



**Slovensko združenje za geodezijo in geofiziko**

**<http://www.fgg.uni-lj.si/sugg/>**

**RAZISKAVE S PODROČJA  
GEODEZIJE IN GEOFIZIKE  
2023**

**zbornik del**

29. srečanje Slovenskega združenja za geodezijo in geofiziko

Ljubljana, 1. februar 2024

## **UREDNIŠKI ODBOR**

Miran Kuhar, Matjaž Ličer, Ina Cecić, Mojca Šraj, Gregor Skok, Klemen Medved,  
Mihaela Triglav Čekada, Rudi Čop, Nina Zupančič, Polona Vreča

## **RECENZIJA**

Jernej Jež  
Martin Knez  
Stanka Šebela  
Žiga Zaplotnik  
Gregor Skok  
Urša Vilhar  
Polona Vreča  
Miran Kuhar  
Bojan Stopar  
Klemen Kregar  
Klemen Medved

## **ORGANIZATOR SREČANJA IN ZALOŽNIK**

Slovensko združenje za geodezijo in geofiziko

Jamova 2, Ljubljana

## **Elektronska izdaja**

E dostop:

[http://fgg-web.fgg.uni-lj.si/sugg/referati/2024/SZGG\\_Zbornik\\_2024\\_e-publikacija.pdf](http://fgg-web.fgg.uni-lj.si/sugg/referati/2024/SZGG_Zbornik_2024_e-publikacija.pdf)

Kataložni zapis o publikaciji (CIP) pripravili v Narodni in univerzitetni knjižnici v Ljubljani

[COBISS.SI -ID=181966083](https://nbn-resolving.org/urn:nbn:si:coibis-181966083)

ISBN 978-961-95299-5-9 (PDF)

## Vsebina

Predgovor .....	5
Prvi del: recenzirani prispevki	
Andrej Gosar - Skalni podor na Rzeniku 26. februarja 2021 in njegova seizmološka zaznava z državno mrežo potresnih opazovalnic .....	7
Klemen Medved, Oleg Odalović, Božo Koler - Modeliranje vertikalnega gradienta težnosti za obdelavo gravimetričnih meritev .....	19
Uroš Perkan - Napovedovanje vremena s konvolucijskimi nevronskimi mrežami.....	35
Boštjan Melinc, Žiga Zaplotnik - Emulacija variacijske asimilacije meritev pri napovedovanju vremena z variacijskim avtokodirnikom.....	53
Stanka Šebela, Barbara Luke - Poplave v JZ delu ZDA v avgustu in septembru 2023 (Floods in the SW USA in August and September 2023) .....	69
Uroš Novak, Roger Bilham - Vgradnja creepmetrov na zahodne Dinarske prelome .....	77
Katarina Zabret, Lana Radulović, Mark Bryan Alivio, Nejc Bezak, Mojca Šraj - Analiza vplivnih dejavnikov na kinetično energijo dežnih kapljic.....	83
Rudi Čop, Jure Atanackov - Geomagnetna nevihta in polarni sij v Sloveniji.....	95
Mihaela Triglav Čekada, Peter Lamovec - Snežišča okoli Prisojnika iz spletnih kamer..	103
Tilen Urbančič, Jure Česnik - Analiza odstopanj izkopa in primarnih površin predora iz fotogrametričnih oblakov točk.....	113
B. Koler, T. Ambrožič, K. Kregar, D. Kogoj, A. Marjeič, S. Savšek, G. Štebe, J. Tekavec, T. Urbančič - Transformacija višin med starim in novim višinskom sistemom Slovenije	123
Marija Zlata Božnar, Primož Mlakar, Boštjan Grašič - Več kot 30 let uporabe umetne inteligence na področju meteorologije v Sloveniji .....	139
Drugi del: razširjeni povzetki	
Danijela Kuzmanović, Jana Banko, Gregor Skok - Verifikacija operativnih napovedi univerzalnega toplotnega klimatskega indeksa v Sloveniji .....	149
Matevž Osolnik, Gregor Skok, Matic Šavli - Detekcija intenzivnih neviht na območju Slovenije .....	151
Sašo Petan, Gregor Vertačnik, Miha Šupek, Neža Lokošek, Maja Koprivšek, Anže Medved, Mojca Sušnik, Matevž Piry, Florjana Ulaga - Nalivi, obilne padavine in izjemne poplave v Sloveniji med 3. in 8. avgustom 2023 .....	153
Peter Mlakar, Janko Merše, Jana Faganelli Pucer - ANet: metoda za poprosiranje vremenskih napovedi s pomočjo strojnega učenja .....	155



## Predgovor

Pred nami je zbornik letošnjega srečanja Slovenskega združenja za geodezijo in geofiziko, ki deluje na področju geoznanosti, katerih vloga pri razumevanju našega planeta skozi desetletja raste tudi zaradi antropogenih podnebnih sprememb, ki smo jim priča. Zdi se, da so in še bodo ti izzivi vedno večji katalizator pospeševanja sodelovanja med različnimi vidiki planetarnih znanosti, katerih smoter v teh časih ni le poglobljanje razumevanja planetarne dinamike, temveč tudi ustvarjanje ustreznih podlag za politične odločitve, brez katerih se ni mogoče spopasti z nobenim kompleksnim družbenim problemom. Kot kažejo prispevki letošnjega srečanja, sodelujoči delujejo na številnih področjih, ki so znanstveno zanimiva in družbeno relevantna. Znanstveniki, še posebej tisti, ki se ukvarjamo z našim planetom, pa smo vedno bolj soočeni z izzivom, kako ohraniti vsaj minimalen strokovni vpliv v javnih debatah, ki se tičejo področij, na katerih delujemo, in ki so vedno bolj polne šuma v obliki lažnih in zavajajočih trditev. Ključno je razumeti, da pri teh izzivih ne gre le za problem znanstvene komunikacije, temveč tudi za preprosto dejstvo, da naših življenj ne kroji le znanost, temveč tudi ekonomija, politika, kultura in še kaj.

V preteklem letu so širšim javnostim prek velikih jezikovnih modelov postale dostopne tehnologije generativne in druge umetne inteligence. Povsem očitno je, da te tehnologije ne bodo spremenile le številnih vidikov naših življenj, temveč tudi način, kako deluje znanost. Del znanstvene skupnosti na umetno inteligenco gleda s skepsa, ker vsaj zaenkrat rezultati te metodologije niso jasno interpretabilni. Sam verjamem, da se bo to sčasoma vsaj do neke mere spremenilo in da bo interpretabilnost vsaj na nekaterih področjih rasla. Po drugi strani pa lahko umetna inteligenca za geoznanosti predstavlja dobrodošel komplement metodam klasične moderne znanosti. Osrednji izziv geoznanosti pogosto izhaja iz dejstva, da se ukvarjamo s procesi, ki jih je zapleteno opisovati, ker se odvijajo na številnih časovnih in prostorskih skalah. Ni povsem očitno, da so vsi ti problemi sploh rešljivi na način, kot smo se jih lotevali v zadnjih 300 letih. Problem turbulence kljub enormnim naporom in vložkom denimo ni zadovoljivo rešen. Morda bo umetna inteligenca v geoznanosti vnesla nove metode reševanja visokodimenzionalnih problemov, ki sicer ne bodo nujno večale našega razumevanja na način, kot smo bili navajeni doslej, bodo pa sposobne te probleme vseeno rešiti.

Vsem skupaj želim, da se tudi prek takih srečanj, kot je ta, ki ga povzema pričujoči zbornik, uspešno soočimo z novimi znanstvenimi pristopi, ki imajo potencial nove znanstvene revolucije.

predsednik SZGG

dr. Matjaž Ličer



# Skalni podor na Rzeniku 26. februarja 2021 in njegova seizmološka zaznava z državno mrežo potresnih opazovalnic

Andrej Gosar\*

## Povzetek

26. februarja 2021 se je ob 6. uri in 16 minut na Rzeniku (1833 m) nad dolino Kamniške Bele zgodil večji skalni podor. V članku obravnavam seizmološko zaznavanje tega podora, ki ga ni povzročil tektonski potres, pa tudi nekatere njegove morfometrične značilnosti. Primerjava zračnih posnetkov pred podorom in po njem je omogočila kvantitativno opredelitev razsežnosti podora. Odlom na zahodnem stebru, ki omejuje njegovo severno steno, je bil visok 200 metrov in širok okoli 100 metrov. Odlomljen skalni material, katerega prostornino ocenjujem na 625.000 m<sup>3</sup>, je nasul strmo gozdno pobočje površine okoli 13 hektarjev. Podor je povzročil tako močno tresenje tal, da ga je zaznala večina seizmografov državne mreže potresnih opazovalnic in dva v sosednji Avstriji na oddaljenosti od 15 do 126 kilometrov od Rzenika. Primerjava seizmoloških zapisov tega skalnega podora, zmernega tektonskega potresa magnitude 1,8 in večjega razstreljevanja v bližnjem kamnolomu je razkrila vso pestrost različnih seizmičnih valovanj in njihovega nastanka. Severna stena Rzenika, ki je visoka okoli 400 metrov in zgrajena iz triasnih apnencev, je znana kot ena najbolj krušljivih sten v naših gorah. Geomorfološka analiza podrobnega digitalnega modela višin je pokazala, da so se tukaj tudi v geološki preteklosti dogajali veliki skalni podori.

**Ključne besede:** skalni podor, potres, seizmologija, seizmograf, Rzenik, Slovenija

**Keywords:** rockfall, earthquake, seismology, seismograph, Rzenik, Slovenia

## Uvod

Velika večina potresov je tektonskih in nastanejo zaradi nenadnega premika kamnin ob prelomu, ko nakopičene napetosti v Zemljini skorji presežejo strižno trdnost. Potresi, ki niso tektonski, pa lahko nastanejo zaradi vulkanske dejavnosti ali skalnih podorov. Vse vrste potresov zaznavamo in opazujemo s potresnimi opazovalnicami, njihovi zapisi (seizmogrami) pa se glede na način nastanka tresenja lahko precej razlikujejo. Hiter razvoj seizmologije se ne odraža samo v vedno bolj občutljivih seizmometrih z zelo širokim frekvenčnim in dinamičnim območjem, temveč predvsem v tem, da se število seizmografov hitro povečuje, kar omogoča vse natančnejši monitoring potresne dejavnosti. V Sloveniji smo na Uradu za seizmologijo ARSO konec leta 2022 upravljali že 48 merilnih mest, 26 jih predstavlja Državno mrežo potresnih opazovalnic (Vidrih et al., 2006), druge pa so akceleroграфи in različne postavitve seizmografov za namenska opazovanja in raziskave. S povečevanjem števila merilnih mest se je povečala tudi zmožnost zaznavanja netektonskih virov tresenja tal, kot so: razstreljevanja v kamnolomih in pri večjih gradnjah, hribinski udari zaradi rudarjenja (Bajc et al., 2004), preboj zvočnega zidu vojaških letal (Pahor in Zupančič, 2018), večji skalni podori in meteoridi, ki so kot bolidi razpadli v ozračju (ARSO, 2020), ali celo zelo redki meteoriti, ki so padli na Zemljina tla (Spurny et al., 2010). V članku na primeru skalnega podora na Rzeniku, ki se je zgodil 26. februarja 2021 (slika 1), obravnavam

njegovo seizmološko zaznavanje, torej primer, ko je bilo tresenje tal posledica podora. Pred tem bom na kratko opisal tudi skalne podore, ki so v goratih predelih pogosta posledica močnih potresov. V gorskem svetu Slovenije in bližnje okolice je bilo v preteklosti več zelo velikih skalnih podorov. Največji se je zgodil ob potresu leta 1348 na Dobraču na avstrijskem Koroškem, ko je v dolino Zilje zgrmel velik del južnega ostenja in jo tudi zajezil (Zorn, 2002).



Slika 1 – Rzenik (1833 m) s skalnim podorom, ki se je zgodil 26. februarja 2021 (foto: A. Gosar).

