): ESA Agenda 2025. European Space Agency (ESA), webstranica 2021, https://esamultimedia.esa.int/docs/ESA_Agenda_2025_final.pdf

ESA (2024): Moonlight project. European Space Agency (ESA) webstranica 15.06.2024. https://www.esa.int/Applications/Connectivity_and_Secure_Communications/Moonlight

ESPI (2022): ESPI Report 81 - Space Education in Europe. European Space Policy Institute (ESPI), 03.2022, https://www.espi.or.at/wp-content/uploads/2022/03/ESPI-Report-81-Space-Education-in-Europe-Full-Report.pdf

Gibney, E (2023): What time is it on the Moon? Scientists are working that out. Nature, e-news, 24.01.2023. https://www.nature.com/articles/d41586-023-00185-z

Gilbert, A. (2021): Mining in Space is Coming. Milken Institute Review, e-newsletter, published 26.04.2021. URL: https://www.milkenreview.org/articles/mining-in-space-is-coming

Ignjatović, D. (2024): Positioning solution in lunar mining, University of Ljubljana, Faculty of Natural Sciences and Engineering, Ph.D. thesis, 2024, https://repozitorij.uni-lj.si/IzpisGradiva.php?id=156174

LePan, A. (2021): Rare Earth Elements: Where in the World Are They? Elements e-newsletter, published 22.11.2021. URL: Rare Earth Elements: Where in the World Are They? (visualcapitalist.com)

McLeod, C.L i Krekeler, M.P.S. (2017): Sources of Extraterrestrial Rare Earth Elements: To the Moon and Beyond. MDPI Resources 2017, 6, 40; doi: 10.3390/resources6030040, 1-29.

Statista (2024): Projected space explorations missions from 2020 to 2030, by type. 15.06.2024. https://www.statista.com/statistics/1169834/space-exploration-missions-worldwide-type/

Space – New Content of Study Programs in Geodesy and Geoinformatics

Abstract

The basic assumptions of geodesy as a profession are based on measurement, prescribed procedures, accuracy, precision, error determination, management and preservation, which determines the profession as conservative in terms of the approach to solving the tasks that are put before it. Such an approach is somewhat out of step with today's trends of the modern world, which is also reflected in the concept and content of the study programs of geodesy and geoinformatics that are carried out in Croatia today. Study programs of geodesy and geoinformatics in Croatia today were designed about 20 years ago and it can be argued, with all the modernizations that have been carried out in recent years, that they do not fully meet the needs of users. New scientific knowledge and technologies are reflected through the development of a digital society that encourages the disappearance of classical and the emergence of new professions, interdisciplinarity, acceleration of all processes and new directions of human development, imposing the need to redefine jobs and professions, and thus the content and form of educational programs. One of the areas of human activity of special interest today is the conquest and exploitation of the resources of the Universe, which has gained great importance in the past 10 years. Today, enormous sums are being invested in the development of technologies that aim to populate the Moon and a human mission to Mars by 2030. The issue of establishing human dwellings, mining and positioning on the Moon is today an example of the development of practical solutions for the near future, e.g. Moonlight project (ESA, 2021) or positioning for mining on the Moon (Ignjatović, 2024). In this context, the question of study programs and content of geodesy and geoinformatics that will meet the needs of practice for experts who have the necessary knowledge and skills for the needs of space operations is justified.

Keywords: *Space, Moon, conquest and exploitation, study program*

Obrazovni resursi za integraciju BIM-a i GIS-a

Vlado Cetl[1], Olga Bjelotomić Oršulić[1], Sanja Šamanović[1], Danko Markovinović[1], Hrvoje Matijević[1], Nikola Kranjčić[1]

[1] Sveučilište Sjever, Jurja Križanića 31b, 42000 Varaždin, Hrvatska, vcetl@unin.hr, oborsulic@unin.hr, sasamanovic@unin.hr, dmarkovinovic@unin.hr, hmatijevic@unin.hr, nkranjcic@unin.hr

Sažetak

S ciljem jačanja kapaciteta u integraciji BIM-a (Building information modeling) i GIS-a (Geoinformation systems) pokrenut je Erasmus+ projekt BIRGIT (training on Building InfoRmation models integrated with Geographical InformaTion) Sveučilišta Sjever i ostalih partnera. Cilj projekta je povezati područja BIM-a i GIS-a u svrhu osposobljavanja budućih stručnjaka potrebnim znanjima i vještinama kroz izradu novih obrazovnih resursa u okviru prijediplomskih i diplomskih studija, te programima cjeloživotnog obrazovanja. BIRGIT projekt je započeo 01. 02. 2022. i završava 31. 01. 2025.god. U ovom radu bit će predstavljeni konačni rezultati rada na projektu kroz razvijene obrazovne resurse koji se sastoje od tekstualnih dokumenata i prezentacija na engleskom jeziku i jezicima partnera što uključuje i hrvatski jezik. Resursi su strukturirani u tri različita paketa: I) Uvod u BIM i GIS, II) 3D GIS, modeli gradova i digitalni blizanci te III) Integracija BIM-a i GIS-a. Obrazovni materijali trenutno su u fazi lokalizacije i završnih testiranja i biti će online dostupni krajem 2024. svima zainteresiranima na web stranici projekta (https://birgitproject.eu/) pod licencom CC-BY-SA. Obrazovni resursi će se moći koristiti u nastavi, za individualne potrebe učenja ili organizaciju ciljanih aktivnosti cjeloživotnog usavršavanja.

Ključne riječi: *BIM, BIRGIT projekt, GIS, integracija, obrazovni resursi*

1. Uvod

Uspješno upravljanje održivim projektima zahtijeva 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 čitav 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 1).

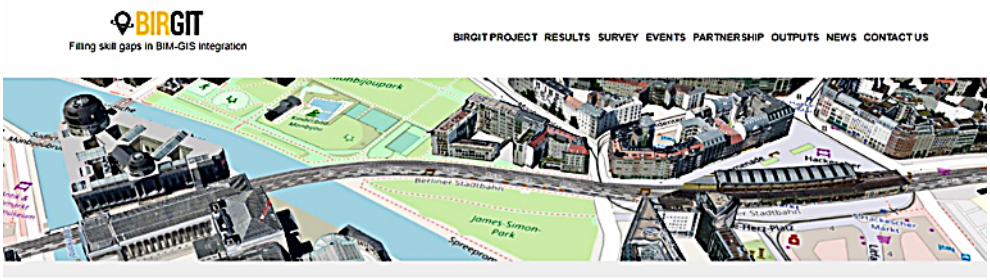
Učinkovita i uspješna integracija BIM-a i GIS-a zahtijeva duboko poznavanje barem jedne od te dvije discipline, kao i znanje o tome kako surađivati s drugom disciplinom. Preliminarna istraživanja dionika u Švedskoj, Italiji, Španjolskoj i Hrvatskoj, ukazala su na nedostatak kvalificiranog osoblja kao i strukovnih tečajeva/radionica koji se bave kompetencijama potrebnim za postizanje integracije BIM-a i GIS-a. Postojeći VET (Vocational education and training) obrazovni 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 (Cetl i dr. 2022) (training on Building InfoRmation models integrated with Geographical InformaTion) čiji su rezultati prikazani u ovom radu.

2. BIRGIT projekt

Erasmus+ BIRGIT projekt (URL 2) ima za cilj povezati područja BIM-a i GIS-a u svrhu osposobljavanja budućih stručnjaka s potrebnim znanjima i vještinama kroz izradu novih obrazovnih resursa u okviru preddiplomskih i diplomskih studija, te programima cjeloživotnog obrazovanja (Slika 1).

BIRGIT projekt se izvodi kroz tri godine u razdoblju od 01. 02. 2022. do 31. 01. 2025.god. Partneri na projektu uz Odjel za geodeziju i geomatiku Sveučilišta 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 pro-



Slika 1: Web stranica BIRGIT projekta (URL 2)

jektnim partnerima može se pronaći na web stranici BIRGIT projekta (URL 2).

Rad na projektu podijeljen je u četiri glavne aktivnosti (Project Results) i s njima povezane zadaće:

- PR1 Zahtjevi industrije na BIM-GIS edukacijskim programima i tečajevima
- PR2 Lokalizacija postojećih resursa
- PR3 Razvoj novih obrazovnih resursa
- PR4 Ispitivanje i ažuriranje izrađenih resursa

2.1. PR1 Zahtjevi industrije na BIM-GIS edukacijskim programima i tečajevima

Cilj ove aktivnosti bio je odrediti zahtjeve za integrirane BIM-GIS obrazovne resurse. Neki su zahtjevi već provedeni u okviru postojećih programa i tečajeva strukovnog obrazovanja i osposobljavanja, no zbog društvenog razvoja s povećanom razinom digitalizacije formulirani su dodatni zahtjevi. Glavna ciljna skupina rezultata projekta su pružatelji tečajeva strukovnog obrazovanja i osposobljavanja, projektni partneri i vanjski pružatelji usluga. Od poduzeća koja rade u tom sektoru očekuje se da iskoriste analizu zahtjeva, primjerice pri izmjeni svojih poslovnih ponuda. Zahtjevi su prikupljeni posebnom anketom i intervjuima s predstavnicima BIM-GIS industrije u partnerskim zemljama u okviru ovog projekta. Navedeni sektorski zahtjevi dodatno su korišteni u projektu pri određivanju i stvaranju novih obrazovnih resursa osposobljavanja u području strukovnog obrazovanja i osposobljavanja. Prema tradiciji, nove teme u obrazovanju i osposobljavanju često se uvode u više akademske studijske programe kao rezultat znanstvenih istraživanja. To je osposobljavanje često znanstveno usmjereno, a nakon nekog vremena, kada je tehnološki razvoj zreo i društvena sposobnost da odgovori na predložene promjene, stvaraju se programi osposobljavanja usmjereni na strukovno obrazovanje i osposobljavanje. Jedan od inovativnih elemenata ove aktivnosti je taj da se taj tok skraćuje bržim usvajanjem novih tehnologija u okviru programa strukovnog obrazovanja i osposobljavanja. To je moguće zahvaljujući povećanoj razini normizacije u industriji, kraćim razvojnim ciklusima unutar softverske industrije i većoj društvenoj spremnosti zbog sve veće pozornosti na mogućnosti digitalizacije. Isto tako, zemlje s manje razvijenim privatnim sektorom u BIM i GIS tehnologijama mogu imati koristi od takvog pristupa. Inovativni dijelovi ove aktivnosti povezani su i sa samim rezultatima i s metodologijom. Metodologija je, naravno, od interesa i za druge sektore koji se suočavaju sa sličnim izazovima. Rezultati (zahtjevi o tečajevima) od interesa su za pružatelje strukovnog obrazovanja i osposobljavanja, kao i za industriju. Očekivani utjecaj je da će pružatelji strukovnog obrazovanja i osposobljavanja izvan partnerstva imati bolje mogućnosti u pružanju novih BIM-GIS tečajeva u svojim programima.

Na temelju provedenih istraživanja u zemljama partnerima identificirane su sljedeće glavne kompetencije koje stručnjaci razmatraju za integraciju BIM i GIS-a (te su kompetencije prioritetne i odabrane u skladu sa zahtjevima i potrebama svake zemlje partnera)::

- Osnovna znanja GIS-a i znanosti o podacima
- Urbanističko planiranje, znanje o pravu nekretnina i geologiji
- Kompetencije za modeliranje i strukturu informacija
- Kompetencije za infrastrukture BIM-a i GIS-a
- BIM za infrastrukturu s naglaskom na GIS vještine
- Vizualizacija
- Upravljanje zajedničkim podatkovnim okruženjem
- Čitanje modela na različitim jezicima
- Rad s kompatibilnim i dobro povezanim modelima i skupovima podataka
- Informacijska pismenost
- Poznavanje relevantnih softvera
- Iskustvo rada na terenu

Potrebe za osposobljavanjem utvrđene u svakoj partnerskoj zemlji u pogledu potrebnih kompetencija i razine stručnosti (stručna razina; srednja stručna razina; srednja razina; osnovna – srednja razina; osnovna razina) i detaljno su prikazane u PR1 izvješću (URL 3).

2.2. PR2 lokalizacija postojećih resursa

Cilj ove aktivnosti bio je lokalizirati niz postojećih obrazovnih resursa, uglavnom tečajeva. Pojam „lokalizacija" u tom kontekstu znači da se tečajevi prevode i prilagođavaju kako bi se zadovoljile nacionalne i lokalne potrebe. Postupak lokalizacije uključivao je aktivnosti kao što su prevođenje teksta, uključivanje

lokalnih skupova podataka, lokalizacija multimedijskih resursa kao i druge vrste izmjena te prilagodbi.

Postupak prevođenja proveden je pomoću usluge eTranslation (URL 4), usluge neuronskog strojnog prevođenja koju pruža Europska komisija.

Ukupno su tri postojeća tečaja prevedena na engleski, a osam tečajeva je lokalizirano i prevedeno na lokalne jezike partnera.

2.3. Razvoj novih obrazovnih resursa

Cilj ove aktivnosti bio je izrada novih obrazovnih resursa, prema identificiranim potrebama, s idejom ponovne uporabe tih resursa od strane partnera te u širem smislu svih zainteresiranih provoditelja edukacija.

U izradi nastavnih materijala korištena je prilagođena SCRUM metodologija (URL 5). Scrum je iterativni i inkrementalni okvir za upravljanje razvojem proizvoda. Metoda se oslanja na dodijeljene uloge (vlasnik proizvoda, programer, Scrum master itd.), tijekove rada (kratki razvojni ciklusi koji se nazivaju sprintovi, sastanci za planiranje sprinta, dnevni Scrums, recenzije sprinta itd.) i artefakte (zaostatak proizvoda, zaostaci u sprintu, povećanje proizvoda itd.).

Sudionici u razvojnom procesu izrade obrazovnih resursa imali su uloge vlasnika proizvoda, Scrum mastera i programera. Razvoj je organiziran u tri paketa obrazovnih resursa:

- Uvod u BIM
- 3D GIS, modeli gradova i digitalni blizanci
- BIM-GIS integracija

Za svaki paket dodijeljeni su vlasnici proizvoda. Njihova je uloga bila sudjelovati na sastancima sprinta i osigurati učinkovite obrazovne resurse. Budući da je svaki paket trebalo provesti kod nekoliko pružatelja usluga osposobljavanja, za svaki paket dodijeljeno je nekoliko vlasnika proizvoda. Za svaki paket dodijeljen je i Scrum master. Njihova uloga bila je rješavanje problema, planiranje aktivnosti, upravljanje zaostacima, preraspodjela resursa ako je to potrebno i olakšavanje komunikacije. Različite uloge dodijeljene su dogovorno između projektnih partnera.

Svi obrazovni resursi izrađeni su originalno na engleskom jeziku u obliku prezentacija i tekstualnih dokumenata s dodatnim pojašnjenjima. Resursi također obuhvaćaju i podatke za praktične vježbe u BIM/GIS softverima.

2.3.1. Uvod u BIM

U okviru ovog paketa razvijeni su sljedeći resursi:

- Blok 1 – Definicija BIM-a
  - Osnove BIM-a (predavanje)
  - Koristi i izazovi s pomoću BIM-a (predavanje)
  - Razine detalja u BIM-u (predavanje)
- Blok 2. – Rad s podacima BIM-a
  - Upravljanje podacima u BIM-u (predavanje)
  - Tijek rada procesa BIM-a (predavanje)
  - Koordinacija BIM-a (predavanje)
  - IFC kao format za razmjenu podataka (predavanje)
  - IFC (vježba)
- Blok 3 – Primjene BIM-a
  - BIM za infrastrukturu i upravljanje objektima (predavanje)
  - BIM za povijesno praćenje građevine (predavanje)
  - BIM softveri i alati (predavanje)

2.3.2. 3D GIS, modeli gradova i digitalni blizanci

U okviru ovog paketa razvijeni su sljedeći resursi:

- Blok 1 – 3D modeli gradova
  - Koncepti 3D modeliranja (predavanje)
  - Semantički modeli gradova (predavanje)
  - Standardi podataka (predavanje)
- Blok 2 – 3D prikupljanje i obrada podataka
  - Prikupljanje 3D podataka (predavanje)
  - Izvori 3D podataka (predavanje)
  - Alati i aplikacije za 3D obradu podataka (predavanje)
  - Izrada 3D modela zgrade iz mjerenih podataka (vježba)
  - Kreiranje 3D objekata iz oblaka točaka (vježba)
  - Kombiniranje podataka s različitim razinama detaljnosti (vježba)
- Blok 3 – Digitalni urbani blizanci
  - Uvod u urbane digitalne blizance (predavanje)
  - Standardi za senzore i podatke (predavanje)
  - Programi kvalitete zraka (predavanje)
  - Alarmi sa senzorom (vježba)

2.3.3. BIM-GIS integracija

U okviru ovog paketa razvijeni su sljedeći resursi:

- Blok 1 – Integracija BIM-GIS-a – uvod i tijek rada
  - Uvod u integraciju BIM-a i GIS-a (predavanje)
  - Tijek rada za integraciju (predavanje)
  - Pretvorba podataka (predavanje)
- Blok 2. – BIM-GIS u životnom ciklusu projekta
  - Integracija u fazi planiranja (predavanje)
  - Integracija u građevinarstvu (predavanje)
  - Integracija u upravljanje objektima (predavanje)
  - Integracija u projekte zaštite okoliša (predavanje)
  - Integracija u procjenu utjecaja na okoliš i procjenu životnog ciklusa (predavanje)
- Blok 3 – BIM-GIS integracija slučajevi korištenja
  - Slučaj korištenja – analiza poplava za fazu planiranja (predavanje)

- Slučaj korištenja – u procesu urbanističkog planiranja i projektiranja (predavanje)
- Slučaj korištenja – pri procjeni energetske učinkovitosti gradova (predavanje)
- Slučaj korištenja – u izgradnji dizalica (predavanje)
- Slučaj korištenja – u prometnim simulacijama (predavanje)

2.4. Ispitivanje i ažuriranje izrađenih resursa

Cilj ove aktivnosti je procijeniti kvalitetu izrađenih obrazovnih resursa, predložiti poboljšanja i implementirati ih.

Kako bi se procijenila kvaliteta razvijenih resursa, od partnera se očekuje testiranje i provođenje obuka, kako kontaktno tako i u online obliku. Zadatak uključuje i planiranje te organizacijske aspekte ovih aktivnosti obuke i metode za prikupljanje i obradu povratnih informacija od sudionika koji sudjeluju u tim aktivnostima.

Aktivnost ima za cilj eventualna ažuriranja i prilagodbu obrazovnih resursa, za njihovo daljnje usvajanje i širenje unutar partnerskih organizacija i diljem zemalja EU-a.

Dosad (lipanj 2024. godine) odrađena je lokalizacija izrađenih obrazovnih resursa što je uglavnom uključivalo prevođenje resursa na lokalne jezike partnera korištenjem usluge eTranslation te dodatnu prilagodbu. U idućim mjesecima (do kraja 2024. godine) provodit će se diseminacija obrazovnih resursa kroz organizirane radionice (multiplier events) u zemljama partnera, prezentacije na skupovima, društvene mreže i dr. Prvi multiplier event održati će se 21. lipnja na Odjelu za geodeziju i geomatiku Sveučilišta Sjever gdje će polaznicima biti predstavljeni izrađeni obrazovni resursi na engleskom i hrvatskom jeziku.

Svi obrazovni resursi biti će objavljeni na web stranici projekta na izvornom engleskom jeziku (originalni resursi) i jezicima partnera (lokalizirani resursi). Korištenje će biti omogućeno svim zainteresiranim besplatno pod otvorenom Creative Commons licencom (CC-BY-SA).

3. Zaključak

BIM i GIS su u praksi još uvijek prilično razdvoje svijeta. 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. Samim time i integracija podataka i procesa BIM-a i GIS-a trenutno ima puno izazova. Neki od najčešće poznatih problema s integracijom podataka povezani su s razlikom u prikazu 3D podataka (geometrija u odnosu na prikaz granica), prirodom geometrijskih referentnih sustava te dostupnosti otvorenih podataka i povezanih web usluga. GIS domena također sve više koristi nove formate podataka, na primjer JSON i XML, u usporedbi sa sektorom BIM, u kojem IFC/STEP još uvijek dominira. Posljedica toga je da mnogi BIM softveri mogu čitati GIS podatke (prvenstveno GeoJSON), dok je podrška za IFC/STEP prilično ograničena u GIS softverima. Bitna razlika je u tome što BIM podaci često modeliraju dizajnirane entitete, dok GIS podaci obično modeliraju ono što je stvarno izgrađeno.

Za potrebe integracije BIM-a i GIS-a potrebno je obrazovati stručnjake koji će posjedovati relevantna znanja iz oba područja. U tome će od velike pomoći biti razvijeni obrazovni materijali razvijeni u okviru BIRGIT projekta. Materijali sadrže predavanja u obliku prezentacija i dodatnih tekstualnih dokumenata, vježbe i skupove podataka, zadatke, prijedloge literature i testne upitnike. Materijali su izrađeni od strane stručnjaka u domeni i uključuju najnovija dostignuća iz BIM-a i GIS-a.

Korištenjem obrazovnih materijala kroz predavanja, tečajeve i radionice, očekuje se kako će GIS stručnjaci prepoznati važnost i razumijevanje mogućnosti i informacijske strukture BIM-a te kako to koristiti i 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.

Mišljenja smo da će integracija podataka i procesa BIM-a i GIS-a donijeti mnoge koristi društvu. S obzirom na probleme povezane s takvom integracijom, potrebno je usavršavanje stručnjaka kako bi se ispunili zahtjevi koje ta vrsta integracije stvara. Potrebno je i odgovarajuće poboljšanje kurikuluma u pružateljima strukovnog obrazovanja i osposobljavanja na visokim učilištima.

Zahvala

Izrada ovog rada podržana je kroz znanstveni projekt: Uloga geodezije i geomatike u razvoju pametnih prostora, koji se provodi na Sveučilištu Sjever u Hrvatskoj. Voditelj projekta je Prof. dr. sc. Vlado Cetl.

Literatura

Cetl, V., Markovinović, D., Šamanović, S., Rezo, M. (2022): Integracija BIM-a i GIS-a. Zbornik radova 15. Simpozija ovlaštenih inženjera geodezije "Geodezija i vode" / Racetin, Ivana (ur.). Zagreb: Hrvatska komora ovlaštenih inženjera geodezije, str. 117.-124.

Van Berlo, L., De Laat, R. (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: GIS AND BIM INTEGRATION. A High Level Global Report, https://www.geospatialworld.net/consulting/reports/gis-and-bim-integration/, (14. 6. 2024.).

URL 2: BIRGIT, https://birgitproject.eu/, (14. 6. 2024.).

URL 3: BIRGIT PR1 Report, https://birgitproject.eu/wp-content/uploads/2023/02/PR1_Report-1.pdf, (15.6.2024.).