### **Potresi in skalni podori**

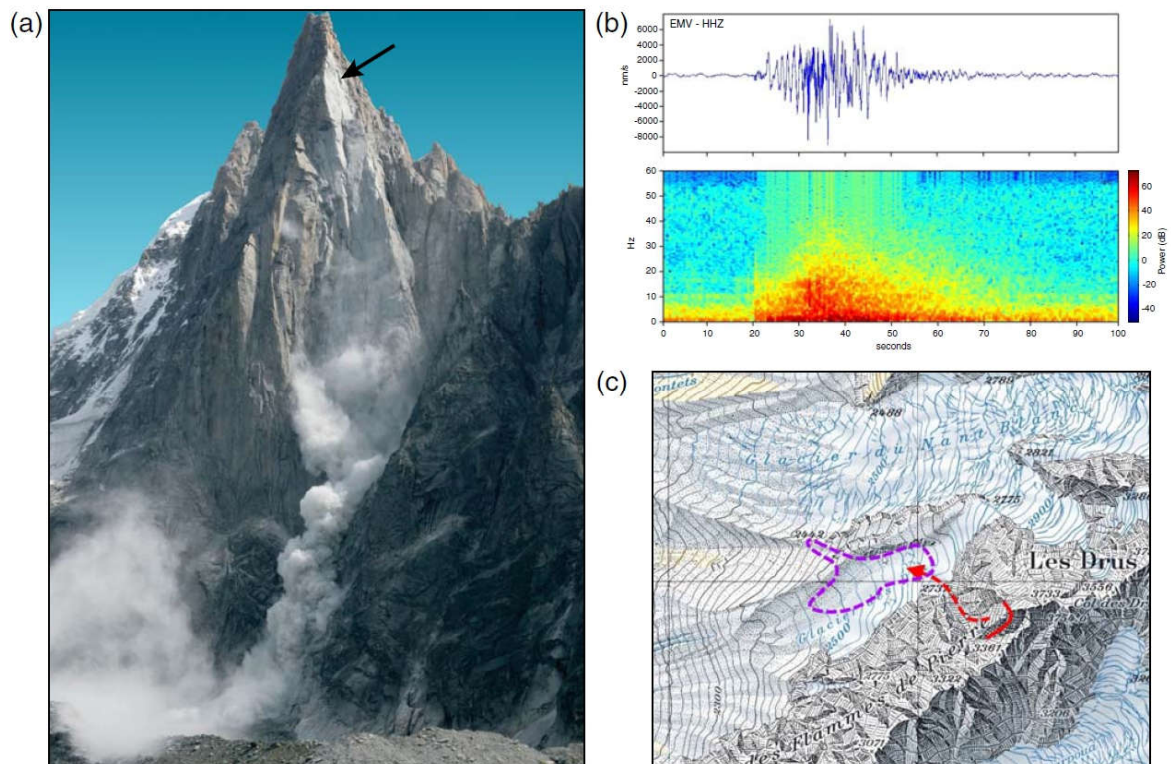
Močni potresi imajo poleg učinkov na ljudi, predmete in stavbe, ki se uporabljajo pri določitvi intenzitete potresa v posameznem naselju, lahko tudi velike učinke na naravno okolje, med katerimi prevladujejo zemeljski plazovi in skalni podori. Makroseizmične intenzitetne lestvice so učinke potresov na naravno okolje dolgo časa le obrobno obravnavale, saj se je zdelo, da jih je težko uporabiti za določitev intenzitete (Vidrih in Ribičič, 1998). To se je spremenilo z uvedbo posebne lestvice učinkov na naravno okolje (Environmental Seismic Intensity scale) ESI 2007 (Guerrieri in Vittori, 2007), ki se uporablja skupaj s klasičnimi 12-stopenskimi lestvicami, predvsem Evropsko potresno lestvico (EMS-98). Poseben pomen ima uporaba ESI 2007 na odmaknjenih redko poseljenih goratih območjih, kjer so za močne potrese učinki na naravno okolje prevladujoči. Čeprav potres 12. aprila 1998 v Posočju z navorno magnitudo 5,6 in največjo intenziteto VII–VIII EMS-98 spada po večini meril med zmerne potrese, je zaradi specifične geološke zgradbe povzročil zelo številne skalne podore v Krnskem pogorju (Ribičič in Vidrih, 1999). Ker je



ožje nadžariščno območje zaradi visokogorja zelo redko poseljeno, kar je omejevalo vrednotenje učinkov na ljudi, predmete in stavbe za določitev intenzitete, se je izkazalo, da je koristno vzporedno uporabiti tudi analizo porazdelitve skalnih podorov za oceno intenzitete (Gosar 2012).

### Primeri seizmičnih opazovanj skalnih podorov

Na gori Aiguille Dru nad Chamonixom (Francija) je konec junija 2005 nastalo več skalnih podorov (Dammeier et al., 2015), ki so odnesli tudi del plezalnih smeri, med njimi znamenit Bonattijev steber (slika 2). 30. junija sta v razmiku dveh minut nastala največja podora, ki sta bila zabeležena na osmih potresnih opazovalnicah v bližnji Švici. Skupna prostornina vseh skalnih podorov na Aiguille Dru v tem poletju je ocenjena na 265.000 m<sup>3</sup> in na podlagi značilnosti seizmičnega zapisa (sliki 2b in c) največjega od njih na 150.000 m<sup>3</sup>. Največja amplituda nihanja tal je namreč tesno povezana s sproščeno energijo. Izrazit je dolgoperiodni signal v območju 20–50 sekund. Celotna višina padanja skalovja je bila 800 metrov, v vznožju stene pa je odložen grušč segal 420 metrov daleč.

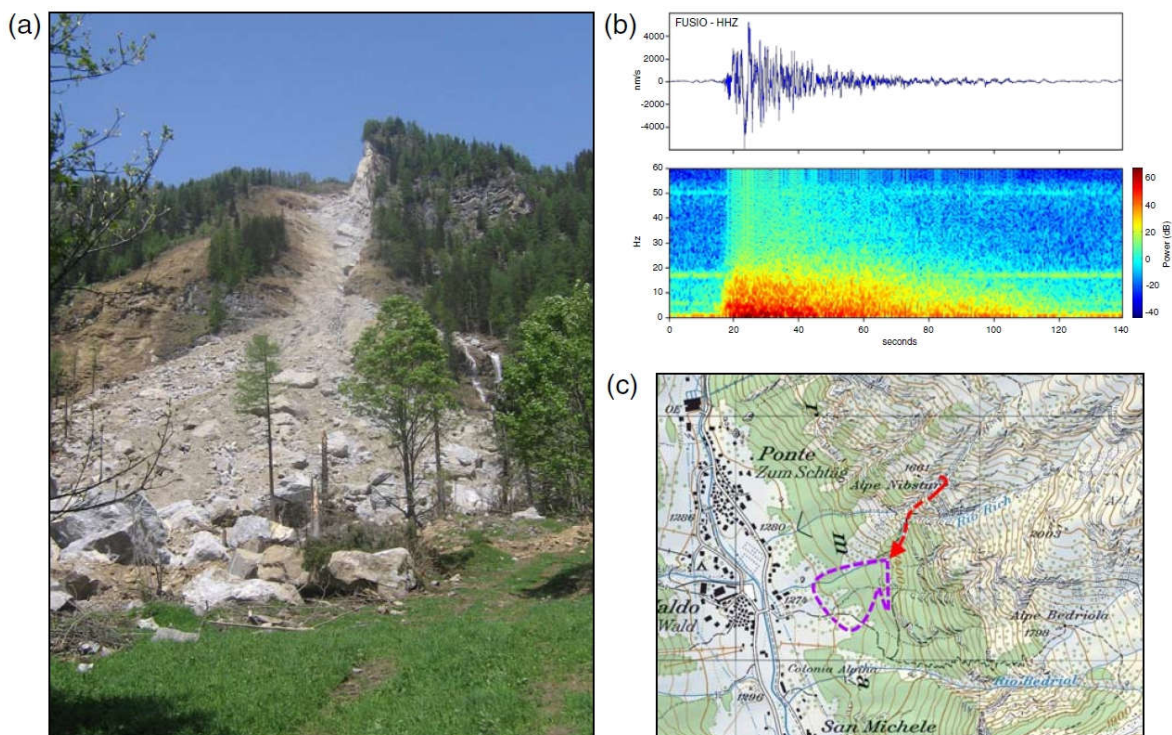


Slika 2 – Podor na gori Aiguille Dru (F) leta 2005 (Dammeier et al., 2015).

- a) Fotografija poznejšega manjšega podora, s puščico je označen odlom.
- b) Seizmogram in njegov spektrogram na najbližji potresni opazovalnici, EMV (15,1 km)
- c) Zemljevid območja z označenim odlomom in območjem nasutja

V dolini Formazza (Italija), ki se od juga globoko zajeda v Švico, se je 19. aprila 2009 v treh zaporednih odlomih zgodil podor (slika 3) z ocenjeno skupno prostornino 700.000 m<sup>3</sup> (Dammeier et al., 2015). Vsi trije so se zelo jasno videli na zapisih osmih potresnih opazovalnic, tudi z izrazitim dolgoperiodnim signalom na območju 8–25 sekund (slika 3b). Prostornina prvega od treh podorov je bila ocenjena na 170.000 m<sup>3</sup>, celotna višina padanja skalovja pa je bila 530 metrov na vodoravni razdalji 600 metrov. Odlom je nastal na grebenu,

ki poteka vzporedno s strmo vpadajočimi prelomi. Ob enem izmed njih je nastal tudi začetni odlom.




Slika 3 – Podor v dolini Formazza (I) leta 2009 (Dammeier et al., 2015).  
 a) Posnetek podora, b) Seizmogram in njegov spektrogram na najbližji potresni opazovalnici, FUSIO (19,3 km), c) Zemljevid območja z označenim odlomom in območjem nasutja

Seizmološke podatke desetih drugih velikih skalnih podorov v francoskih Alpah so analizirali Deparis et al. (2008). Ugotovili so, da trajanje nihanja tal na izbrani razdalji (30 km) od podora bolje korelira s sproščeno potencialno energijo kot pa največja amplituda, izmerjena na seizmogramih. Seizmični zapisi kažejo na delno možnost razlikovanja seizmičnega vira, in sicer se včasih lahko loči sam odlom od udarca podora ob pobočje v vznožju skalne stene.

### Skalni podor na Rzeniku 26. februarja 2021

Rzenik je 1833 metrov visoka gora v Kamniško-Savinjskih Alpah v grebenu, ki poteka od Ojstrice proti Veliki planini. Njegova severna stena je skoraj v celoti zgrajena iz triasnega masivnega apnenca cordevolske starosti (Premru, 1982). 400 m visoka severna stena Rzenika je znana kot ena najbolj krušljivih v slovenskih Alpah, kar močno povečuje težavnost in tveganost alpinističnih vzponov.



Slika 4 – Digitalni ortofoto (DOF, vir GURS) območja Rzenika, posnet:  
a) pred podorom leta 2019, b) po podoru leta 2021.

26. februarja 2021 se je ob 6. uri in 16 minut zjutraj zgodil v steni Rzenika velik skalni podor (sliki 1 in 4). Že istega dne so poročali, da je podor zasul planinsko pot na Presedljaj in da so prašenje, ki so ga povzročile padajoče skale, zaznali tudi na vhodu v dolino Kamniške Bele (Občina Kamnik, 2021). Naslednjega dne je območje preletel športni pilot in posnel nazorne fotografije (PD Domžale, 2021). Konec februarja 2021 je bilo v tem delu Slovenije v gorah razmeroma malo snega za ta čas, doline pod 1400 metri pa so bile večinoma kopne. Tudi vreme je bilo že dlje časa sončno in brez padavin.

Z analizo razpoložljivih podatkov daljinskega zaznavanja sem ocenil razsežnost skalnega podora. Pri tem je bila najbolj koristna primerjava posnetkov cikličnega aerosnemanja, saj sta za območje Rzenika na voljo posnetka iz let 2019 in 2021, torej pred podorom in po njem (slika 4) in tudi fotografija stene posneta z vrha Kamniškega dedca (slika 1). Podor se je zgodil v stebru na desni (zahodni) strani severne stene med n.m.v. 1230 in 1430 metri. Odlomljen del stene je visok okoli 200 metrov in širok okoli 100 metrov. Podor je nasul strmo ( $30^{\circ}$ – $35^{\circ}$ ), pred tem večinoma poraslo, pobočje, med n.m.v. 750 in 1230 metri v dolžini okoli 600 metrov in širini okoli 340 metrov. Pri tem je dosegel strugo Kamniške Bele. Površina nasutega skalovja, izmerjena na digitalnem ortofoto posnetku, znaša  $0,125 \text{ km}^2$ . Če grobo ocenim ali predpostavim, da je debelina nasutja povprečno 5 metrov, je njegova prostornina  $625.000 \text{ m}^3$ . To je podobno kot pri podoru na Formazzi v Italiji (slika 3) in bistveno manj kot pri dveh največjih podorih, ki sta nastala v Krnskem pogorju ob potresu leta 1998. Na podlagi primerjav digitalnih modelov višin sta bili prostornini teh podorov ocenjeni za Veliki Lemež na  $15 \times 10^6 \text{ m}^3$  in za Osojnico na  $3 \times 10^6 \text{ m}^3$  (Gosar, 2012).

### **Seizmološka registracija skalnega podora na Rzeniku in primerjava z drugimi seizmičnimi dogodki**


Velik skalni podor na Rzeniku smo zaznali na večini izmed 26 seizmografov Državne mreže potresnih opazovalnic (slika 5), kar kaže na zelo veliko energijo, ki se je ob zrušenju spremenila v potresno valovanje. Na sliki 6 je 13 seizmogramov navpične komponente (Z) seizmografov, ki sicer merijo nihanje tal v treh pravokotnih smereh, razvrščeni so od

najbližje do najbolj oddaljene potresne opazovalnice od lokacije podora. Amplitude so normalizirane za vsako opazovalnico posebej, zato je treba upoštevati njihovo različno merilo. Najbližje (14,6 km) je opazovalnica na Možjanci (MOZS), najbolj oddaljeni pa so Bojanci (BOJS) v Beli krajini (103,6 km) in Kog (KOGS) v Slovenskih Goricah (125,6 km). Iz seizmograma je razvidno, da se trajanje nihanja tal z oddaljenostjo povečuje, in sicer zaradi razlike v času potovanja hitrejših longitudinalnih potresnih valov in počasnejših transverzalnih ter površinskih potresnih valov. Prav tako se z oddaljenostjo opazovalnice od podora zmanjšujeta največja amplituda nihanja in razmerje med signalom in šumom. Šum se vidi predvsem v času pred prvim prihodom potresnega valovanja, na primer na seizmogramih opazovalnic ROBS, CRES in KOGS. Čeprav je zaradi bližine mesta z veliko prometa in industrije opazovalnica LJU na Golovcu v Ljubljani med bolj zašumljenimi, je zaradi bližine podora (32,5 km) signal zelo jasno viden. Po glavnem podoru ob 05.16 UTC (06.16 po lokalnem času), se je ob 05.55 UTC zgodil še manjši podor, ki so ga zaznale samo nekatere bližnje opazovalnice.




Slika 5 – Potresne opazovalnice slovenske državne mreže potresnih opazovalnic in lokacija podora na Rzeniku. Na seizmogramih (slike 6–8) so prikazani zapisi samo tistih opazovalnic, katerih oddaljenost od Rzenika (v kilometrih) je prikazana na tej karti.


Seizmološki zapis skalnega podora se navadno bistveno razlikuje od zapisa tektonskega potresa ali večjega razstreljevanja v kamnolomu, zato ju je zanimivo primerjati. Območje Kamniških in Savinjskih Alp potresno sicer ni med dejavnejšimi v Sloveniji, se pa tudi tu občasno dogajajo potresi. Za primerjavo sem vzel potres magnitude 1,8, ki se je zgodil 19. 9. 2013, in sicer 3 kilometre jugozahodno od Rzenika v globini 17 kilometrov (slika 7), in večje razstreljevanje 18. 1. 2019 v kamnolomu podjetja Calcit v Stahovici, ki je 5 kilometrov južno od Rzenika (slika 8).



Slika 6 – Seizmogrami podora na Rzeniku 26. 2. 2021, zabeleženi na 13 izbranih potresnih opazovalnicah, označenih z njihovo kodo na sliki 5. Na desni je zapisana oddaljenost opazovalnice od mesta podora.




Slika 7 – Seizmogrami potresa magnitude 1,8 dne 13. 9. 2019, ki se je zgodil 3 kilometre jugozahodno od Rzenika v globini 12 kilometrov, zabeleženi na istih 13 potresnih opazovalnicah kot na sliki 6.



Slika 8 – Seizmogrami večjega razstreljevanja v kamnolomu Stahovica, ki je 5,2 kilometra južno od Rzenika, zabeleženi na istih 13 potresnih opazovalnicah kot na sliki 6.

Seizmogrami skalnih podorov, potresov in večjih razstreljevanj v kamnolomih (slike 6–8) se razlikujejo zaradi številnih razlogov:

- Podor in razstreljevanje sta pojava na Zemljinem površju, zaradi česar se izraziteje razvijejo površinska potresna valovanja (Rayleighjevo in Lovejevo valovanje), za katere so značilne nižje frekvence, večje amplitude in nižja hitrost potovanja. Tektonski potres pa ima žarišče v globini, ki je v Sloveniji večinoma med 5 in 20 kilometrov, zaradi česar prevladujejo prostorska potresna valovanja (longitudinalno in transverzalno), ki so hitrejša od površinskih in imajo višje frekvence.
- Potres majhnih do zmernih magnitud je zaradi majhnega zdrsa kamninskih blokov ob tektonskem prelomu hipen pojav, zaradi česar je trajanje nihanja tal krajše. Skalni podor je daljšega trajanja, saj se navadno ne odlomi ves del stene naenkrat, temveč postopoma, poleg tega je pod steno navadno nagnjeno pobočje, vzdolž katerega se odlomljeno skalovje nekaj časa kotali. Razstreljevanje bi lahko bilo hipno, če bi celotno količino uporabljenega eksploziva sprožili naenkrat, kar pa ne bi bilo učinkovito za drobljenje kamnine, lahko pa bi bilo tudi nevarno za okolico. Zato se pri večjih razstreljevanjih v kamnolomih uporabljajo zakasnilci in se posamezna polnjenja v zaporednih strelnih vrtinah prožijo s kratkimi zamiki. Tako sta dosežena učinkovitejše drobljenje kamnine in manjši razmet skalovja. Posledično je tudi nihanje tal daljše.



Slika 9 – Seizmogrami navpične komponente, zabeleženi na potresni opazovalnici Možjanca (MOZS) in njihovi spektrogrami (gostota spektra moči) za:  
 a) podor na Rzeniku, b) tektonski potres magnitude 1,8,  
 c) večje razstreljevanje v kamnolomu Stahovica

Navedeno se odraža na seizmogramih na slikah od 6 do 8 in spektrogramih (gostota spektra moči) za seizmogramе, ki so najbližji opazovalnici MOZS na Možjanci (slika 9). Seizmogrami na sliki 9 niso filtrirani in se zato razlikujejo od tistih na slikah od 6 do 8, na katerih je bil za nazornejši prikaz uporabljen pasovnoprepustni filter 1–20 Hz. Pri potresu (sliki 7 in 9b) so razvita praktično le prostorska valovanja, razlika med prihodoma hitrejših longitudinalnih in počasnejših transverzalnih valov pa je le okoli 2 sekundi, saj je opazovalnica oddaljena od nadžarišča le 15 km. Zaradi razmeroma velike globine žarišča je pri tako majhni oddaljenosti na navpični komponenti zapisa amplituda obeh vrst valovanja skoraj enaka, oziroma za longitudinalno celo malo višja. Celotno trajanje nihanja tal je le okoli 10 sekund, saj se površinska valovanja niso razvila. Prevladujejo visoke frekvence, ki segajo do 60 Hz (slika 9). Pri podoru (sliki 6 in 9a) traja nihanje tal okoli 70 sekund z največjimi amplitudami po 10–12 sekundah, pri čemer že prevladujejo površinska valovanja, ki sledijo višjefrekvenčnemu začetnemu delu zapisa s prostorskimi valovanji, vendar brez jasne ločnice med longitudinalnimi in transverzalnimi. Spektrogram pokaže, da je v seizmogramu širok razpon frekvenc med 2 in 30 Hz, in sicer brez izrazitejših vrhov. Pri razstreljevanju (sliki 8 in 9c) sledijo začetnemu visokofrekvenčnemu delu, dolgemu okoli 10 sekund in s frekvenco do 40 Hz, izrazita nizkofrekvenčna valovanja na območju med 15 in 90 sekundami zapisa, ki so veliko bolj razvita kot pri podoru. V njih prevladujejo frekvence do 10 Hz, brez kakšnih izrazitejših vrhov.

Skalni podori so v razmeroma krušljivih slovenskih gorah precej pogosti (Zorn, 2002), vendar navadno ne tako obsežni, kot je bil podor na Rzeniku 26. februarja 2021. Taki so izjemno redki in jih večinoma povzročijo le močni potresi. Čeprav je severna stena Rzenika znana kot ena najbolj krušljivih v Sloveniji, ni znanih zgodovinskih zapisov o podobno velikih podorih, na katere pa lahko sklepamo po obsežnem melišču pod steno, ki pa je večinoma poraščeno. Letalsko lasersko skeniranje površja (LiDAR) nam omogoča videti tudi golo površje brez dreves, saj nekateri žarki skozi krošnje dosežejo tla, kar je pomembno za geomorfološke analize (Gosar, 2007). Digitalni model višin območja Rzenika na podlagi letalskega laserskega skeniranja Slovenije iz leta 2015 jasno pokaže, da so se morali v ne tako oddaljeni geološki preteklosti tu zgoditi podobno veliki ali celo večji skalni podori, saj je nasut material v pahljačasti obliki dosegel dno doline Kamniške Bele.

## **Zaključek**

Z državnim seizmološkim monitoringom ne zaznamo le potresov, temveč tudi nekatere druge umetno povzročene ali naravne pojave, pri katerih se sprosti veliko energije, ta pa se deloma spremeni v seizmična valovanja, ki jih zaznajo seizmografi. Tudi skalni podor na Rzeniku 26. februarja 2021 so najprej zaznale potresne opazovalnice, saj se je zgodil v odmaknjeni dolini, zgodaj zjutraj in pozimi, ko v dolinah Kamniške Bistrice in Kamniške Bele ni bilo očitvidcev. Ti so najprej videli le velik oblak prahu, saj severna stena Rzenika ni neposredno vidna iz nobenega naselja. Podor je bil tako velik, da so ga zaznale potresne opazovalnice po vsej Sloveniji do razdalje 126 kilometrov in tudi dve bližnji v Avstriji. Primerjava seizmoloških zapisov skalnega podora, zmernega tektonskega potresa in večjega razstreljevanja v bližnjem kamnolomu je razkrila pestrost različnih seizmičnih valovanj in njihovega nastanka.



## Literatura

- ARSO, 2020. Državna mreža potresnih opazovalnic je 28. februarja 2020 ob 10.32 zabeležila padec meteorita. [https://twitter.com/ARSO\\_potresi/status/1233350684000620544](https://twitter.com/ARSO_potresi/status/1233350684000620544)
- Bajc, J., Živčič, M., Gostinčar, M., 2004. Seizmična aktivnost v Šaleški dolini spomladi 2002. Potresi v letu 2002, 56–71. Ljubljana: Agencija RS za okolje.
- Dammeier, F., Guilhem, A., Moore, J. R., Haslinger, F., Loew, S., 2015. Moment tensor analysis of rockslide seismic signals. *Bulletin of the Seismological Society of America*, 105, 3001–3014.
- Deparis, J., Jongmans, D., Cotton, F., Baillet, L., Thouvenot, F., Hantz, D., 2008. Analysis of rock-fall and rock-fall avalanche seismograms in the French Alps. *Bulletin of the Seismological Society of America* 98, 1781–1796.
- Gosar, A., 2007. Letalsko lasersko skeniranje (LiDAR) Idrijskega in Ravenskega preloma v zahodni Sloveniji. *Ujma* 21, 139–144.
- Gosar, A., 2012. Application of Environmental Seismic Intensity scale (ESI 2007) to Krn Mountains 1998 Mw = 5.6 earthquake (NW Slovenia) with emphasis on rockfalls. *Nat. hazards earth syst. sci.*, 12/5, 1659–1670.
- Guerrieri, L., Vittori, E., 2007. Intensity Scale ESI 2007. *Memorie Descrittive della Carta Geologica D'Italia*, 74, 41.
- Občina Kamnik 2021. Skalni podor v dolini Bele – na tem območju je priporočljiva skrajna previdnost. <https://www.kamnik.si/objava/644034>.
- Pahor, J., Zupančič, P., 2018: Preboj zvočnega zidu dveh letal na zapisih državne mreže potresnih opazovalnic. *Potresi v Sloveniji 2016*, 78–86. Ljubljana: Agencija RS za okolje.
- PD Domžale 2021. Podor v Rzeniku iz zraka. <https://www.pdd.si/2021/02/28/podor-v-rzeniku-iz-zraka/>.
- Premru, U., 1982. Osnovna geološka karta SFRJ, list Ljubljana, 1 : 100.000. Geološki zavod Ljubljana.
- Spurny, P., Borovička, J., Kac, J., Kalenda, P., Atanackov, J., Kladnik, G., Heinlein, D., Grau, T., 2010. Analysis of instrumental observations of the Jesenice meteorite fall on April 9, 2009. *Meteoritics & planetary science*. 45/8, 1392–1407.
- Vidrih, R., Ribičič, M., 1998. Porušitve naravnega ravnotežja v hribinah ob potresu v Posočju 12. aprila 1998 in Evropska makroseizmična lestvica (EMS-98). *Geologija*, 41, 365–410.
- Vidrih, R., Sinčič, P., Tasič, I., Gosar, A., Godec, M., Živčič, M., 2006. Državna mreža potresnih opazovalnic; Seismic network of Slovenia. *Agencija RS za okolje, Urad za seizmologijo in geologijo*, 287.
- Zorn, M., 2002. Rockfalls in Slovene Alps. *Geografski obzornik*, XLII, 123–160.