URL 4: eTranslation, https://commission.europa.eu/resources-partners/etranslation_en, (15.6.2024.).

URL 5: What Is Scrum Methodology? & Scrum Project Management https://www.digite.com/agile/scrum-methodology/, (15. 6. 2024.).

Educational Resources for BIM and GIS Integration

Abstract

To strengthen capacities in the integration of BIM (Building information modeling) and GIS (Geoinformation systems), 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 goal of the project is to connect the areas of BIM and GIS to train future experts with the necessary knowledge and skills through the creation of new educational resources within the framework of undergraduate and graduate studies, as well as lifelong education programs. The BIRGIT project started on February 1, 2022, and ends on January 31, 2025. This paper will present the final results of the work on the project through developed educational resources consisting of text documents and presentations in English and partner languages, including Croatian. The resources are structured in three different packages: I) Introduction to BIM and GIS, II) 3D GIS, city models and digital twins, and III) Integration of BIM and GIS. The educational resources are currently in the phase of localization and final testing and will be available online by the end of 2024 to all interested users on the project's website (https://birgitproject.eu/) under the CC-BY-SA license. Educational resources will be able to be used in classes, for individual learning needs, or for the organization of targeted lifelong learning activities.

Keywords: *BIM, GIS, integration, BIRGIT project, educational resources*

Modernizacija studijskih programa geodezije i geoinformatike kroz Erasmus+ KA2 projekte

Vesna Poslončec-Petrić[1], Željko Bačić[1]

[1] Geodetski fakultet, Kačićeva 26, Zagreb, Hrvatska, vesna.posloncec@geof.hr, zbacic@geof.hr

Sažetak

Brze tehnološke promjene potaknute digitalnom revolucijom rezultirale su ubrzanim promjenama na svim razinama obrazovanja. Izazovi s kojima se visokoškolsko obrazovanje suočava povezani su s uvođenjem novih digitalnih tehnologija, ritmom tehnoloških promjena koje su brže od uobičajenog ritma modernizacije nastavnih programa, nastankom novih i nestankom starih profesija, interdisciplinarnošću i potrebom za studijima koje će omogućiti stjecanje praktičnih vještina. Sve navedeno traži nove sadržaje i forme studiranja. Jedan od alata pomoću kojih sveučilišta diljem Europe provode promjene je i Erasmus+ program Europske unije, pogotovo Ključna akcija 2 koja ima za cilj modernizaciju odnosno oblikovanje novih studijskih programa (Partnerstva i Jačanje kapaciteta u visokom obrazovanju). Geodetski fakultet je od 2016. sudjelovao ili sudjeluje u pet projekata izgradnje kapaciteta u visokom obrazovanju (CBHE projekti BESTSDI, GEOBIZ, UN4DRR, SEED4NA, SmartWB) i jednom projektu Alijanse za sektorske vještine (Erasmus+ SSA projekt EO4GEO) koji su imali za cilj modernizaciju cijelih ili dijelova studijskih programa geodezije i geoinformatike i srodnih profila. U okviru svakoga od navedenih projekata provedena su istraživanja na osnovu kojih su stečene spoznaje o potrebama korisnika (dionici iz javnog i privatnog sektora), definirani dijelovi studijskih programa za modernizaciju, kao i sadržaj same modernizacije. Pri tome je poseban naglasak bio na razvoju suradnje akademske i gospodarske zajednice, odnosno uključivanje gospodarskih dionika u obrazovni proces u dijelu praktičnih znanja i vještina. Ovaj rad daje pregled što korisnici koji su sudjelovali u projektima očekuju od modernizacije studijskih programa i načina studiranja, rješenja koja su razvijena i implementirana te izazova koji su se u procesima modernizacije pojavili.

Ključne riječi: *Erasmus, CBHE projekti, SSA projekti, modernizacija kurikuluma, suradnja dionika*

1. Uvod

Četvrta (digitalna) i peta tehnološka (podatkovna) revolucija u proteklih 30 godina ubrzano i dubinski su promijenile i nadalje mijenjaju gospodarske, političke i socijalne uvjete funkcioniranja te način života ljudske zajednice i svakog pojedinca. One su također potaknule globalizaciju te uz porast stanovništva i urbanizaciju stvorile novi okvir u kojem zajednice (države) funkcioniraju. Navedeni utjecaji i promjene odražavaju se na sve razine sustava obrazovanja i obrazovnih institucija u cijelom svijetu Pored tehnoloških revolucija, pandemija COVID-19 virusa uzrokovala je tektonske promjene u načinu izvođenja nastave i na velika vrata uvela nastavu na daljinu uz pomoć informatičke opreme i programskih rješenja. Izazov koji se u nastaloj situaciji postavio pred obrazovne sustave i institucije svodi se na traženje odgovora na pitanje: kako u ovom vremenu brzih promjena (tehnoloških, socijalnih) odgovoriti na potrebe društva promjenama u sustavu koji se mijenja bitno sporije od tehnoloških i socijalnih promjena? U tom kontekstu mi danas možemo pratiti s koliko napora se obrazovni sustavi usklađuju s tim promjenama kako bi društvu i gospodarstvu isporučili stručnjake koji su dobro pripremljeni i raspolažu znanjima i vještinama potrebnim danas.

Izazovi promjene društva i problemi (sporost) modernizacije i transformacije obrazovnih sustava što direktno utječe na razinu gospodarskog rasta i blagostanje građana jedan su od glavnih razloga što se danas povećana pažnja posvećuje obrazovanju kako na razini svake države, tako i na globalnoj razini. Brojne međunarodne institucije, organizacije i asocijacije, bave se danas, sukladno okvirima svojeg djelovanja, pitanjima obrazovanja i njegove modernizacije. Upravo zbog činjenice da za promjene u sustavu obrazovanja, od ustrojavanja adekvatne organizacije, preko usvajanja primjerene metodologije do definiranja optimalnih sadržaja, traže vremena kojeg gospodarstvo i društvo nemaju bitno je prepoznati trendove i izazove današnjeg obrazovanja. Tako Svjetski ekonomski forum (El-Azar, 2022) ističe četiri globalna trenda koji će oblikovati visoko obrazovanje budućnosti:

1. Učenje od svugdje	*Što predstavlja korak dalje u implementaciji učenja na daljinu.*
2. Zamjena predavanja s aktivnim učenjem	*Polazeći od spoznaje/zaključka da su predavanja učinkovit način poučavanja i neučinkovit način učenja.*
3. Učenje vještina koje će u promjenjivom svijetu ostati relevantne	*Prema provedenom istraživanju, 96% nositelja funkcija na sveučilištima smatra kako dobro pripremaju mlade ljude za radnu snagu. Manje od polovice (41%) studenata i samo 11% poslovnih čelnika dijelilo je to mišljenje*
4. Korištenje formativne procjene umjesto ispita s visokim ulogom	*Formativna procjena, koja podrazumijeva i formalne i neformalne evaluacije kroz put učenja, potiče učenike da zapravo poboljšaju svoju izvedbu, a ne samo da je ocjenjuju.*

Nastavno na ključne trendove visokog obrazovanja u budućnosti, sveučilišta se uvijek suočavaju s vanjskim i unutarnjim izazovima (Klychanko i Mau, 2021). Ti se izazovi mogu suziti na sljedeće:

1. Iznimna dinamičnost tržišta rada, uključujući pojavu novih zanimanja;
2. Transformacija obrazovanja u jedan od ključnih pokretača gospodarskog rasta i povećanja potražnje za kvalitetnim obrazovanjem;
3. Brza pojava i razvoj novih obrazovnih tehnologija koje se moraju brzo usvojiti u profesionalnom obrazovanju;
4. Žešća konkurencija za najbolje akademsko osoblje;
5. Tehnološka baza i kvaliteta obrazovnog okruženja glavni su čimbenici konkurentnosti sveučilišta;
6. Znanstveni razvoj kroz globalnu mrežnu suradnju;
7. Organizacije, tvrtke i zemlje međusobno se natječu u pogledu kvalitete modela upravljanja i upravljačkih timova. Važnost i razvoj upravljanja sveučilištima;
8. Mobilnost studenata i osoblja postaje čimbenik učinkovitog razvoja obrazovanja;
9. Održavanje dinamičnog razvoja sveučilišta i njihove financijske stabilnosti.

Uviđajući značaj visokog obrazovanja za budućnost, EU je osmislila programe koji imaju za cilj potaknuti i ubrzati modernizaciju nastavnih sadržaja i organizaciju izvođenja nastave u EU, ali i također i globalno.

2. Erasmus projekti Ključne aktivnosti 2

Erasmus+ program obuhvaća sve europske i međunarodne programe i inicijative Europske unije (EU) u području obrazovanja (odgoj i opće obrazovanje, visoko obrazovanje, obrazovanje odraslih), osposobljavanja (strukovno obrazovanje i osposobljavanje), mladih i sporta. Počeo se provoditi 2014. godine kada je dotadašnjih sedam različitih programa objedinjeno u jedan. Prvi ciklus obuhvati je razdoblje od 2014. do 2020. godine, a trenutno se do 2027. godine provodi drugi ciklus Erasmus+ programa. Erasmus+ usmjeren je jačanju znanja i vještina te zapošljivosti europskih građana, kao i unaprjeđivanju obrazovanja, osposobljavanja te rada u području mladih i sporta. Posebno je usmjeren povezivanju obrazovanja, osposobljavanja i sektora mladih s poslovnim sektorom, te je otvoren za njihove zajedničke projekte (EACEA, 2023).

Opći je cilj programa cjeloživotnim učenjem podupirati obrazovni, profesionalni i osobni razvoj ljudi u području obrazovanja, osposobljavanja, mladih i sporta u Europi i šire, što doprinosi održivom rastu, kvaliteti radnih mjesta, socijalnoj koheziji, poticanju inovacija te jačanju europskog identiteta i aktivnoga građanstva. Program će kao takav biti bitan instrument za izgradnju europskog prostora obrazovanja i podupirati provedbu europske strateške suradnje u području obrazovanja i osposobljavanja, uz temeljne sektorske programe. Osim toga, bitan je za unapređenje suradnje u području politike za mlade u skladu sa strategijom EU za mlade za razdoblje 2019. – 2027. i razvoj europske dimenzije u području sporta (EACEA, 2023).

Prioriteti koji se žele ostvariti provedbom programa, koji istovremeno predstavljaju šire prioritete EU su (a) uključivost i raznolikost, (b) digitalna transformacija, (c) okoliš i borba protiv klimatskih promjena te (d) sudjelovanje u demokratskom životu, zajedničke vrijednosti i građanski angažman. Program je organiziran u tri ključne aktivnosti koje se međusobno nadopunjuju:

- Ključna aktivnost 1- Mobilnost u svrhu učenja za pojedince,
- Ključna aktivnost 2 – Suradnja organizacija i institucija,
- Ključna aktivnost 3 – Podrška razvoju politika i suradnji

te aktivnosti Jean Monet koje promiču poučavanja i istraživanja o europskoj integraciji i rasprave o prioritetima politika EU. Za provedbu programa ukupna indikativna financijska omotnica programa iznosi više od 26 milijardi EUR iz proračuna EU-a za sedam godina (2021. – 2027.) (EACEA, 2023).