# Modeliranje vertikalnega gradienta težnosti za obdelavo gravimetričnih meritev

Klemen Medved<sup>1</sup>, Oleg Odalović<sup>2</sup>, Božo Koler<sup>3</sup>

## Povzetek

Vertikalni gradient težnosti (VGT) določa spremembo težnega pospeška po višini (vzdolž vertikale) in ga dobimo z odvajanjem vektorja težnega pospeška  $g$  oziroma z drugimi odvodi težnostnega potenciala  $W$ . Pri izvajanju gravimetričnih meritev ima poznavanje oz. nepoznavanje vertikalnega gradienta težnostnega polja velik pomen, saj moramo težni pospešek, izmerjen z instrumentom reducirati na stabilizirano točko. Ker so meritve dolgotrajne in drage običajno uporabljamo vrednosti normalnega težnostnega polja, ki pa se zaradi nehomogene strukture Zemlje, razlikuje od dejanskega. Zato je smiselno, da z razpoložljivimi podatki modeliramo vrednosti vertikalnega gradienta težnosti in le-te uporabimo v gravimetričnih izmerah, saj s tem bistveno izboljšamo končne vrednosti težnih pospeškov na posameznih točkah.

**Ključne besede:** težnostno polje Zemlje, gravimetrija, vertikalni gradient težnosti, modeliranje, gravimeter, gravimetrične meritve, digitalni model reliefa

**Key words:** Earth's gravitational field, gravimetry, vertical gravity gradient, modeling, gravimeter, gravimetric measurements, digital terrain model

## Uvod

Gravimetrični podatki se uporabljajo tako v geodeziji (npr. določanje ploskve geoida, določanje geopotencialnih kot) kot v geofiziki in geologiji (interpretacija notranjih struktur Zemlje). Vertikalni gradient predstavlja spremembo pospeška sile teže v prostoru vzdolž vertikale (Hofmann-Wellenhof in Moritz, 2006). Pri izvajanju gravimetričnih meritev ima poznavanje oz. nepoznavanje vertikalnega gradienta težnostnega polja velik pomen, saj moramo težni pospešek, izmerjen z instrumentom reducirati na izmeritveno točko.

V splošnem velja, da z današnjimi gravimetri lahko izmerimo vrednost težnega pospeška z natančnostjo nekaj  $\mu\text{Gal}$  (Scintrex, 2017, LaCoste & Romberg, 2004), pri tem pa se te meritve nanašajo na merski senzor instrumenta. V praksi se meritve reducirajo na neko trajno ali začasno stabilizirano točko (npr. reper), ki po višini lahko odstopa (od senzorja instrumenta) od nekaj mm pa do več kot en meter. Ta popravek imenujemo »popravek višine gravimetra« (Torge, 1989) in pri redukciji uporabimo vrednost vertikalnega gradienta težnosti nad točko. Vertikalni gradient težnosti na površju Zemlje žal ni konstanten, zaradi nehomogene geološke strukture Zemlje se razlikuje od točke do točke. Dejansko vrednost vertikalnega gradienta težnosti lahko določimo z gravimetričnimi meritvami na različnih višinah nad posamezno točko (Dykowski, 2012, Repanič in sod., 2015), vendar pa so te meritve dolgotrajne in drage in jih ne moremo izvesti na vseh gravimetričnih točkah neke države, npr. v Sloveniji jih imamo več kot 3000. V praksi se zato pri izračunih uporablja vrednost normalnega vertikalnega gradienta, ki se nanaša na nivojski elipsoid in je matematično definiran. Nepoznavanje dejanskih vrednosti vertikalnih gradientov težnosti torej povzroča relativno velike napake pri obdelavi gravimetričnih meritev in posledično

<sup>1</sup> Geodetska uprava RS, Zemljemerska 12, 1000 Ljubljana

<sup>2</sup> Univerzitet u Beogradu, Građevinski fakultet, Bulevar Kralja Aleksandra 73, 11000 Belgrade, Srbija

<sup>3</sup> Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Jamova 2, 1000 Ljubljana

končnih vrednostih težnega pospeška na površju Zemlje. Te napake so tudi nekajkrat večje od natančnosti meritev, ki jo omogočajo sodobni relativni gravimetri, npr. Scintrex CG-5, s katerim lahko dosežemo natančnost  $0,010 \times 10^{-5} \text{ m/s}^2$  (Crossley in sod., 2013).


Osnovna ideja raziskave je, da model vertikalnih gradientov težnosti lahko izračunamo na osnovi odvodov težnostnega potenciala. Le-te je možno pridobiti z izračunanim topografskim popravkom ob predpostavki, da uporabimo kvaliteten digitalni model reliefa in potencialno tudi digitalni model gostot topografskih mas (Zahorec in sod., 2017). Za točko na površju Zemlje lahko izračunamo topografski popravek na dveh višinah. Razlika med njima predstavlja vpliv topografskega popravka na normalni vertikalni gradient. Po teoriji se topografski popravek na posamezni točki računa do standardne zunanje razdalje 166,7 km (Torge, 1989), največji vpliv pa imajo okoliške mase do razdalje nekaj 100 m (Hinze in sod., 2005). Iz teh podatkov lahko modeliramo vrednosti vertikalnih gradientov težnosti.

### **Meritve vertikalnega gradienta težnosti**

Z relativnimi gravimetri ne moremo neposredno izmeriti vertikalnega gradienta, lahko pa ga določimo na osnovi relativnih merenj na različnih višinah nad isto točko. Postopek je vesplošno znan in se uporablja predvsem pri reduciranju absolutnih gravimetričnih meritev na nivo stabilizirane točke. Do sedaj so bile v Sloveniji gravimetrične meritve za potrebe določitve vertikalnega gradienta izvedene samo na šestih absolutnih gravimetričnih točkah, ki so vključene v slovensko gravimetrično mrežo 0. reda. To so točke: AGT100 (Bogenšperk), AGT200 (Gotenica), AGT 300 (Sevnica), AGT 400 (Sv. Arh na Pohorju), AGT 500 (Socerb) in AGT 600 (Kluže). Meritve so bile izvedene leta 1996, 1998, 2000 in 2014, hkrati s samo izvedbo absolutnih gravimetričnih meritev. Skupno vsem tem točkam je, da so stabilizirane v večjih stabilnih objektih (gradovi, cerkve), večinoma v kletnih etažah, kar pomeni, da ni nezanemarljiv vpliv mas (topografskih in umetnih), ki se nahajajo nad samim nivojem točke.

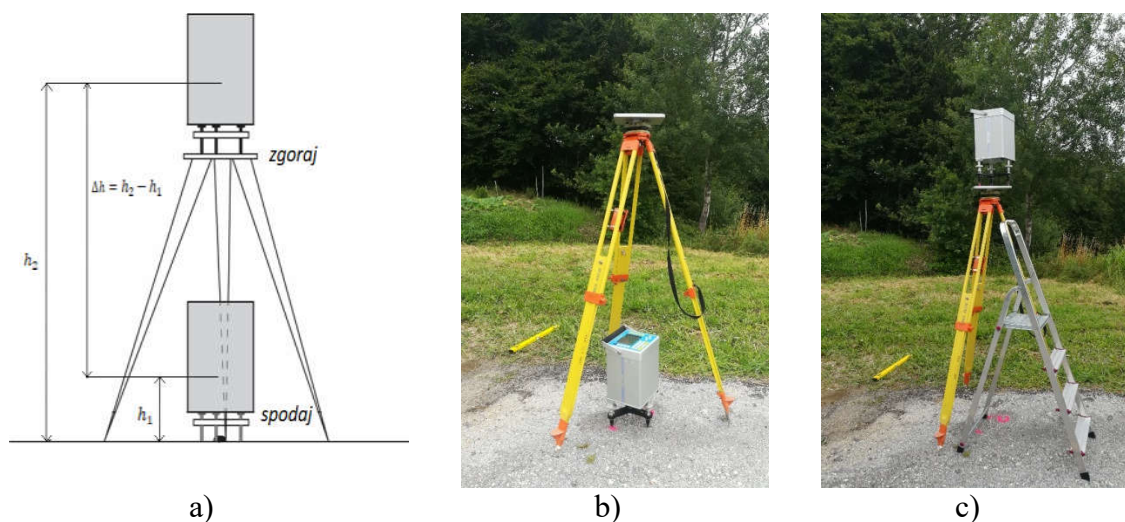
Zato smo za potrebe te raziskave izvedli niz meritev vertikalnih gradientov na točkah razporejenih po celotnem ozemlju Slovenije. V testno izmero so bile tako vzete vse točke gravimetrične mreže 1. reda (Koler in sod., 2012). Grafični prikaz razporeditve izmerjenih točk je na sliki 1. Meritve so se izvajale skozi daljše časovno obdobje in sicer v letu 2018 z instrumentom Scintrex CG-3M, v letu 2019 in 2020 pa z instrumentom Scintrex CG-5.

Položaj in višina detajlne gravimetrične točke je bila določena z GNSS-RTK metodo izmere, s tremi neodvisnimi serijami izmere v trajanju po 30 sekund, z dvofrekvenčnimi sprejemniki GNSS in navezavo na omrežje SIGNAL. Na nekaterih točkah so višine določene z nivelmansko izmero – navezavo na nivelmansko mrežo.



Slika 1: Testno območje z izmerjenimi točkami.

Sam postopek izmere na točki je bil sledeč: Nad stabilizirano točko smo postavili stativ in nanj namestili posebej v ta namen izdelano ploščo, ki omogoči postavitev podnožja instrumenta. Zaradi tresljajev pri transportu z avtom, smo pred meritvami počakali vsaj 15 minut, da se instrument umiri in stabilizira. S tem tudi preprečimo temperaturne šoke in zmanjšamo pogreške zaradi vpliva histereze. Na vsaki točki je izvedeno vsaj 11 nizov meritev, izmenjujoče na obeh višinah nad gravimetrično točko (6 spodaj, 5 zgoraj), pri čemer vsak niz tvori 60 eno-sekundnih meritev. Primer izmere je prikazan na sliki 2. Meritve so opravljene v naslednjem zaporedju: 1–2–1–2–1 ..., pri čemer je 1 – meritev spodaj in 2 – meritev zgoraj. Za vsak niz posebej izmerimo višino instrumenta (glej sliko 2) in jo zabeležimo v zapisnik. Prav tako zapišemo izmerjene vrednosti težnega pospeška za vsak niz, ki jih poda instrument. Temperaturo zraka in zračni tlak smo merili s prenosno meteorološko postajo Thommen HM-30 s serijsko številko B111225, proizvajalca Huber, ki je bil ustrezno certificiran. Na vseh točkah so meritve izvedene na dveh višinah na razmiku, ki je približno 1,5 m. Srednja višina senzorja vseh meritev znaša 0,255 m za postavitev spodaj in 1,705 m za postavitev zgoraj. Srednja razlika v višinah med postavitvijo spodaj in zgoraj znaša 1,450 m.



Slika 2: a) Položaj instrumenta med meritvami vertikalnega gradienta težnosti, b) meritev spodaj in c) meritev zgoraj.

## Izračun vertikalnih gradientov

V okviru obdelave podatkov meritev izračunamo ustrezne popravke in redukcije za meritve na vsaki točki. Relativna gravimetra Scintrex CG-3M in Scintrex CG-5 omogočata uporabo nekaterih redukcij v realnem času, ki smo jih upoštevali med samimi meritvami. To so:

- popravek dolgoročnega hoda gravimetra,
- popravek za nehorizontalnost gravimetra,
- popravek zaradi spremembe temperature senzorja,
- redukcijo meritev za kalibracijski faktor in
- popravek zaradi plimovanja trdne Zemlje (po modelu Longman).

Naknadno pa smo upoštevali še naslednje (Torge, 1989):


- redukcijo izmerjene vrednosti težnega pospeška z nivoja senzorja instrumenta na nivo,
- točke oz. redukcijo za višino instrumenta,
- popravek zaradi vpliva zračnega tlaka,
- popravek zaradi gibanja Zemljinih polov,
- redukcijo opazovanj za preostali hod instrumenta.

V naši raziskavi smo meritve izvajali na dveh višinah, torej se nad točko izmere predpostavlja konstantni vertikalni gradient, ki se izračuna z:

$$VGT = \frac{g_j - g_k}{h_j - h_k} = \frac{\Delta g_{jk}}{\Delta h_{jk}}, \quad (1)$$

kjer so:  $g_{j,k}$  – odčitki gravimetra na stojiščih  $j$  in  $k$ ,  $h_{j,k}$  – referenčne višine gravimetra na stojiščih  $j$  in  $k$ ,  $\Delta g_{jk}$  – razlika odčitkov in  $\Delta h_{jk}$  – razlika referenčnih višin gravimetra.