Za modernizaciju obrazovanja najznačajnija je ključna aktivnost 2 koja uključuje niz mjera koje se realiziraju kroz:

- Partnerstva za suradnju (uključujući: Mala i Suradnička partnerstva)
- Partnerstva za izvrsnost (uključujući: Europska sveučilišta, Centre strukovne izvrsnosti, Akademije za stručno usavršavanje učitelja i Erasmus Mundus)

Tablica 1: Pregled Erasmus+ KA2 projekata Geodetskog fakulteta

Naziv projekta	Partnera	Partnerske zemlje	Programske zemlje
Western Balkans academic education evoulution and professional's sustainable training for Spatial Data Infrastructure – BESTSDI, 2016-2019 (CBHE)	19 GEOF= koordinator	Albanija, Bosna i Hercegovina, Crna Gora, Kosovo, Srbija	Belgija, Hrvatska, Sj.Makedonija Njemačka
Towards an innovative strategy for skills development and capacity building in the space geo-information sector supporting Copernicus User Uptake – EO4GEO, 2018-2021 (SSA)	26 GEOF= partner		Austrija, Belgija, Grčka, Hrvatska, Italija, Latvija, Nizozemska, Njemačka, Poljska, Slovenija. Švedska, Španjolska
Business driven problem-based learning for academic excellence in geoinformatics – GEOBIZ, 2019-2022 (CBHE)	16 GEOF= koordinator	Albanija, Bosna i Hercegovina, Crna Gora, Kosovo, Moldavija	Belgija, Hrvatska, Njemačka, Srbija
University network for disaster risk reduction and management in Indian Ocean Rim - UN4DRR, 2020-2023 (CBHE)	9 GEOF= partner	Indonezija, Maldivi, Sri Lanka	Belgija, Cipar, Hrvatska, Španjolska
Spatial Data Infrastructure and Earth observation education and training for North Africa - SEED4NA, 2020-2023 (CBHE)	10 GEOF= partner	Egipat, Maroko, Tunis	Belgija, Hrvatska, Nizozemska, Njemačka
Curricula innovation in climate-smart urban development based on green and energy efficiency with the nonacademic sector – SmartWB, 2023-2025 (CBHE)	18 GEOF= partner	Albanija, Bosna i Hercegovina, Crna Gora	Austrija, Hrvatska, Norveška, Njemačka, Srbija, Španjolska

- Partnerstva za inovacije (Savez za inovacije, Projekti usmjereni na budućnost)
- Projekti jačanja kapaciteta (u visokom obrazovanju, u području strukovnog obrazovanja i osposobljavanja, u području mladih, u području sporta)

Prema ciljevima svake mjere i načinima kako se realiziraju, u kontekstu modernizacije visokoškolskog obrazovanja trenutan i najdublji trag ostavljaju partnerstva za izvrsnost kroz koja se uspostavljaju nove institucionalne forme obrazovanja. Konkretno, Europska sveučilišta uspostavljaju nove studijske programe koje zajedno realiziraju tri sveučilišta i koja predviđaju osmišljavanje novih studijskih programa, pokretanje studija i studiranje upisanih studenata na sva tri sveučilišta (po godinu dana) čime se ostvaruju brojni prioriteti Europske unije, no zbog visoke cijene takvog oblika obrazovanja održivost tih projekata nakon prestanka EU financiranja je problematična.

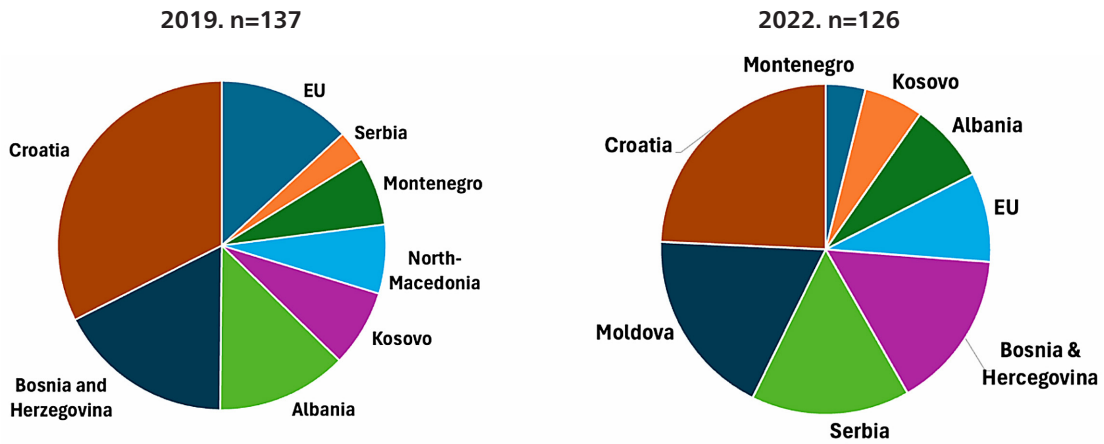
Stoga se za modernizaciju visokoškolskog obrazovanja koriste projekti Suradničkih partnerstava (namijenjeni za institucije iz EU i pridruženih zemalja) te projekti Jačanja kapaciteta u visokom obrazovanju (CBHE) (namijenjeni za institucije izvan EU). Ti projekti, za koje se vrijednost darovnice EU kreće između 250.000 i 1.000.000 EUR su i najbrojniji (npr. godišnje se financira više od 200 CBHE projekata.

Geodetski fakultet, odnosno Erasmus projektni tim, je od 2016. godine do danas sudjelovao ili sudjeluje u pet CBHE projekata i jednom projektu Alijanse za sektorske vještine (SSA), što je danas ekvivalentno Partnerstvu za inovacije, koji su obrađivali pojedine teme iz područja geodezije i geoinformatike (vidi Tablicu 1).

Iz naslova projekata je vidljivo što im je bio cilj pri čemu su CBHE projekti išli za modernizacijom studija (predmeta) i uspostavom suradnje s dionicima, a SSA projekt je imao za cilj razviti strategiju koja će dati odgovor kako obrazovati stručnjake za efikasnu primjenu daljinskih istraživanja (Copernicus programa) u EU te studijske sadržaje i oblike izvođenja nastave koji će doprinijeti bržem i kvalitetnijem usvajanju potrebnih znanja i vještina. Svi navedeni projekti su uspješno u rokovima realizirani, osim UN4DRR i SEED4NA projekata koji su zbog utjecaja pandemije COVID-19 virusa produženi za 6 odnosno 10 mjeseci.

3. Analize i mjere razvijene kroz Erasmus+ projekte Geodetskog fakulteta

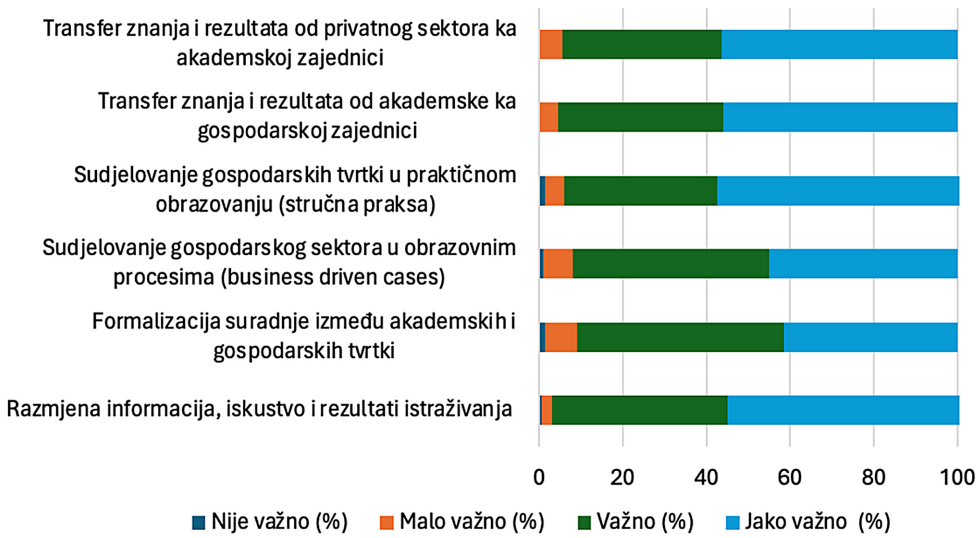
Svi CBHE projekti podrazumijevaju da konzorciji partnerskih institucija provedu prethodnu detaljnu analizu potreba korisnika, dionika (gospodarstva, struke, javne uprave, studenata i nastavnika). Kako su projekti BESTSDI i GEOBIZ tematski bili vrlo bliski, provodili se u istoj regiji (Zapadni Balkan) i obuhvatili dijelom iste partnerske institucije (8 od 17 odnosno 16) istraživanje o potrebama za suradnjom u području infrastrukture prostornih podataka akadem-



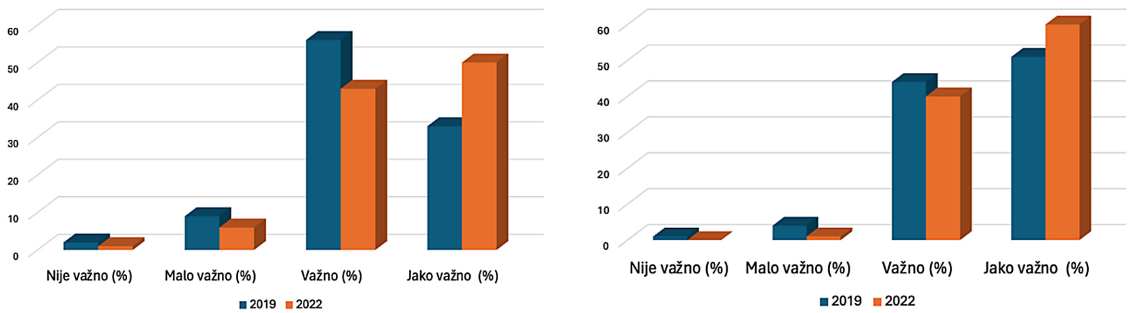
Slika 1: Pregled broja zaprimljenih odgovora na istraživanje po projektima i državama

skih i gospodarskih dionika provedeno 2019. godine (Crompvoets i dr., 2020) ponovljeno je u okviru GEO-BIZ projekta 2022. godine. Istraživanja su provedena s ciljem prikupljanja informacija o:

- potrebama i očekivanjima akademske zajednice i poslovnih subjekata u pogledu kvaliteta sadašnjeg visokog obrazovanja u Infrastrukturi Prostornih Podataka (IPP),
- očekivanjima poslovnog sektora o znanju i vještinama koje pružaju akademske institucije,
- oblicima suradnje akademskog i poslovnog sektora u obrazovnom i istraživačkom procesu,
- očekivanjima akademskog i poslovnog sektora u daljem razvoju IPP i
- praćenju promjena potreba i suradnje u području IPP.



Slika 2: Prepoznata važnost pojedinih aspekata pitanja „Koliko važnim nalazite aspekte postojeće suradnje akademskog i poslovnog sektora u području IPP obrazovanja i istraživanja?“



„Formalizacija suradnje između akademskih i gospodarskih tvrtki“

„Razmjena informacija, iskustvo i rezultati istraživanja“

Slika 3: Promjena razmišljanja dionika 2019. i 2022. godine na aspekte pitanja o suradnji

Tablica 2: Modernizirani/novi predmeti i LLL tečajevi definirani kroz dovršene Erasmus CBHE i SSA projekte Geodetskog fakulteta

Projekt	Partnerskih fakulteta	Moderniziranih predmeta	Novih predmeta	LLL tečajeva	Ukupno
BESTSDI	13	117	8	35	160
EO4GEO	-	17		23	40
GEOBIZ	10	24	4	32	60
UN4DRR	5	13	12	15	40
SEED4NA	6	21	9	18	48
Ukupno	**34**	**192**	**33**	**123**	**348**

Istraživanjem, u obliku ankete obuhvaćeni su predstavnici tvrtki i javnih tijela iz područja geodezije, geoinformatike i srodnih područja. U oba istraživanja anketa je upućena na oko 800 adresa u 6 država Zapadnog Balkana 2019., odnosno 5 država i Moldaviju 2022. godine. Istraživanjem (anketom) u velikoj mjeri su obuhvaćeni isti subjekti, te je i broj zaprimljenih odgovora bio približno jednak (vidi sliku 1). Istraživanje u okviru GEOBIZ projekta provedeno je s ciljem istraživanja da li su BESTSDI i GEOBIZ projekt u konkretnom okviru uspjeli i u kojoj mjeri promijeniti percepciju dionika o potrebi suradnje akademskih i gospodarskih dionika u domeni infrastrukture prostornih podataka, što može poslužiti kao objektivni pokazatelj efekta CBHE projekata na percepciju dionika (izvan kruga konzorcija partnera) o značaju i korisnosti te vrste projekata.