Na sliki 3 so prikazane izmerjene vrednosti vertikalnih gradientov na vseh obravnavanih točkah.



Slika

3: Grafični prikaz vrednosti VGT za vse izmerjene točke.

Na sliki 4 je prikazan histogram porazdelitve vseh merjenih vrednosti vertikalnih gradientov težnosti v 12 velikostnih razredov. Več kot 60 % vrednosti se nahaja v intervalu [285, 330], kar pomeni da ima več kot 60 % rezultatov vrednost, ki je izjemno blizu teoretični vrednosti, to je vrednosti normalnega gradienta težnosti (308,6 µGal/m).



Slika 4: Frekvence porazdelitve merjenih vrednosti vertikalnih gradientov težnosti

Razlike med minimalnim in maksimalnim izmerjenim vertikalnim gradientom težnosti na tem območju znašajo 180,7  $\mu\text{Gal/m}$ . Torej gre za relativno velike spremembe. Največji vertikalni gradient (403,0  $\mu\text{Gal/m}$ ) je izmerjen na točki GT18 (Maribor), najmanjši (222,3  $\mu\text{Gal/m}$ ) pa na točki GT16 (Črna na Koroškem). Srednja vrednost na vseh izmerjenih točkah je 306,2  $\mu\text{Gal/m}$ , kar je zelo blizu vrednosti normalnega gradienta težnosti (308,6  $\mu\text{Gal/m}$ ). Iz tega stališča lahko rečemo, da je izbor točk za nadaljnje analize modeliranja vertikalnega gradienta zelo primeren, saj vsebuje odstopanja od normalne (srednje) vrednosti tako v eno kot v drugo stran. Standardni odkloni izvedenih meritev ( $\bar{\sigma}_{\Delta g} = 2,52 \mu\text{Gal}$ ) so pridobljeni iz ocene natančnosti posameznih odčitkov in predstavljajo t. i. notranjo natančnost meritev. Zanima pa nas kakšna je dejanska ocena natančnosti izvedenih gravimetričnih meritev vertikalnega gradienta z relativnim gravimetrom Scintrex, oziroma t. i. zunanja natančnost. V izraz (1) vpeljemo zakon o prenosu varianc in kovarianc za nekorelirana merjenja in tako dobimo vpogled, kako vpliva natančnost razlike pospeška sile teže  $\Delta g$  in natančnost spremembe višinske razlike stojišča  $\Delta h$  na natančnost izračunanega vertikalnega gradienta. Velja:

$$\sigma_{VGT}^2 = \left(\frac{1}{\Delta h}\right)^2 \sigma_{\Delta g}^2 + \left(-\frac{\Delta g}{\Delta h^2}\right)^2 \sigma_{\Delta h}^2. \quad (2)$$

V preglednici 1 so zbrane minimalne, maksimalne in srednje vrednosti izmerjenih razlik težnih pospeškov, izmerjenih višinskih razlik in pripadajoče izračunane ocene natančnosti določitve vertikalnega gradienta težnosti.

Preglednica 1: Ocene natančnosti izmerjenih vertikalnih gradientov težnosti

	Min.	Maks.	Sred.
$\Delta g$ [ $\mu\text{Gal}$ ]	222,3	403,0	465,0
$\Delta h$ [m]	1,238	1,651	1,505
$\sigma_{VGT}$ [ $\mu\text{Gal/m}$ ]	5,6	4,2	4,6


Pri izmeri vertikalnih gradientov težnosti z uporabo relativnega gravimetra Scintrex CG-3M oz. CG-5 in metodo izmere, kot je predhodno opisana, znašajo ocenjene natančnosti določitve vertikalnih gradientov težnosti do maks. 5,6  $\mu\text{Gal/m}$ . To vrednost v nadaljevanju obravnavamo kot kriterij za oceno natančnosti pri obdelavi oz. analizi modeliranih vrednosti vertikalnih gradientov.

## Modeliranje vertikalnih gradientov težnosti

Za modeliranje težnostnega polja Zemlje smo uporabili t.i. z metodo »forward-modelling«. Vse mase nad elipsoidom smo obravnavali kot topografske mase (slika 5a), pri čemer smo sprejeli predpostavko, da lahko vertikalni gradient težnosti modeliramo z naslednjo enačbo:

$$VGT = W_{zz} = U_{zz} + \delta W_{zz}^{TOPO}, \quad (3)$$

kjer je  $\delta W_{zz}^{TOPO}$  predstavlja vpliv topografskih mas na vertikalni gradient težnosti. Nato v vseh izračunih topografske mase razdelimo na mase nad geoidom in mase pod geoidom, kot je prikazano na sliki 5b.



Slika 5: a) Topografske mase med površjem Zemlje in elipsoidom in b) njihova razdelitev na mase nad geoidom in mase pod geoidom.

Posledično smo tudi učinek topografskih mas na vertikalni gradient težnosti razdelili na vpliv mas nad geoidom in vpliv mas pod geoidom:

$$VGT = W_{zz} = U_{zz} + \delta W_{zz}^{NG} + \delta W_{zz}^{PG}, \quad (4)$$

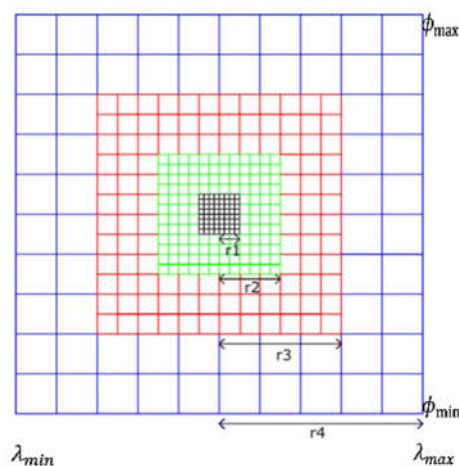
kjer je  $\delta W_{zz}^{NG}$  vpliv topografskih mas, ki se nahajajo med ploskvijo geoida in fizičnim površjem Zemlje in  $\delta W_{zz}^{PG}$  vpliv topografskih mas med ploskvijo geoida in elipsoidom.

Vse topografske mase nad geoidom se razdelijo v elementarna telesa s konstantno gostoto, kot so kvadri, tesoroidi ali poliedri. Za ta telesa se nato izračunajo Newtonovi prostorski integrali v obliki zaprtih izrazov. Gradienti težnostnega potenciala vseh topografskih mas se nato dobijo s seštevanjem posameznih drugih odvodov težnostnega potenciala vseh elementarnih teles (Hirt, 2016). V našem pristopu smo modelirali gravitacijski vpliv topografskih mas v obliki seštevanja topografskih mas med elipsoidom in geoidom in topografske mase med geoidom in fizično površino Zemlje (Odalović in sod., 2022) pri čemer smo kot osnovno telo uporabili kvader.

Uporabili smo maksimalno razdaljo 166,74 km (Tsoulis, 1999), le da smo namesto krožnice kot omejitvenega lika uporabili kvadrat, vse z namenom izboljšanja hitrosti izračuna. DMR je namreč podan v obliki kvadratov s poljubno dimenzijo. Na tak način je bila vsaka obravnavana točka  $P$  pozicionirana v središče kvadrata, ki ga omejujejo geografska širina  $\phi_{min}$  in  $\phi_{max}$  in geografska dolžina  $\lambda_{min}$  in  $\lambda_{max}$ . Vse izbrane topografske mase so bile s presekom z DMR-ji razdeljene tudi na kvadre (Nagy in sod., 2000). Za



dotatno izboljšanje hitrosti izračunov pa smo, kot je običajno, uporabili različne DMR-je glede na razdaljo med točko  $P$  in središčem mase vsakega upoštevanega kvadra. Tako smo opredelili do štiri referenčne razdalje  $r_i$ ,  $i = 1, \dots, 4$ , (slika 6).



Slika 6: Razdelitev topografskih mas okoli obravnavane točke na cone z različnimi resolucijami DMR.

Na koncu smo izračunali skupni vpliv izbranih topografskih mas na vertikalni gradient težnosti  $z$ :

$$\delta W_{zz}^{TOPO} = \sum_{i=1}^n (\delta W_{zz}^{Kvader})_i, \quad (5)$$

kjer je  $n$  skupno število kvadrov na obravnavanem območju in se  $\delta W_{zz}^{Kvader}$  izračuna z enačbo po Nagy in sod., 2000.

Med celotnim procesom računanja vertikalnih gradientov težnosti preverjamo skladnost vseh izračunov z uporabo dveh drugih odvodov po koordinatnih oseh  $x$  in  $y$ , da velja pogoj:

$$\delta W_{xx}^{TOPO} + \delta W_{yy}^{TOPO} + \delta W_{zz}^{TOPO} = 0. \quad (6)$$

Upoštevan je tudi vpliv ukrivljenosti Zemlje in sicer se gravitacijski vpliv posameznega kvadra (enačbe Nagy in sod., 2000) popravi, če je kvader oddaljen več kot 10 km od obravnavane točke  $P$ . Uporabi se metodo transformacije; opis postopkov in uporabljene enačbe določitve tega vpliva so detajlno podani v Makhloof (2007).

Dodaten izziv v postopku modeliranja vertikalnega gradienta težnosti predstavlja nekonsistentnost višin na obravnavanih točkah. Točke imajo višine določene večinoma z geodetskimi merskimi tehnikami (nivelman, trigonometrično višinomerstvo, GNSS višinomerstvo), medtem ko so višine DMR določene s tehnikami daljinskega zaznavanja. Seveda se tako pojavi neskladnost ( $\Delta H$ ) med merjeno višino stabilizirane točke in višino iste točke določene s presekom DMR. Odstopanje je odvisno predvsem od višinske kakovosti DMR, pri čemer v splošnem lahko rečemo, da višja prostorska ločljivost DMR (npr.  $1 \times 1$  m) zagotavlja manjša odstopanja.

V izračunih smo uporabili različne razpoložljive DMR (preglednica 2) in različne razdalje območij  $r_i$  (slika 6). S kombiniranjem teh podatkov smo ustvarili različne modele izračuna, kot so prikazani v preglednici 2. Vse skupaj smo obravnavali 27 različnih variant modelov. Referenčne razdalje  $r_1, r_2, r_3$  in  $r_4$  so izražene v km, pri čemer se računa od 0,0 km naprej, glej sliko 6. Uporabljene so različne razdalje, pri čemer smo uporabili pristop podrobneje predstavljen v Zahorec in sod. (2017).

Preglednica 2: Modeli uporabljeni v izračunih.

Ime modela	Uporabljen DMR (poudarjeno) in razdalje [km]			
	$r_1$	$r_2$	$r_3$	$r_4$
1a	<b>DMR1000</b>	-	-	-
	166,74			
2a	<b>DMR100</b>	<b>DMR1000</b>	-	-
	28,80	166,74		
3a	<b>DMR25</b>	<b>DMR1000</b>	-	-
	28,80	166,74		
4a	<b>DMR12,5</b>	<b>DMR1000</b>	-	-
	28,80	166,74		
5a	<b>DMR12,5</b>	<b>DMR100</b>	<b>DMR1000</b>	-
	5,24	28,80	166,74	
	<b>DMR1</b>	<b>DMR25</b>	<b>DMR100</b>	<b>DMR1000</b>
6a	0,25			
7a	0,50	5,24	28,80	166,74
8a	1,00			
	<b>DMR1</b>	<b>DMR12,5</b>	<b>DMR100</b>	<b>DMR1000</b>
9a	0,25			
10a	0,50	5,24	28,80	166,74
11a	1,00			
	<b>DMR1</b>	<b>DMR12,5</b>	<b>DMR25</b>	<b>DMR1000</b>
12a	0,25	5,24	28,80	166,74
13a	0,50			
	<b>DMR1</b>	<b>DMR12,5</b>	<b>DMR1000</b>	
14a	0,25	5,24	166,74	-
	<b>DMR1</b>	<b>DMR25</b>	<b>DMR100</b>	<b>DMR1000</b>
15a	0,05	-	-	-
16a	0,10			
17a	0,25			
18a	0,50			
19a	1,00			
20a	1,50			
21a	0,50	5,24	-	-
22a	0,50	5,24	28,80	-
23a	0,50	10,00	28,80	-
24a	0,50	5,24	32,00	-
25a	0,50	5,24	28,80	50,00
26a	0,50	5,24	28,80	100,00
27a	0,50	5,24	28,80	150,00

### Analiza rezultatov

Na podlagi izračunanih (modeliranih) vrednosti VGT lahko za vsako obravnavano točko izvedemo primerjavo z referenčno (merjeno) vrednostjo VGT. Dobimo razliko odstopanj za vse točke za vse modele, ki jo obravnavamo kot napako modeliranja:

$$\Delta_i = VGT_{ref} - VGT_{mod}, \quad (7)$$


kjer je  $VGT_{ref}$  referenčna (merjena) vrednost vertikalnega gradienta težnosti in  $VGT_{mod}$  modelirana (izračunana) vrednost vertikalnega gradienta težnosti.