Komparativna analiza je pokazala vidljiv pomak u razmišljanjima dionika o potrebi suradnje akademskog i gospodarskog sektora što se može ilustrirati odgovorima na pitanje „Koliko važnim nalazite aspekte postojeće suradnje akademskog i poslovnog sektora u području IPP obrazovanja i istraživanja?", vidi slike 2 i 3, i poslužila je kao podloga za oblikovanje novih oblika suradnje akademskih i gospodarskih subjekata. Koristeći iskušani model Sporazuma o suradnji mogući oblici te suradnje su proširen na razradu praktičnog dijela nastave zasnovanog na problemskim zadacima koji su proistekli iz problema/zadataka s kojima se tvrtke susreću oblikovanih na način da se mogu kontinuirano nadograđivati što je potpomognuto aktivnim sudjelovanjem tvrtki, kako kroz korištenje njihove opreme, sudjelovanja djelatnika tvrtki u izvođenju nastave (vježbi) i izvođenju dijela praktične nastave u tvrtkama.

4. Modernizacija kurikuluma partnerskih sveučilišta

Realizacijom prije navedenih projekata Erasmus tim Geodetskog fakulteta sudjelovao je u modernizaciji postojećih i izradi novih kurikuluma predmeta i modula studijskih programa geodetsko-geoinformatičkih i srodnih studija. Paralelno, iz tih moderniziranih ili novih materijala oblikovan je i niz tečajeva cjeloživotnog obrazovanja. Partneri na projektima su u trećoj (ukoliko je produžen četvrtoj) godini projekta modernizirane i nove sadržaje testirali kroz izvođenje predmeta u redovitoj nastavi ili organizaciju cjeloživotnih tečajeva. Ukupno je u kroz doprinos svakog projekata stvorena banka predmeta i LLL tečajeva s opisima predmeta i sadržajem materija za 348 jedinica, vidi Tablicu 2.

Stvorena banka opisa i materijala za predmete i LLL tečajeve, bez obzira na činjenicu da u tih 348 jedinica ima i ponavljanja predstavlja izuzetnu vrijednost koja može poslužiti svim partnerskim, a i vanjskim sveučilištima/fakultetima pri modernizaciji ili izradi novih studijskih programa, što se odnosi i na studije geodezije i geoinformatike u Hrvatskoj.

5. Problemsko učenje i poučavanje usmjereno na studente

Kako postojeći (klasični) tako i novi (moderni) oblici poučavanja imaju svoje prednosti i nedostatke. Međutim, promjene koje se događaju u društvu, tehnološke i socijalne, koje rezultiraju novim generacijama koje različito razmišljaju i savladavaju izazove nameće potrebu usklađivanja organizacije nastave i metodologije poučavanja na sveučilištima. Kao moderni oblici provedbe nastave i metodologije poučavanja danas se spominju:

Problemsko učenje ili učenje zasnovano na problemima, eng. Problem Based Learning (PBL) najstariji je oblik modernog učenja definiran već 1960-tih godina i zasniva se na promicanju kritičkog razmišljanja i rješavanja problema u autentičnim situacijama učenja. PBL koristi autentične, loše definirane i interdisciplinarne scenarije problema za poticanje učenja. Istraživanjem različitih perspektiva i rješavanjem nedostataka u učenju studenti konstruiraju znanje i razvijaju održiva rješenja. Predavač igra ulogu voditelja koji podržava studente u njihovom procesu učenja.

Kombinirana mobilnost, eng. Blended Mobility (BM) odnosi se na stratešku kombinaciju faza internetskog

učenja s razdobljima kratke fizičke mobilnosti prvenstveno prema subjektima gospodarskog ili javnog sektora u kojima student praktično svladava vještine i znanja kroz realizacija postavljenog zadatka uz potporu stručnjaka iz tvrtke/institucije u kojoj realizira BM. Uloga predavača je također vođenje studenta, ali je u odnosu na PBL još manje izražena. Taj je pristup međunarodnom učenju posljednjih godina stekao znatan interes za europsko sveučilišno obrazovanje zbog uvođenja mješovitih intenzivnih programa u novi program Erasmus +.

Masivni otvoreni tečajevi putem daljinskog pristupa, eng. Massive open on-line courses dobili su veliki poticaj posljedicama pandemije COVID-19 virusa kada su neposredni kontakti između ljudi bili drastično ograničeni. Ovaj vid poučavanja zasniva se na unaprijed snimljenim materijalima poučavanja, definiranim zadacima i provjerama znanja koji omogućuju da veliki broj studenata pristupi takvom tečaj, te su financijski vidno jeftiniji u realizaciji od klasičnog oblika nastave. Stoga danas u svijetu već ima niz sveučilišta koja svoju cjelokupnu nastavu izvode putem daljinskog pristupa (on-line).

Poučavanje i učenje usmjereno na studente, eng. student-centered approach in teaching and learning osmišljen je kao koncept poučavanja i učenja nasuprotan klasičnom današnjem modelu poučavanja usmjerenog na predavače, eng. teacher-centered. Model poučavanja usmjeren na predavače osmišljen je u 19. stoljeću kada su se sveučilišta u svijetu počela oblikovati i organizirati u formu koju i danas primjenjuju. Zbog svih prije navedenih promjena i utjecaja, ali i činjenice da je model osmišljen za elitna sveučilišta s manjim brojem studenata, dok ga danas primjenjujemo na masovnim sveučilištima, taj oblik visokoškolskog poučavanja danas više nije adekvatan i vidljivo ostvaruje sve slabije rezultate (studenti postaju pasivni konzumenti poučavanja). Oblik poučavanja za uvođenje pristupa usmjerenog na studente je učenje temeljeno na projektima (PBL) u kojem studenti rade na projektima, poput projekata zajednice i dizajna, a od njih se očekuje da upravljaju projektima ili barem predlažu akcije ili rješenja. Pristup usmjeren na studente usko je povezan s upotrebom tehnologije za istraživanje, interakcije, gamifikaciju, simulacije i povratne informacije. Povratne informacije usmjerene na studente potiču aktivno učenje putem promišljenih povratnih informacija, dok prilagodljiva nastava uključuje učenike u izgradnju sadržaja. Uloga sveučilišta u ovom pristupu je stvoriti uvjete za studenta da može realizirati svoj izbor i zamisli studiranja, dok je predavač facilitator studentovog studiranja. Navedeno također implicira da odgovornost za studiranje, koje danas dijele student i predavač postaje u potpunosti odgovornost studenta.

Kroz Erasmus+ projekte projektni tim Geodetskog fakulteta testirao je do sada prva tri oblika poučavanja prateći kako su oni implementirani na partnerskim sveučilištima. Uspjeh implementacije navedenih pristupa ovisio je prvenstveno o motivaciji predavača da uvedu promjene u „svoje" predmete. Evaluacije testno održanih moderniziranih ili novouvedenih predmeta pokazala je dvojake rezultate. Dobro pripremljeno i realizirano izvođenje predmeta rezultiralo je zadovoljstvom studenata i pojačanim interesom za predmet/studij. Pri tome je adekvatna motivacija studenata bila od posebne važnosti, jer su se kako predavači, tako i studenti našli u izmijenjenoj situaciji s promijenjenom ulogom, odnosno odgovornošću. Ukoliko se može govoriti o nedostatcima novouvedenih metoda, prije svega je riječ o smanjenju neposrednog kontakta između predavača i studenta te gubljenju socijalnog značenja visokoškolskog obrazovanja u kontekstu oblikovanja vrijednosti kod mladih ljudi zasnovanih na kontaktu s predavačima.

6. Zaključak

Erasmus+ projekti jačanja kapaciteta u visokom obrazovanju pokazali su se u proteklih osam godina koliko se realiziraju na Geodetskom fakultetu Sveučilišta u Zagrebu kao vrlo koristan alat za testiranje novih sadržaja studijskih programa i oblika poučavanja. Kako se implementacija novih sadržaja i oblika događa prvenstveno na partnerskim sveučilištima izvan EU, to omogućuje programskim partnerima, sveučilištima iz EU stjecanje prethodnih spoznaja i iskustava o uvođenju novih sadržaja i oblika koja se mogu iskoristiti za modernizaciju vlastitih studijskih programa, odnosno uvođenja novih formi poučavanja. Veći broj projekata u kojim je sudjelovao Geodetski fakultet omogućio je stvaranje bogate banke predmeta i LLL tečajeva koji predstavljaju bogatstvo izbora u trenutku kada će se u Hrvatskoj pristupiti modernizaciji sadržaja i metodologije izvođenja studija Geodezija i geoinformatika.

Literatura

Crompvoets, J., Bačić, Ž., Poslončec-Petrić, V. (2020): Academia-Business Survey on Needs and Cooperation in Field of Spatial Data Infrastructure. Survey Report, EuroSDR publication, June 2020, 1-35

EACEA (2023): Erasmus+ program – vodič kroz program. Europska izvršna agencija za obrazovanje i kulturu (EACEA), verzija 1 (2024): 28.11.2023.

El-Azar, D. (2022): 4 trends that will shape the future of higher education. World Economic Forum, Minerva project, objavljeno 7.02.2022. https://www.weforum.org/agenda/2022/02/four-trends-that-will-shape-the-future-of-higher-education/

Klychanko, T i Mau, V. (2021): Modern Challenges for Universities. Poglavlje u The Promise of Higher Education, van't Land, H., Corcoran, A i Iancu, D-C urednici, Springer, Cham. https://doi.org/10.1007/978-3-030-67245-4_36

Modernization of Geodesy and Geoinformatics Study Programs through Erasmus+ KA2 Projects

Abstract

Rapid technological changes driven by the digital revolution have resulted in accelerated changes at all levels of education. The challenges that higher education faces are related to the introduction of new digital technologies, the pace of technological changes that are faster than the usual pace of modernization of curricula, the emergence of new and the disappearance of old professions, interdisciplinarity and the need for studies that will enable the acquisition of practical skills. All of the above requires new content and forms of study. One of the tools by which universities across Europe implement changes is the Erasmus+ program of the European Union, especially Key Action 2, which aims to modernize or create new study programs (Partnerships and Capacity Building in Higher Education). Since 2016, the Faculty of Geodesy has participated or is participating in five capacity building projects in higher education (CBHE projects BESTSDI, GEOBIZ, UN4DRR, SEED4NA, SmartWB) and one project of the Alliance for Sectorial Skills (Erasmus+ SSA project EO4GEO) that aimed to modernize all or part of the study programs of geodesy and geoinformatics and related profiles. Within each of these projects, research was conducted on the basis of which knowledge was gained about the needs of users (stakeholders from the public and private sectors), defined parts of study programs for modernization, as well as the content of the modernization itself. In doing so, special emphasis was placed on the development of cooperation between the academic and economic community, i.e. the involvement of economic stakeholders in the educational process in the part of practical knowledge and skills. This paper provides an overview of what the beneficiaries who participated in the projects expect from the modernization of study programs and ways of studying, the solutions that have been developed and implemented, and the challenges that have arisen in the modernization processes.