Za vsak posamezni model lahko na podlagi odstopanj ( $\Delta_i$ ) na vseh 30 testnih točkah določimo statistične kazalce odstopanj: Min. – minimum, Maks. – maksimum, Raz. – razpon, Pov. – povprečje, Med. – mediana, Std. o. – standardni odklon, RMS – korenjen srednji kvadratni pogrešek. Korelacijo med merjenimi in modeliranimi vrednostmi vertikalnih gradientov težnosti preverimo s pomočjo Pearsonovega korelacijskega testa: vrednosti  $R^2$  ( $RSQ$ ) – kvadrat korelacijskega koeficienta,  $r$  – korelacijski koeficient,  $m$  – koeficient linearne trendne regresije. Zbirnik statističnih kazalcev vseh izračunanih modelov za testno območje je prikazan v preglednici 3.

Preglednica 3: Statistični kazalci odstopanj med referenčnimi in modeliranimi vrednostmi VGT.

Model	Min [ $\mu\text{Gal}/\text{m}$ ]	Max [ $\mu\text{Gal}/\text{m}$ ]	Raz. [ $\mu\text{Gal}/\text{m}$ ]	Pov. [ $\mu\text{Gal}/\text{m}$ ]	Std. o. [ $\mu\text{Gal}/\text{m}$ ]	RMS [ $\mu\text{Gal}/\text{m}$ ]	$R^2$	$r$	$m$
1a	-47,6	56,2	103,9	10,2	23,4	25,5	0,448	0,669	0,962
2a	-28,8	34,3	63,2	-0,6	14,4	14,4	0,788	0,888	1,000
3a	-62,7	28,6	91,3	-15,1	21,2	26,1	0,786	0,886	1,051
4a	-63,4	38,2	101,6	-24,1	26,0	35,5	0,714	0,845	1,080
5a	-63,9	41,3	105,2	-23,2	27,4	36,0	0,684	0,827	1,077
6a	-34,5	18,8	53,3	-9,2	12,3	15,4	0,870	0,933	1,030
7a	-34,7	18,1	52,8	-9,2	12,3	15,4	0,871	0,933	1,030
8a	-34,7	18,0	52,7	-9,4	12,3	15,4	0,871	0,933	1,030
9a	-34,5	18,8	53,3	-9,2	12,3	15,3	0,870	0,933	1,030
10a	-34,7	18,1	52,8	-9,2	12,3	15,4	0,870	0,933	1,030
11a	-34,7	18,0	52,7	-9,4	12,3	15,4	0,871	0,933	1,030
12a	-34,5	18,8	53,3	-9,2	12,3	15,3	0,871	0,933	1,030
13a	-34,7	18,1	52,7	-9,2	12,3	15,3	0,871	0,933	1,030
14a	-34,6	18,7	53,3	-9,2	12,3	15,3	0,871	0,933	1,030
15a	-190,3	-18,5	171,8	-113,7	32,0	118,1	0,143	0,378	1,358
16a	-187,9	-15,3	172,6	-112,1	30,6	116,2	0,236	0,486	1,355
17a	-168,6	-12,8	155,8	-95,0	30,5	99,7	0,329	0,573	1,302
18a	-139,4	-12,0	127,4	-71,4	28,9	77,1	0,393	0,627	1,227
19a	-108,7	-6,4	102,3	-48,2	23,3	53,5	0,538	0,733	1,152
20a	-93,4	-0,1	93,3	-38,9	20,5	44,0	0,621	0,788	1,123
21a	-41,9	9,5	51,4	-18,0	13,0	22,2	0,841	0,917	1,057
22a	-36,0	16,0	52,0	-10,6	12,3	16,2	0,869	0,932	1,034
23a	-36,0	15,9	51,9	-10,6	12,3	16,2	0,869	0,932	1,034
24a	-35,8	16,3	52,1	-10,5	12,3	16,1	0,869	0,932	1,034
25a	-35,3	17,1	52,4	-9,9	12,3	15,8	0,870	0,933	1,032
26a	-34,9	17,8	52,7	-9,5	12,3	15,5	0,870	0,933	1,031
27a	-34,7	18,1	52,8	-9,3	12,3	15,4	0,870	0,933	1,030


Za nekaj reprezentativnih modelov so na grafikonih izrisane linearne regresijske (trendne) funkcije in pripadajoči  $R^2$  (RSQ) na sliki 7. Z rdečo barvo so prikazane funkcije v obliki enačbe  $y = mx + a$  in s črno barvo v obliki enačbe  $y = mx + 0$ . Na osi  $x$  so modelirane (izračunane) vrednosti, na osi  $y$  pa referenčne (merjene) vrednosti vertikalnih gradientov težnosti. Že iz spodnjih štirih prikazanih modelov se vidi, da se korelacije močno razlikujejo glede na izbrani model.



Slika 7: Korelacije med referenčnimi (os x) in modeliranimi (os y) VGT za štiri obravnavane modele.


Na podlagi izvedenih računov lahko s pomočjo statističnih kazalcev in korelacijskega testa neposredno primerjamo vpliv posameznih vhodnih podatkov na končni rezultat in izvedemo analizo vpliva resolucije DMR, vpliva referenčne razdalje in vpliva položaja obravnavane točke.

Na sliki 8 so obravnavani modeli, kjer se spreminjajo podatki DMR (resolucije 1000 m, 100 m, 25 m, 12,5 m, 1 m), pri čemer so razdalje izračuna enake (166,74 km). Pričakovano se rezultati modeliranih VGT izboljšujejo z večanjem resolucije uporabljenih DMR, torej najboljše so rezultati pri uporabi DMR1 (modela 7a in 10a) in najslabši pri uporabi DMR1000 (modela 1a in 2a). Iz rezultatov sklepamo, da resolucija DMR bistveno vpliva na rezultat izračuna, pri čemer večja resolucija DMR poda boljše rezultate modeliranega vertikalnega gradienta.



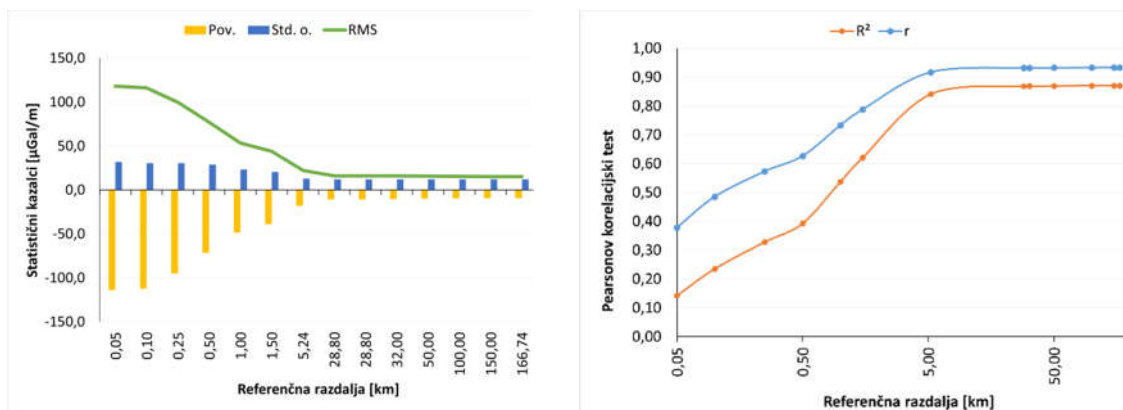
Slika 8: Statistični kazalci – uporaba različnih resolucij DMR v coni 1.

Na sliki 9 prikazujemo vpliv uporabe različnih resolucij DMR v oddaljenih conah (cona 2 in cona 3), pri čemer referenčne razdalje ostajajo nespremenjene. Pri vseh modelih je do razdalje  $r_1$  (0,25 km ali 0,5 km) uporabljen DMR1, od  $r_1$  naprej pa različni razpoložljivi DMR in sicer (12,5 m, 25 m, 100m) in v coni 4 DMR1000. Uporabljeni so modeli 6a, 9a, 12a, 14a, 7a, 10a in 13a. Vidimo, da sprememb med njimi dejansko ni zaznati. Iz tega sklepamo, da resolucija DMR v conah 2 in 3, torej na razdalji do 5,24 oz. 28,8 km, ne vpliva na rezultat izračuna, seveda pa se z večanjem resolucije podaljšuje računski čas.




Slika 9: Statistični kazalci – uporaba različnih resolucij DMR v coni 2 in coni 3.

Na sliki 10 so prikazani statistični kazalci izračunov v odvisnosti od končne razdalje izračuna okoli posamezne točke (modeli 15a, 16a, 17a, 18a, 19a, 20a, 21a, 22a, 23a, 24a, 25a, 26a, 27a in 12a). Pri tem smo pri vseh izračunih uporabili isto kombinacijo DMR (DMR1, DMR25, DMR100 in DMR1000), spreminja se samo  $r_i$ . Vidimo, da se rezultati bistveno izboljšajo, če v izračunu upoštevamo radij vsaj 10 km okoli posamezne točke, od 30 km naprej pa ni zaznati nobenega vpliva.



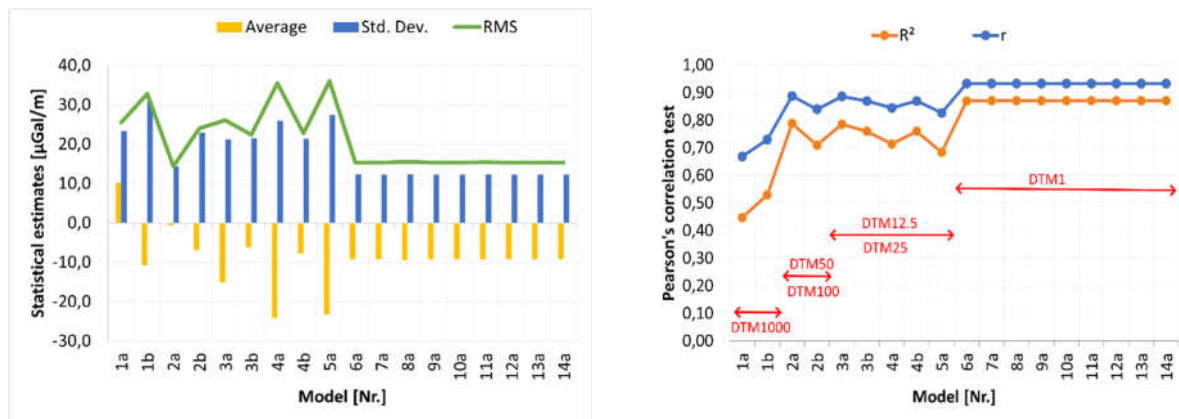
Slika 10: Statistični kazalci – vpliv končne referenčne razdalje izračuna.

Na sliki 11 so prikazane razlike med modeli, kjer spreminjamo samo razdaljo v coni 1 ( $r_1$ ), torej v neposredni bližini točke (0,25 km, 0,5 km in 1km). Pri vseh variantah uporabimo isto kombinacijo DMR, v coni 1 uporabimo DMR1, v coni 2 DMR25 (modeli 8\_\*) oz. DMR12\_5 (modeli 9\_\*), v coni 3 DMR100 in coni 4 DMR1000. Uporabljeni so modeli 6a, 7a, 8a, 9a, 10a, 11a, 12a in 13a. Vidimo, da sprememba  $r_1$  dejansko ne vpliva na rezultate izračuna, saj so vsi statistični kazalci skoraj identični.




Slika 11: Statistični kazalci – vpliv referenčne razdalje v coni 1 z DMR1.

Za celovitejši pregled je smiselno grafično prikazati statistične kazalce izračunov še za vse obravnavane modele skupaj. To nam poda grobi vpogled v razmerja med posameznimi modeli in končnimi modeliranimi vrednostmi VGT. Na sliki 12 so prikazani vsi obravnavani modeli. Na desnem grafikonu so tudi označeni osnovni parametri, ki v grobem podajajo vpliv bistvenega elementa na rezultate.