Keywords: *Erasmus, CBHE projects, SSA projects, curriculum modernization, stakeholder cooperation*

Primjena blockchaina i pametnih ugovora u pravnom prometu nekretninama

Josip Šimić[1], Ilija Ćaćić[1], Jelena Jurišić[1]

[1] Ericsson Nikola Tesla, Krapinska 45, Zagreb josip.simic@ericssonnikolatesla.com, ilija.cacic@ericssonnikolatesla.com, jelena.jurisic@ericssonnikolatesla.com

Sažetak

Primjena blockchaina i pametnih ugovora u zemljišnoj knjizi i katastru predstavlja inovativan pristup digitalizaciji procesa evidentiranja i upravljanja nekretninama. U radu se, kroz analizu primjera iz prakse i teorijskih pristupa, istražuje kako blockchain može osigurati integritet i nepromjenjivost podataka, eliminirajući potrebu za posrednicima i smanjujući mogućnost prijevara. Zemlje poput Švedske, Gruzije i Ujedinjenog Kraljevstva već su pokrenule inicijative za korištenje blockchain tehnologije u zemljišnim knjigama, što je rezultiralo poboljšanom transparentnošću, ubrzanim procesima i smanjenjem troškova. Pametni ugovori dodatno olakšavaju procese automatskim izvršavanjem transakcije u slučaju zadovoljenja niza uvjeta, što ubrzava i pojednostavljuje cijeli postupak transakcija s nekretninama. U praksi, to znači da se transakcije vezane uz nekretnine, poput kupoprodaje, mogu provesti bez potrebe za posredovanjem trećih strana kao što su javni bilježnici ili odvjetnici. Unatoč potencijalnim koristima, postoje i izazovi u implementaciji ovih tehnologija, uključujući pravne i regulatorne prepreke, sigurnosne probleme i potrebu za integracijom s postojećim sustavima. Predviđa se da će do 2030. godine implementacija ovih tehnologija postati sve raširenija, što će rezultirati daljnjim unapređenjem procesa evidentiranja nekretnina i smanjenjem administrativnih troškova. Primjena blockchaina i pametnih ugovora predstavlja ključni korak prema digitalnoj transformaciji zemljišnih knjiga i katastra, pružajući mogućnost stvaranja efikasnijeg, transparentnijeg i pristupačnijeg sustava upravljanja nekretninama.

Ključne riječi: *blockchain, , katastar, nekretnine, pametni ugovori, zemljišne knjige*

1. Uvod

Digitalna transformacija mijenja način poslovanja u raznim industrijama, uključujući i sektor nekretnina. Primjena blockchain tehnologije i pametnih ugovora u zemljišnoj knjizi i katastru nudi inovativna rješenja za sigurnije, transparentnije i učinkovitije upravljanje nekretninama. Ovaj rad istražuje kako ove tehnologije mogu unaprijediti procese evidentiranja i upravljanja nekretninama kroz analizu teorijskih pristupa i praktičnih primjera.

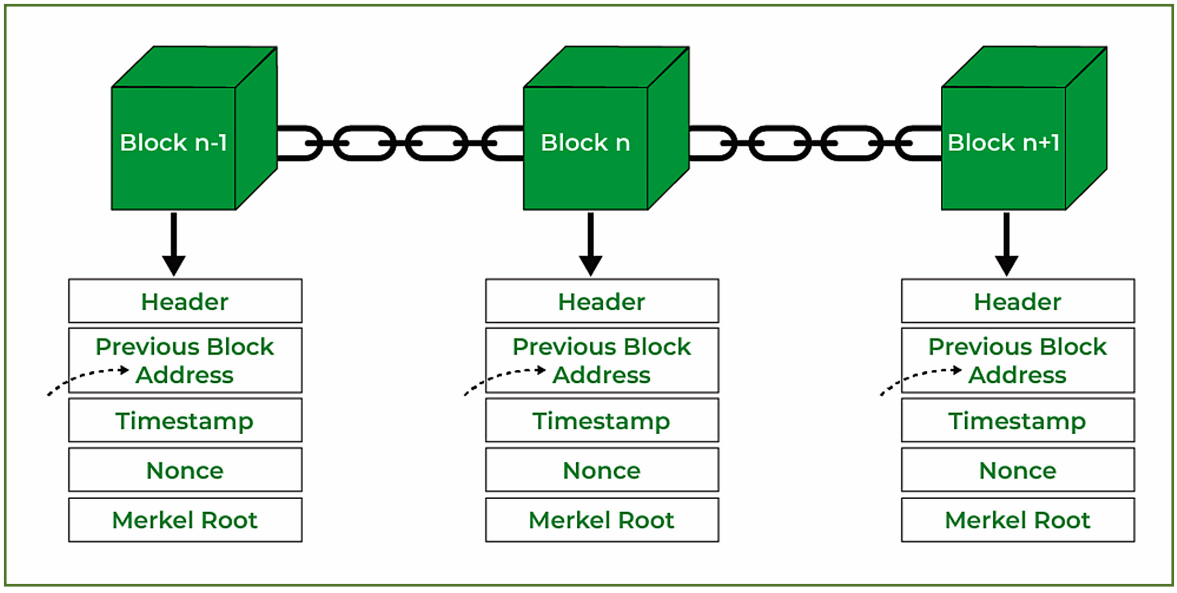
Tehnološki napredak i digitalna transformacija predstavljaju ključne elemente suvremenih poslovnih modela, a sektor nekretnina nije iznimka. U tradicionalnim sustavima zemljišnih knjiga i katastra, postoji niz izazova koji se odnose na točnost podataka, transparentnost, sigurnost i učinkovitost procesa. Blockchain tehnologija, sa svojom decentraliziranom i transparentnom prirodom, nudi potencijalna rješenja za ove izazove. Uvođenjem pametnih ugovora, procesi vezani uz transakcije nekretninama mogu biti dodatno pojednostavljeni i automatizirani, što može dovesti do značajnih poboljšanja u učinkovitosti i smanjenju troškova.

2. Blockchain tehnologija

Blockchain je decentralizirana digitalna knjiga koja bilježi transakcije na mreži računala. Njegove ključne karakteristike uključuju decentralizaciju, transparentnost, sigurnost i nepromjenjivost, što ga čini idealnim za primjenu u zemljišnim knjigama gdje je točnost podataka i povjerenje od izuzetne važnosti. Blockchain omogućuje sigurno čuvanje podataka kroz kriptografske metode, čime se osigurava da se podaci ne mogu mijenjati nakon što su jednom zabilježeni. Time se eliminira mogućnost manipulacije podacima i povećava povjerenje u sustav (Beck i dr., 2017).

Jedna od osnovnih prednosti blockchaina je njegova decentralizirana priroda koja omogućuje da nema jedinstvenog mjesta za kontrolu ili manipulaciju podacima. Svaki čvor u blockchain mreži posjeduje kopiju cijele blockchain knjige, čime se osigurava transparentnost i sigurnost podataka. Svaka promjena ili dodavanje podataka mora biti odobrena od strane većine čvorova u mreži, što dodatno osigurava integritet i točnost podataka (Zavolokina i dr., 2020).

Osim toga, blockchain koristi kriptografske metode za zaštitu podataka. Svaka transakcija je zaštićena di-



Slika 1: Shematski prikaz blockchain tehnologije (Swan, 2015)

gitalnim potpisima koji osiguravaju autentičnost i nepovredivost podataka. To znači da su podaci sigurni od neovlaštenog pristupa i manipulacije. Uz to, svaki blok u blockchainu sadrži hash prethodnog bloka, što čini lanac transakcija nepromjenjivim i otpornim na promjene (Wüst i Gervais, 2018).

3. Pametni ugovori: definicija i funkcionalnost

Pametni ugovori su samostalno izvršivi ugovori čiji su uvjeti ugovora zapisani u kodu. Oni automatski provode i izvršavaju uvjete ugovora kada su ispunjeni unaprijed definirani uvjeti. Ovi ugovori omogućuju eliminaciju posrednika u transakcijama, čime se smanjuju troškovi i ubrzava proces. Pametni ugovori koriste kriptografske metode za sigurnost i nepovredivost podataka, čime se dodatno povećava povjerenje među stranama uključenim u transakciju.

Pametni ugovori omogućuju automatsku provjeru i izvršenje ugovornih obveza bez potrebe za ljudskom intervencijom. Na primjer, u slučaju kupoprodaje nekretnine, pametni ugovor može automatski provjeriti ispunjenje svih uvjeta transakcije (kao što su uplata sredstava, prenos vlasništva i slično) i izvršiti prijenos vlasništva čim su svi uvjeti ispunjeni. To značajno ubrzava proces i smanjuje mogućnost grešaka ili prijevara.

Pametni ugovori također mogu smanjiti administrativne troškove povezane s obradom i provedbom ugovora. Automatska provjera i izvršenje uvjeta smanjuje potrebu za ručnim pregledom i intervencijama, što rezultira bržim i jeftinijim transakcijama. Uz to, pametni ugovori mogu povećati sigurnost transakcija jer su svi uvjeti i podaci vezani uz ugovor pohranjeni u blockchainu, što ih čini nepromjenjivima i otpornima na manipulacije. (Szabo, 1997)



Slika 2: Primjer pametnog ugovora u blockchain mreži (vlastita ilustracija)

4. Blockchain i pametni ugovori u transakcijama nekretninama

Blockchain tehnologija osigurava da svi podaci o nekretninama budu nepromjenjivi i transparentni, stvarajući pouzdaniji sustav zemljišnih knjiga. Zemlje poput Švedske i Gruzije pioniri su u primjeni blockchaina za zemljišne knjige.

4.1. Švedska

Švedska je jedna od prvih zemalja koja je pokrenula pilot projekte za korištenje blockchain tehnologije u zemljišnim knjigama. Lantmäteriet, švedska agencija za katastar, u suradnji s nekoliko privatnih tvrtki, započela je s istraživanjem blockchaina za transparentnije i sigurnije transakcije nekretninama. Projekt je započet 2016. godine, a do danas je pokazao značajne prednosti u ubrzanju procesa i smanjenju administrativnih troškova. Uvođenje blockchain tehnologije omogućilo je brže i učinkovitije evidentiranje vlasničkih prava, smanjenje broja potrebnih posrednika i smanjenje troškova povezanih s administracijom (Proskurovska i Dörry, 2022).

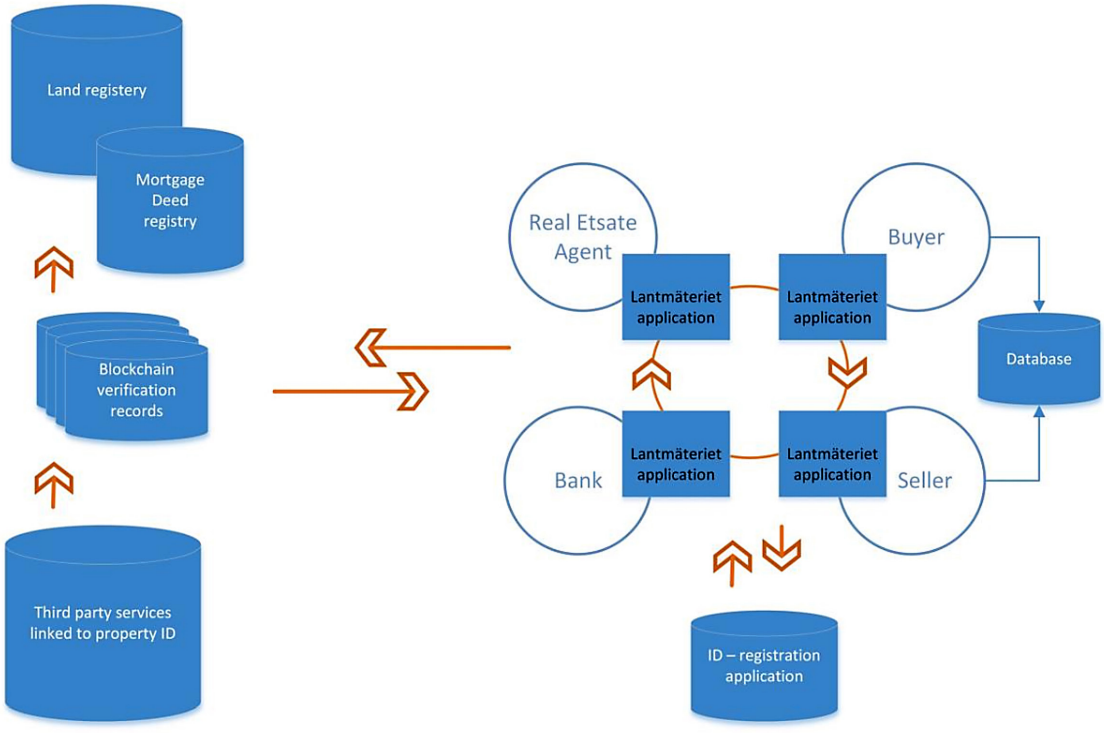
Jedna od glavnih inicijativa bila je digitalizacija procesa registracije nekretnina putem blockchaina. Kroz suradnju s privatnim sektorom, Švedska je razvila sustav koji omogućuje sigurno i transparentno praćenje vlasničkih prava. Uvođenje blockchaina smanjilo je vrijeme potrebno za registraciju transakcija s nekoliko mjeseci na nekoliko dana (Beck i dr., 2017). Ovaj sustav omogućava brže i sigurnije obavljanje transakcija, što je rezultiralo većim povjerenjem korisnika u sustav zemljišnih knjiga (Zavolokina i dr., 2020).

Naučene lekcije iz švedskog iskustva uključuju potrebu za bliskom suradnjom između državnih tijela i privatnog sektora, kao i važnost edukacije svih sudionika u procesu kako bi se osiguralo pravilno razumijevanje i korištenje novih tehnologija. Također, prilagodba pravnog okvira bila je ključna za podršku implementaciji novih tehnologija (Piazza i Sforza, 2017). Švedska je uspjela postići značajno smanjenje vremena potrebnog za završetak transakcija nekretninama, što je rezultiralo većom zadovoljstvu korisnika i smanjenjem administrativnih troškova (Gillpatrick i dr., 2022).

4.2. Gruzija

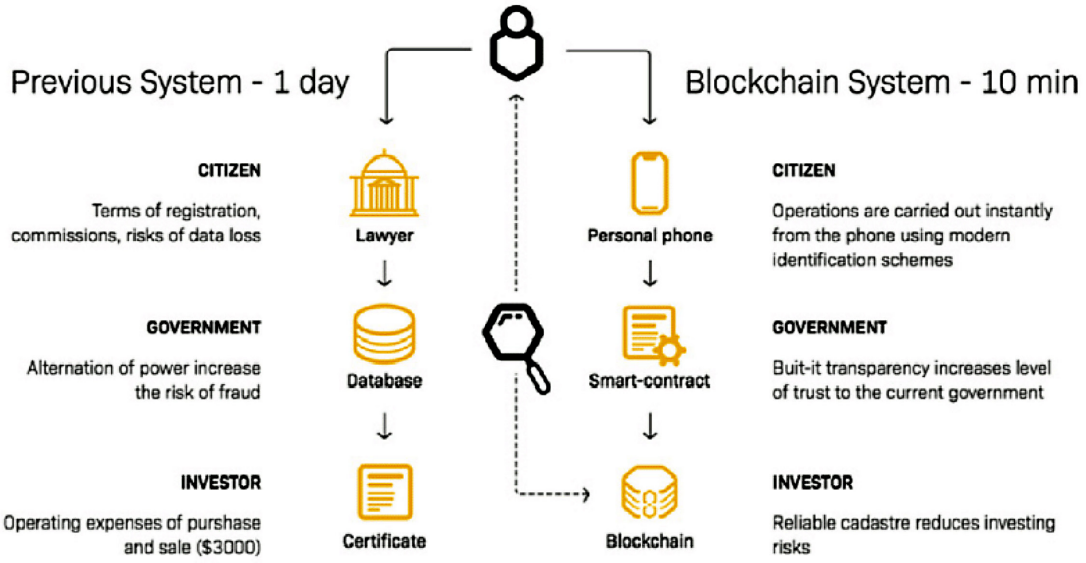
Gruzija je implementirala blockchain tehnologiju u svoj zemljišni registar kroz suradnju s tvrtkom Bitfury. Nacionalna agencija za javni registar (NAPR) koristi blockchain od 2017. godine za verifikaciju transakcija nekretninama. Ovaj sustav omogućava transparentno praćenje vlasničkih prava i smanjenje prijevara. Implementacija blockchain tehnologije u Gruziji rezultirala je značajnim povećanjem povjerenja u zemljišne registre, smanjenjem korupcije i prijevara, te povećanjem učinkovitosti procesa registracije vlasničkih prava (Gillpatrick i dr., 2022).

Kroz projekt uvođenja blockchain tehnologije, Gruzija je uspjela digitalizirati i automatizirati proces registracije nekretnina. Tradicionalno, proces registracije vlasništva bio je spor i podložan greškama, ali uvođenjem blockchaina, Gruzija je uspjela smanjiti vrijeme potreb-



Source: Kempe (2017: 60)

Slika 3: Prikaz sustava zemljišne knjige poslije implementacije blockchain tehnologije u Švedskoj (Proskurovska i Dörry, 2022)



Slika 4: Prikaz sustava zemljišne knjige prije i poslije implementacije blockchain tehnologije u Gruziji (Gillpatrick i dr., 2022)

no za registraciju na samo nekoliko dana (Piazza i Sforza, 2017). Osim toga, transparentnost koju nudi blockchain omogućila je građanima i investitorima veću sigurnost i povjerenje u sustav (Zavolokina i dr., 2020).

Naučene lekcije iz gruzijskog iskustva uključuju važnost integracije blockchaina za povećanje povjerenja u zemljišne registre, transparentnost koju nudi blockchain za smanjenje korupcije i prijevara, te ključnu ulogu tehničke podrške i sigurnosti sustava. Implementacija blockchain tehnologije u Gruziji pokazala je kako inovativni pristupi mogu riješiti dugogodišnje probleme u upravljanju nekretninama i povećati efikasnost administrativnih procesa (Zwitter i Boisse-Despiaux, 2018).

4.3. Ujedinjeno Kraljevstvo

U Ujedinjenom Kraljevstvu, HM Land Registry pokrenuo je projekt Digital Street kako bi istražio mogućnosti blockchain tehnologije u modernizaciji zemljišne knjige. Cilj projekta je ubrzanje procesa transakcija i smanjenje troškova kroz digitalizaciju i automatizaciju. Kroz ovaj projekt, UK je uspio testirati i prilagoditi različite aspekte blockchain tehnologije, uključujući sigurnost, brzinu transakcija i pravnu valjanost digitalnih zapisa.

Projekt Digital Street omogućio je testiranje novih tehnologija u kontroliranim uvjetima, što je pomoglo identificirati potencijalne probleme i prilagoditi sustav prije široke implementacije. Uvođenje blockchain tehnologije omogućilo je brže i sigurnije obavljanje transakcija nekretninama, smanjujući pritom troškove i povećavajući transparentnost. Jedan od ključnih ciljeva projekta bio je smanjenje vremena potrebnog za obavljanje transakcija s nekoliko tjedana na samo nekoliko dana.

Naučene lekcije iz iskustva Ujedinjenog Kraljevstva uključuju potrebu za stalnim testiranjem i prilagodbom inovacija u zemljišnim knjigama, sudjelovanje svih relevantnih dionika, uključujući pravnike, developere i vladu, te važnost pravne sigurnosti i prilagodbe zakonskog okvira za podršku implementaciji novih tehnologija. Iskustvo UK-a pokazalo je kako blockchain tehnologija može unaprijediti transparentnost i učinkovitost sustava zemljišnih knjiga, smanjujući pritom administrativne troškove i vrijeme potrebno za obavljanje transakcija. (URL 1).

5. Praktične implikacije i koristi

Implementacija blockchaina i pametnih ugovora donosi brojne praktične koristi u procesu transakcija nekretninama. Prije svega, blockchain tehnologija pojednostavljuje cijeli proces kupnje i prodaje nekretnina. Korištenjem decentralizirane knjige, svaka transakcija se bilježi u stvarnom vremenu, smanjujući potrebu za ručnim dokumentima i posrednicima. To omogućuje brže obavljanje transakcija i smanjenje troškova povezanih s administrativnim postupcima.

Eliminacija posrednika predstavlja jednu od ključnih koristi pametnih ugovora. Tradicionalno, transakcije nekretninama zahtijevaju sudjelovanje brojnih posrednika, uključujući javne bilježnike, odvjetnike i brokere. Pametni ugovori smanjuju potrebu za posrednicima, omogućujući izravne transakcije između kupca i prodavatelja. Ovo rezultira smanjenjem troškova i ubrzanjem procesa.

Jedna od najvećih prednosti blockchain tehnologije je smanjenje rizika od prijevara i grešaka. Nepromjenjiva knjiga blockchaina osigurava da, jednom zabilježena transakcija, ne može biti izmijenjena ili falsificirana. To značajno smanjuje rizik od prijevara i grešaka koje se često javljaju u tradicionalnim sustavima zemljišnih knjiga. Transparentnost koju pruža blockchain omogućava pregled povijesti transakcija, što pomaže u izgradnji povjerenja među svim uključenim stranama.

Blockchain tehnologija također povećava transparentnost i povjerenje u sustav zemljišnih knjiga. Sve transakcije su vidljive svim sudionicima u mreži, što omogućava veću razinu transparentnosti i povjerenja. To može rezultirati većom sigurnošću i povjerenjem u sustav zemljišnih knjiga, čime se smanjuje potreba za dodatnim provjerama i kontrolama.

6. Izazovi i pravni aspekti

Implementacija blockchaina i pametnih ugovora u zemljišne knjige i katastar suočava se s brojnim izazovima, uključujući pravne i regulatorne prepreke, sigurnosne probleme i potrebu za integracijom s postojećim sustavima. Postojeći zakoni i propisi ne pokrivaju dovoljno blockchain tehnologiju, stoga je razvoj odgovarajućeg pravnog okvira ključan za podršku legalizaciji i standardizaciji korištenja blockchaina. Jedan od ključnih izazova je prilagodba postojećeg pravnog okvira kako bi se omogućila implementacija blockchain tehnologije. Tradicionalni zakoni i propisi često nisu prilagođeni za podršku inovativnim tehnologijama poput blockchaina. Stoga je potrebno razviti nove zakone i propise koji će omogućiti legalizaciju i standardizaciju korištenja blockchain tehnologije u zemljišnim knjigama i katastru (Piazza i Sforza, 2017).