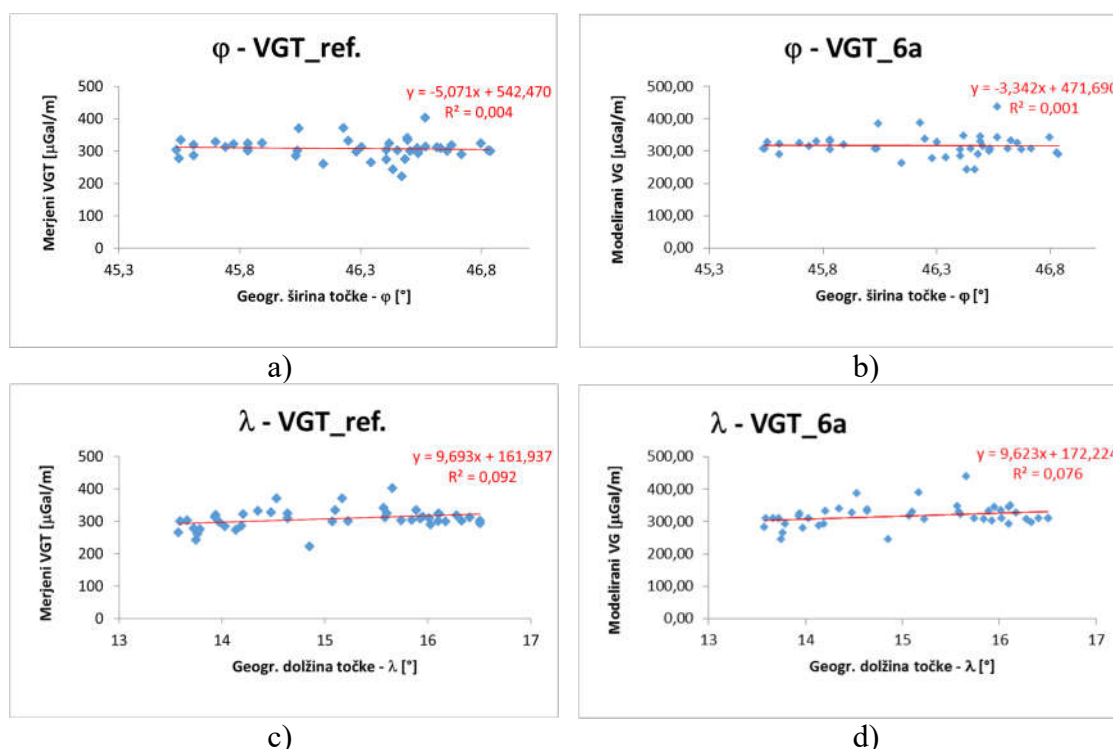
Slika 12: Prikaz statističnih cenilk za vse obravnavane modele skupaj.

Zanimajo nas morebitne korelacije med vertikalnimi gradienti težnosti (merjenimi ali modeliranimi) in ostalimi spremenljivkami – nadmorsko višino (slika 13) ter geografsko širino oz. geografsko dolžino (slika 14). Predvidevamo, da korelacije ni.



Slika 13: Prikaz korelacije med nadmorsko višino točk (H) in levo referenčnim VGT ter desno modeliranim VGT (primer modela 6a).

Prav tako ni zaznati korelacije med merjenimi oz. modeliranimi VGT in položajem točk ( $\varphi$ ,  $\lambda$ ), ki je prikazana na grafikonih na sliki 14.



Slika 14: Prikaz korelacij med geografsko širino ( $\varphi$ ) in a) referenčnim VGT b) modeliranim VGT (primer modela 6a), ter geografsko dolžino ( $\lambda$ ) in c) referenčnim VGT d) modeliranim VGT (primer modela 6a).

Kot je že navedeno je ocenjena natančnost ( $\sigma_{VGT}$ ) izvedenih terenskih meritev vertikalnih gradientov težnosti z relativnim gravimetrom Scintrex  $\sim 6 \mu\text{Gal/m}$  (glej preglednico 1). S faktorjem  $k = 2$  lahko sprejmemo zgornjo kontrolno mejno vrednost razlik med izmerjenimi in modeliranimi vertikalnimi gradienti, ki tako znaša  $\sim 12 \mu\text{Gal/m}$ . Na podlagi te mejne vrednosti lahko ugotovimo, kateri modeli dejansko dosegajo natančnost, ki je primerljiva z merjenimi vrednostmi. Za primerljivo statistično cenilko vzamemo standardni odklon obravnavanih modelov (iz preglednice 3) in na podlagi tega kriterija lahko sklepamo naslednje:

- če želimo, da je natančnost modeliranih vrednosti vertikalnih gradientov težnosti primerljiva z natančnostjo merjenih vrednosti, je potrebno v postopku modeliranja (v bližnji okolici obravnavane točke) uporabiti DMR v resoluciji  $1 \times 1 \text{ m}$ . Za bližnjo okolico (cona 1) se smatra razdalja vsaj 250 m.

- če želimo, da je natančnost modeliranih vrednosti vertikalnih gradientov težnosti primerljiva z natančnostjo merjenih vrednosti, je potrebno poleg zgoraj navedenega v postopku modeliranja upoštevati razdaljo vsaj 28,8 km okoli obravnavane točke.

Očitno je torej, da resolucija uporabljenega DMR, predvsem v najbližji coni (cona 1), bistveno vpliva na kvaliteto rezultata. Razlika med DMR1000 in DMR1 je očitna (glej tudi slike 8 do 11), saj je korelacijski koeficient bistveno višji (od 0,6 do 0,9). Podobno pričajo tudi ostali statistični kazalci.

## Zaključek

Poznane vrednosti vertikalnih gradientov težnosti imajo v geodeziji velik pomen. Pri gravimetričnih meritvah je namreč potrebno reducirati vrednosti izmerjenih težnih pospeškov, pa naj si gre za relativne ali absolutne gravimetrične meritve, iz nivoja senzorja gravimetra na nivo same merjene točke. Običajno se za to uporabi normalni vertikalni gradient težnosti ( $308,6 \mu\text{Gal}/\text{m}$ ), ki predstavlja splošno sprejeto srednjo vrednost. Vendar pa dejanske vrednosti vertikalnih gradientov težnosti lahko tudi zelo odstopajo. Na podlagi nekaj konkretnih primerov iz prakse smo preverili smotrnost uporabe dejanskega vertikalnega gradienta pri obdelavi gravimetričnih meritev. Iz njih je razvidno, da je v nekaterih primerih pogrešek, ki ga naredimo v postopku obdelave relativnih gravimetričnih meritev, zaradi nepoznavanja dejanskega vertikalnega gradienta težnosti, zelo velik. Lahko celo preseže  $100 \mu\text{Gal}$ , kar bistveno presega oceno natančnosti rezultata (vrednosti težnega pospeška na točki). Na njegovo velikost vplivata dva bistvena dejavnika, ki sta vrednost dejanskega vertikalnega gradienta težnosti na točki in višinska razlika med točko in merskim senzorjem gravimetra. Iz navedenih primerov lahko zaključimo, da je za praktično implementacijo te raziskave v geodetsko prakso oz. v obdelavo gravimetričnih meritev, bistveno vprašanje, s kakšno natančnostjo želimo dobiti rezultate meritve. V splošnem lahko rečemo, da npr. za potrebe določitve geopotencialnih kot reperjev ali izračun (kvazi)geoida zadostuje uporaba normalnega vertikalnega gradienta težnosti. Nasprotno pa je poznavanje dejanskega vertikalnega gradienta težnosti bistveno pri izvedbi lokalnih mikro-gravimetričnih meritev, kjer se zahteva natančnost pod  $10 \mu\text{Gal}$ .

Uporabljena tehnika modeliranja vertikalnega gradienta težnosti se razlikuje od znanih in uporabljenih postopkov modeliranja vertikalnega gradienta težnosti. Prvič, namesto da bi uporabili različni metodi za izračun vpliva topografskih mas pod in nad geoidom, smo z uporabo iste metode ocenili vpliv vseh mas nad elipsoidom. Drugič, za določitev območja računanja in razdelitve na cone smo uporabili lik kvadrat, kar je v nasprotju z običajno uporabljenim likom kroga in sicer smo to izvedli z namenom izboljšanja hitrosti izračuna. Poleg tega so bile pri modeliranju uporabljene teoretične enačbe, ki omogočajo modeliranje ne glede na geografski položaj in nadmorsko višino obravnavane točke.

Prostorska ločljivost uporabljenega DMR pomembno vpliva na natančnost modeliranega VGT. Modelirane vrednosti VGT so povezane z izmerjenimi vrednostmi s korelacijskimi koeficienti v razponu od 0,669 (DMR z ločljivostjo  $1000 \times 1000 \text{ m}$ ) do 0,933 (DMR z ločljivostjo  $1 \times 1 \text{ m}$ ), kar kaže na velik vpliv pravilno obravnavanih topografskih mas pri modeliranju VGT. Za modeliranje VGT je treba upoštevati računsko razdaljo najmanj 10 km okoli obravnavane točke. Vpliv topografskih mas od razdalje 30 km naprej pa ne prispeva bistveno k točnosti izračuna. Največji prispevek pri modeliranju VGT ima najbližja cona, prispevek bolj oddaljenih con ima veliko manjši vpliv, zato je pomembno, da v neposredni bližini (cona 1) obravnavane točke uporabimo najbolj kakovosten DMR (npr.  $1 \times 1 \text{ m}$ ). Analiza različnih razdalj prve oz. najbližje cone (0,25 km, 0,5 km in 1 km) kaže na bistveno naraščanje računskega časa ter rahlo in nepomembno povečanje kakovosti modeliranja. Podobno velja pri uporabi DMR z različnimi ločljivostmi ( $12,5 \times 12,5 \text{ m}$ ,  $25 \times 25 \text{ m}$  ali  $100 \times 100 \text{ m}$ ) v conah 2 in 3. Zato je smiselno uvesti delitev obravnavanega računskega območja na posamezne cone (od 1 do 4), kjer se uporabljajo DMR z različnimi ločljivostmi. Uporaba DMR1 v coni 1 (od 0 m do 250 m), DMR25 v coni 2 (od 0,25 km do 5,24 km), DMR100 v coni 3 (od 5,24 km do 28,8 km) in DMR1000 v coni 4 (od 28,8 km do 166,7 km) se izkaže za najustreznejšo kombinacijo uporabljenih DMR z različnimi ločljivostmi, v smislu optimizacije računskega časa in točnosti rezultatov. Zato predlagamo



uporabo te kombinacije DMR in referenčnih razdalj v prihodnjih izračunih. Če želimo, da je natančnost modeliranih vrednosti vertikalnih gradientov težnosti primerljiva z natančnostjo merjenih vrednosti, je potrebno v postopku modeliranja (v bližnji okolici obravnavane točke) uporabiti DMR v resoluciji  $1 \times 1$  m. Za bližnjo okolico (cona 1) se smatra razdalja vsaj 250 m. Če želimo, da je natančnost modeliranih vrednosti vertikalnih gradientov težnosti primerljiva z natančnostjo merjenih vrednosti, je potrebno poleg zgoraj navedenega v postopku modeliranja upoštevati razdaljo vsaj 28,8 km okoli obravnavane točke. Na podlagi rezultatov lahko tudi sklepamo, da med višino terena in napako modeliranja ni statistično značilne korelacije. Enako velja tudi za geografski položaj obravnavane točke. Kakovost modeliranega VGT tako ni odvisna od geografske lege ali nadmorske višine. Analiza vpliva (učinkov) višine nad terenom, na katero se nanašajo izračuni, kaže, da je razlika med rezultati modeliranja za dve bližnji višini nepomembna in, da je mogoče modeliranje vertikalnega gradienta težnosti izvesti s privzeto vrednostjo višine nad terenom, ki je bila 1 m.

Ker postopek modeliranja vertikalnih gradientov težnosti, uporabljen v tej nalogi, dosega natančnost reda samih meritev že ob uporabi fiksne gostote topografskih mas ( $2670 \text{ kg/m}^3$ ), lahko tudi zaključimo, da uporabljena metoda ustreza trenutnim praktičnim zahtevam v geodeziji.