Sigurnost podataka također je ključna u implementaciji blockchaina. Zaštita osjetljivih informacija u transakcijama nekretninama je ključna za osiguranje povjerenja u sustav. Blockchain koristi kriptografske metode za zaštitu podataka, ali je također potrebno osigurati dodatne mjere sigurnosti kako bi se spriječio neovlašten pristup i manipulacija podacima (Wüst i Gervais, 2018).

Pitanje privatnosti također predstavlja izazov u implementaciji blockchain tehnologije. Transparentnost koju nudi blockchain može biti u sukobu s potrebom za zaštitom osobnih informacija. Stoga je potrebno razviti mehanizme koji će omogućiti balansiranje između transparentnosti i privatnosti podataka (Zwitter i Boisse-Despiaux, 2018).

Integracija blockchaina s postojećim sustavima zemljišnih knjiga i nekretnina može biti složena, a naravno veliki je zadatak i uvjeravanje dionika da prihvate blockchain tehnologiju, što zahtijeva demonstraciju jasnih prednosti i pružanje opsežne edukacije i podrške (Zavolokina i dr., 2020).

7. Implementacija blockchaina i pametnih ugovora u Hrvatskoj

Hrvatska ima potencijal za implementaciju blockchaina i pametnih ugovora u zemljišnu knjigu i katastar kako bi se poboljšali postojeći sustavi upravljanja nekretninama. Naravno, nužan je razvoj odgovarajućeg pravnog okvira koji će omogućiti legalizaciju i standardizaciju korištenja blockchain tehnologije i pametnih ugovora. Implementacija rješenja za zemljišne knjige i katastar temeljenog na blockchainu u Republici Hrvatskoj mogla bi uključivati sljedeće komponente:

1. Implementacija privatnog i dozvoljenog blockchaina:

   Samo ovlašteni sudionici, poput javnih bilježnika, zaposlenika katastra i zemljišne knjige, imali bi pravo verificirati transakcije. Sve transakcije, uključujući hashove, zabilježile bi se i pohranile u privatnom blockchainu (jedna od mogućih tehnologija implementacije je platforma otvorenog koda Hyperledger Fabric). Ovlašteni sudionici osiguravaju integritet i sigurnost podataka, a svaka promjena bit će transparentno zapisana i verificirana od strane mreže sudionika.

2. One stop shop za zemljišne knjige i katastar (OSS):

   Postojeći OSS bi se nadogradio da uključuje korisnička sučelja za kupce, prodavatelje, javne bilježnike i zaposlenike zemljišne knjige i katastra. Korisnici pristupaju OSS-u-u putem web ili mobilne aplikacije, omogućujući im pregled, unos i verifikaciju podataka o nekretninama te praćenje statusa transakcija u realnom vremenu. Autentifikacija korisnika se obavlja (kao i danas) putem Nacionalnog identifikacijskog i autorizacijskog sustava (NIAS) Republike Hrvatske.

3. Sustav Pametnih Ugovora (eng. Smart Contract Engine):

   Sustav pametnih ugovora definira redoslijed transakcija, a pametni ugovori se potvrđuju u blockchainu (spomenuta platforma Hyperledger Fabric podržava i pametne ugovore). Pametni ugovori bi automatski izvršavali transakcije nakon ispunjenja unaprijed definiranih uvjeta, poput provjere uplate ili prijenosa vlasništva, čime se smanjuje potreba za ručnim intervencijama.

4. Vanjska pohrana:

   Veliki dokumenti, poput kupoprodajnih ugovora bi se pohranili izvan blockchaina, dok će samo ključni podaci i hashovi tih dokumenata biti pohranjeni unutar blockchaina.

5. Zajednički informacijski sustav za zemljišne knjige i katastar (elektronička evidencija podataka o nekretninama i pripadajućim pravima):

   Kroz nadogradnju Zajedničkog informacijskog sustava za zemljišnu knjigu i katastar (ZIS) omogućio bi se brzi pristup i ažuriranje podataka putem standardiziranih API-ja, integrirajući postojeće sustave/podatke s blockchainom.

6. Sustav za ovjeru pametnog Ugovora:

   Svaki sudionik, bilo da je kupac, prodavatelj, javni bilježnik, morat će se registrirati i verificirati putem NIAS-a kako bi imao pristup sustavu. Elektronički potpis će osigurati da samo ovlaštene osobe mogu unositi ili mijenjati podatke. OSS već koristi digitalni potpis (ePotpis/mPotpis) koji osigurava SDURD za sva tijela državne uprave u RH.

7. Sustav za elektroničko plaćanje:

   Automatska uplata kupoprodajne cijene biti će moguća putem usluge povjerenja (eng. trust service). Sustav bi omogućio automatsku uplatu nakon ispunjenja uvjeta transakcije, čime se dodatno ubrzava proces i smanjuje rizik od grešaka ili prijevara.

Implementacija ovakvog rješenja u Republici Hrvatskoj zahtijeva temeljitu analizu postojećih sustava, razvoj pravnog i regulatornog okvira te blisku suradnju između javnog i privatnog sektora. Unatoč izazovima, prednosti su brojne, uključujući veću transparentnost, smanjenje administrativnih troškova i brže transakcije nekretninama. Pokretanje pilot projekata u odabranim područjima omogućit će testiranje učinkovitosti i otkrivanje potencijalnih prepreka prije široke implementacije.

8. Budući pogledi

Predviđa se da će do 2030. godine usvajanje blockchaina i pametnih ugovora u nekretninama postati sve raširenije. Potencijal ovih tehnologija za revolucioniranje transakcija nekretninama i evidencije zemljišta je značajan, obećavajući poboljšanu transparentnost, smanjenje troškova i ubrzanje procesa (URL 2).

9. Zaključak

Implementacija blockchain tehnologije i pametnih ugovora u zemljišnoj knjizi i katastru predstavlja značajan korak prema digitalnoj transformaciji upravljanja nekretninama. Primjeri iz Švedske, Gruzije i Ujedinjenog Kraljevstva pokazuju da blockchain može značajno poboljšati učinkovitost, sigurnost i transparentnost transakcija nekretninama. Uvođenje ovih tehnologija omogućilo je smanjenje vremena potrebnog za obavljanje transakcija, smanjenje administrativnih troškova i povećanje povjerenja korisnika u sustave zemljišnih knjiga.

Hrvatska ima veliki potencijal za usvajanje ovih tehnologija, no potrebno je provesti temeljitu analizu postojećih sustava, razviti odgovarajuće pravne i regulatorne okvire te osigurati suradnju između javnog i privatnog sektora.

U konačnici, primjena blockchaina i pametnih ugovora može donijeti brojne koristi, uključujući brže i sigurnije transakcije, smanjenje rizika od prijevara i grešaka te veću transparentnost i povjerenje u sustav zemljišnih knjiga. S obzirom na predviđeni rast i razvoj ovih tehnologija, Hrvatska bi trebala aktivno raditi na njihovoj implementaciji kako bi osigurala modernizaciju i unapređenje svojih sustava upravljanja nekretninama.

Literatura

Beck, R., Avital, M., Rossi, M. i dr. (2017): Blockchain Technology in Business and Information Systems Research. Bus Inf Syst Eng 59, 381–384.

Campbell-Verduyn, M. (2018): Bitcoin and Beyond: Cryptocurrencies, Blockchains, and Global Governance. International Journal of Technology and Globalisation, 8(4), 213-230.

Gillpatrick, T., Boğa, S., Aldanmaz, O. (2022): How Can Blockchain Contribute to Developing Country Economies? A Literature Review on Application Areas. ECONOMICS. 10. 105-128.

Piazza, C., Sforza, G. (2017): Blockchain Technology in Real Estate Transactions: Legal, Regulatory, and Risk Management Issues. Journal of Real Estate Management, 12(3), 45-68.

Proskurovska, A., Dörry, S. (2022): The blockchain challenge for Sweden's housing and mortgage markets. Environment and Planning A: Economy and Space, 54(8), 1569-1585.

Swan, M. (2015): Blockchain: Blueprint for a New Economy. O'Reilly Media, Inc., Sebastopol.

Szabo, N. (1997): The Idea of Smart Contracts,

Wüst, K., Gervais, A. (2018): "Do you Need a Blockchain?," Crypto Valley Conference on Blockchain Technology (CVCBT), Zug, Switzerland, 2018, 45-54.

Zavolokina, L., Schlegel, M., Schwabe, G. (2020): How can we reduce barriers to blockchain adoption? Role of ecosystem design and organizational interventions, Information Systems and e-Business Management, 19(3), 883-908.

Zwitter, A., & Boisse-Despiaux, M. (2018): Blockchain for Humanitarian Action and Development Aid. Journal of International Humanitarian Action, 3(1), 15-32.

URL 1: Bold Group, https://www.legalfutures.co.uk/latest-news/land-registry-successfully-transfers-house-using-blockchain, (20.06.2024.).

URL 2: SNS Insider, https://www.snsinsider.com/reports/smart-contracts-market-1542 (20.06.2024.).

Application of Blockchain and Smart Contracts in Land Registry and Cadastre

Abstract

The application of blockchain and smart contracts in land registry and cadastre represents an innovative approach to digitizing the processes of property recording and management. Through the analysis of practical examples and theoretical approaches, this paper explores how blockchain can ensure data integrity and immutability, eliminate the need for intermediaries, and reduce the possibility of fraud. Countries such as Sweden, Georgia, and the United Kingdom have already initiated blockchain technology in their land registries, resulting in improved transparency, accelerated processes, and cost reductions. Smart contracts further facilitate processes by automatically executing transactions upon the fulfilment of certain conditions, speeding up and simplifying the entire property transaction process. In practice, this means that real estate transactions, such as purchases and sales, can be conducted without the need for third-party intermediaries such as notaries or lawyers. Despite the potential benefits, there are challenges in implementing these technologies, including legal and regulatory obstacles, security issues, and the need for integration with existing systems. It is predicted that by 2030, the implementation of these technologies will become increasingly widespread, resulting in further improvements in property recording processes and reductions in administrative costs. The application of blockchain and smart contracts represents a crucial step towards the digital transformation of land registries and cadastres, providing the possibility of creating a more efficient, transparent, and accessible property management system.

Keywords: *blockchain, smart contracts, real estate, land registries, cadastre*

SPONZORI

generalni

Geomatika SMOLČAK d.o.o.

zlatni

GeoWILD

GEO CENTAR

GEOSUSTAVI GEODETSKI INSTRUMENTI I PRIBOR

Ericsson Nikola Tesla

RIEGL

TEHNOMEHANIK d.o.o.

srebrni

KOMTEH 30+ godina

GEODETSKI ZAVOD d.d. SPLIT
ZAVOD ZA PROJEKTIRANJE I IZVOĐENJE GEODETSKIH POSLOVA
21000 SPLIT, R. Boškovića 20, tel: 021/ 470-899, 470-911, fax: 470-937, e-mail: zavod@geozavod-st.hr www.geozavod-st.hr

ZWCAD
GEOPLUS GEOSOFT

GEODETSKI ZAVOD RIJEKA

geoprojekt
Dioničko društvo za geodetske poslove, građevinsko projektiranje i nadzor
Sukoišanska 43, 21000 Split, Hrvatska

PREHNIT

ArcGeo

GeoMIR.software
G6+CAD AUTODESK AUTOCAD OEM

GEODATA

brončani

Geo Grupa d.o.o.
Zagreb

ACES

GENERALI

GEOPROJEKT

ISBN: 978-953-49258-7-4
9 789534 925874