### Literatura in viri

- Crossley D., Hinderer J., & Riccardi U. (2013). The measurement of surface gravity. *Rep Prog Phys*, 76, 4:046-101. doi: 10.1088/0034-4885/76/4/046101
- Dykowski, P. 2012. Vertical gravity gradient determination for the needs of contemporary absolute gravity measurements – first results. *Reports on Geodesy*, 92(1): 23–35.
- Hinze, W.J., Aiken, C., Brozena, J.M., Coakley, B.J., Dater, D., Flanagan, G.P., Forsberg, R., Hildenbrand, T.G., Keller, G.R., Kellogg, J.W., Kucks, R., Li, X., Mainville, A., Morin, R.J., Pilkington, M.I., Plouff, D., Ravat, D., Román, D.A., Urrutia-Fucugauchi, J., Véronneau, M., Webring, M.W., Winester, D. 2005. New standards for reducing gravity data: The North American gravity database. *Geophysics*, 70(4): 25–32. DOI: [10.1190/1.1988183](https://doi.org/10.1190/1.1988183).
- Hirt, C. (2016). Gravity forward modelling. In E. Grafarend (Ed.), *Encyclopedia of Geodesy*. Cham, Switzerland: Springer. doi:[https://doi.org/10.1007/978-3-319-02370-0\\_106-1](https://doi.org/10.1007/978-3-319-02370-0_106-1)
- Hofmann-Wellenhof, B., & Moritz, H. (2006). *Physical Geodesy*. Vienna: Springer. doi:10.1007/978-3-211-33545-1
- Koler, B., Medved K., Kuhar M. 2012. The New Fundamental Gravimetric Network of Slovenia. *Acta geodaetica et geophysica Hungarica*, 47(3): 271–286. DOI: [10.1556/AGeod.47.2012.3.1](https://doi.org/10.1556/AGeod.47.2012.3.1).
- LaCoste & Romberg, 2004. Instruction Manual Model G & D Gravity Meters, LaCoste & Romberg, Austin, Texas, USA.
- Makhloof, A.-E. (2007). *The Use of Topographic-Isostatic Mass Information in Geodetic Applications*. Bonn: Rheinische Friedrich-Wilhelms-Universität Bonn.
- Nagy, D., Papp, G., & Benedek, J. (2000). The gravitational potential and its derivatives for the prism. *Journal of Geodesy*, 552-560. doi:10.1007/s001900000116
- Odalović, O., Medved, K., Naod, S. 2022. Modeling of vertical gravity gradient by normal gravity field and digital terrain models. *Journal of Geodesy* 96, art.74: 18.str.DOI: [10.1007/s00190-022-01669-y](https://doi.org/10.1007/s00190-022-01669-y)
- Repanić, M., Kuhar, M., Malović, I. 2015. High precision vertical gravity gradient determination in Croatia. *Acta Geodaetica et Geophysica*, 50: 151–171. DOI: [10.1007/s40328-015-0102-z](https://doi.org/10.1007/s40328-015-0102-z).
- Scintrex 2017. CG-6 Autograv Gravity Meter. Operation Manual. Revision A, Concord, Canada, Scintrex Limited: 84 str.
- Torge, W. (1989). *Gravimetry*. Berlin-New York: Walter de Gruyter.

- Tsoulis, D. (1999). *Analytical and Numerical Methods in Gravity Field Modelling of Ideal and Real Masses*, Doctoral Dissertation. Munchen: Technischen Universitat Munchen.
- Zahorec, P., Marušiak, I., Mikuška, J., Pašteka, R., & Papčo, J. (2017). Numerical Calculation of Terrain Correction Within the Bouguer Anomaly Evaluation (Program Toposk). In J. M. Roman Pašteka (Ed.), *Understanding the Bouguer Anomaly* (pp. 79-92). Amsterdam: Elsevier. doi:10.1016/B978-0-12-812913-5.00004-X

# Napovedovanje vremena s konvolucijskimi nevronskimi mrežami

Uroš Perkan<sup>1</sup>, Gregor Skok<sup>1</sup>, Žiga Zaplotnik<sup>2,1</sup>

## Povzetek

Moderno napovedovanje vremena temelji na numeričnih vremenskih modelih, ki časovno evolucijo atmosferskih polj izračunajo na podlagi osnovnih fizikalnih zakonov. V pričujočem članku opišemo model strojnega učenja za globalno srednjeročno napovedovanje vremena ConvCastNet, ki smo ga razvili v okviru magistrske naloge. ConvCastNet temelji na konvolucijskih nevronskih mrežah in napoved izvaja na 3-stopinjski ekviangularni prostorski mreži za 10 atmosferskih, morskih in kopenskih spremenljivk.

ConvCastNet se napovedovanja nauči tako, da pri učenju upošteva cenilko (t. i. funkcijo izgube), ki meri razliko med kratkoročno napovedjo in istočasnim približkom resničnega stanja ozračja, ki ga določimo iz rekonstrukcij preteklega vremena, t. i. reanaliz, ERA5. V model implementiramo nov način obravnave robov atmosferskih polj in polj latentnih značilnk, tako da je upoštevana Zemljina sferična geometrija. Začetni pogoj za modelsko napoved so polja reanaliz, napoved pa izvedemo z avto regresivnim korakanjem s časovnim korakom 1 dan. ConvCastNet napoveduje dnevno povprečje atmosferskih spremenljivk.

Vremenska napoved z modelom ConvCastNet omogoča natančno napovedovanje razvoja sinoptičnih vremenskih valov. Pri napovedovanju polja geopotenciala na 500 hPa ploskvi ConvCastNet tako doseže 7,8 dni z vrednostjo koeficienta korelacij anomalij (ACC) večjo od 0,6, s čimer se pri tej metriki približa rezultatom najnovjših modelov strojnega učenja in fizikalnemu determinističnemu visokoresolucijskemu modelu (HRES) Evropskega centra za srednjeročne vremenske napovedi (ECMWF).

Model ConvCastNet lahko več dni vnaprej uspešno napove položaje sinoptičnih valov in baričnih tvorb ter uspešno sledi trajektorijam tropskih ciklonov. Zaradi nizke ločljivosti in dnevnega povprečenja atmosferskih polj pa ni sposoben izvedbe koristne napovedi intenzitete tropskih ciklonov, lokalnih ekstremnih padavinskih dogodkov in ostalih lokalnih vremenskih ekstremov. Analiza porazdelitve napak modela v letu 2022 pokaže, da je absolutna napaka vremenskih napovedi največja na baroklinih območjih v visokih geografskih širinah, normiranje napake z naravno variabilnostjo vremena pa pokaže, da te glede na tipično hitrost spreminjanja vremena najhitreje naraščajo v tropih.

**Ključne besede:** strojno učenje, napovedovanje vremena, konvolucijska nevronska mreža, konvolucijskih kodirnik, povprečna kvadratna napaka, koeficient korelacij anomalij, tropski ciklon, absolutna napaka

**Keywords:** machine learnig, weather forecasting, convolutional neural network, convolutional encoder-decoder, root mean squared error, anomaly correlation coefficient, tropical cyclones, absolute error

## Uvod

Vremenske razmere vplivajo na kopico različnih človekovih dejavnosti, ki neposredno ali posredno vplivajo na blagostanje človeške civilizacije. Neugodne vremenske razmere lahko otežijo kmetovanje, onemogočijo uspešno pridelavo hrane, povzročijo težave v

---

<sup>1</sup> Univerza v Ljubljani, Fakulteta za matematiko in fiziko, Jadranska ulica 19, Ljubljana

<sup>2</sup> Evropski center za srednjeročne vremenske napovedi, Robert-Schuman-Platz 3, Bonn, Nemčija

prometu in pridobivanju električne energije, v najslabšem primeru pa povzročijo tudi izgubo premoženja in človeške žrtve. Zaradi njihovega izrazitega vpliva na blagostanje prebivalstva napovedovanje vremena predstavlja enega izmed ključnih virov za priprave na neugodne vremenske dogodke in preprečitev njihovih negativnih posledic.

Zasnove modernega napovedovanja vremena segajo v začetek 20. stoletja, ko je L. F. Richardson pokazal, da lahko sistem parcialnih diferencialnih enačb, ki opisujejo atmosfero (gibalne enačbe, kontinuitetna enačba, termodinamska enačba in plinska enačba) diskretiziramo in rešujemo na mreži točk (Richardson & Lynch, 1922). Prvo numerično vremensko napoved je približno tri desetletja kasneje izvedel J. G. Charney (Charney et al., 1950), od takrat pa je s hitrim napredkom v računski zmogljivosti superračunalnikov, izpopolnjevanjem numeričnih shem, izboljšavo algoritmov za pridobivanje kakovostnega približka začetnega stanja ozračja (t. i. začetni pogoj) in večanjem števila in kakovosti meritev vremenska napoved numeričnih vremenskih modelov dosegla velik napredek v natančnosti na kratkoročnih, srednjeročnih, sezonskih in klimatoloških časovnih skalah (Bauer, 2015).

Dinamika atmosfere je zaradi nelinearnih členov v prognostičnih parcialnih diferencialnih enačbah kaotična, zato je kakovost vremenske napovedi omejena z velikostjo napake v začetem pogoj. Poleg tega napako dodatno večajo izbira numerične metode, parametrizacija podmrežnih procesov in netočnost robnih pogojev. Z nadomestitvijo fizikalnih modelov s statističnimi metodami se pri napovedovanju vremena znebimo potrebe po obravnavi raznoraznih parametrizacij, ki so v fizikalnih modelih dodane, kjer neposredna simulacija procesov ni mogoča (Rasp et al., 2018). Modeli strojnega učenja se lahko povezav med atmosferskimi spremenljivkami in napoved nadaljnjega razvoja vremena učijo na podlagi podatkov o stanju vremena v preteklosti. Tako se znebimo potrebe po izvajanju aproksimacij v fizikalnih enačbah in model napovedovanja učimo tako, da minimizira napako med napovedanim stanjem atmosfere in dejanskim stanjem atmosfere, pridobljenim v procesu asimilacije meritev (npr. Courtier et al., 1994).

Preizkušenih je bilo že veliko različnih arhitektur nevronske mreže. Dueben in Bauer, 2018 sta uporabila preprosto gosto povezano nevronske mreže, Weyn et al., 2019 in Weyn et al., 2021 pa so uporabili konvolucijske nevronske mreže (CNN) in z njimi zgradili konvolucijski kodirnik, imenovan DLWP (angl. *Deep Learning Weather Prediction*). Pokazali so, da je DLWP stabilen in sposoben izvedbe daljših vremenskih napovedih. Izvedli so tako deterministično vremensko napoved, kjer se za vsako lokacijo napove le po eno vrednost vsake izmed modelskih spremenljivk, kot ansambelsko vremensko napoved, kjer se za vsako lokacijo napove verjetnostno porazdelitev vrednosti vsake izmed spremenljivk. Pri slednji so uporabili podatke 10 perturbiranih začetnih pogojev iz reanalize ERA5 (Hersbach et al., 2020) in 32 različno naučenih modelov ter tako dosegli 320 članov ansambla. Ansambelska napoved DLWP je hitra in energijsko učinkovita, vendar po kakovosti ne premaga ansambelske napovedi Evropskega centra za srednjeročne vremenske napovedi (ECMWF).

Dobre rezultate so pokazali modeli osnovani na grafovskih nevronske mrežah (GNN) (npr. Keisler, 2022; Lam et al., 2023; Rabier, 2023). Te delujejo na podatkih, ki so predstavljeni v obliki grafov, torej vsebujejo vozlišča in vmesne povezave. Vsako vozlišče vsebuje svoje podatke, npr. temperaturo, tlak, geopotencial itd., na različnih vertikalnih nivojih. Podatke najprej iz ekviangularne mreže preslikajo v t. i. R-krat zgoščeno ikozaedrično mrežo, v kateri so točke enakomerno porazdeljene po sferi. Nato izvedejo iterativno posodabljanje skritih stanj v vozliščih, na koncu pa skrita stanja dekodirajo nazaj na ekviangularno mrežo in s tem izvedejo en korak napovedi.

Poleg omenjenih CNN in GNN, so bile za napovedovanje preizkušene tudi različne oblike t. i. vision transformer nevronske mreže (npr. Pathak et al., 2022; Bi et al. 2023; Chen et al.

2023), nevronske operator SFNO (angl. *Spherical Fourier Neural Operators*) (Bonev, 2023) in kombinacija reševanja fizikalnih enačb z matematično diskretizacijo dinamičnega jedra in aproksimacijo ostalih fizikalnih procesov z nevronske mreže (Kochkov et al., 2023). Vision transformerji napoved izvajajo s t. i. mehanizmom pozornosti (angl. *attention-mechanism*), SFNO pa z nevronske operatorjem, ki vrednosti uteži določa z upoštevanjem sferične geometrije v Fourierovem prostoru. Vsi omenjeni pristopi na podlagi površinsko uteženih metrik korena povprečne kvadratne napake (angl. *root mean squared error*) (RMSE) in koeficienta korelacij anomalij (angl. *anomaly correlation coefficient*) (ACC) dosegajo podobno kakovost vremenske napovedi kot ECMWF-jev fizikalni visokoresolucijski deterministični model (HRES).

Dosedanje raziskave so pokazale, da so napovedi nekaterih nevronske mrež lahko boljše korelirane z dejanskim razvojem vremena in imajo manjšo povprečno napako kot napoved HRES (npr. Lam et al. 2023; Rabier, 2023; Kochkov et al., 2023). Po drugi strani imajo za razliko od HRES vsi omenjeni pristopi težave s spektralnim glajenjem napovednih polj (Rasp et al. 2023; Bonavita 2023). Posledično modeli strojnega učenja trenutno niso sposobni napovedovanja lokalnih ekstremnih padavinskih, vetrovnih in ostalih dogodkov na majhnih prostorskih skalah, hkrati pa množice njihovih napovedi ne moremo združevati v zanesljiv ansambel, ki bi zagotovil ustrezno oceno verjetnosti ekstremnih dogodkov.

V tem članku povzamemo glavne ugotovitve iz raziskovalne magistrske naloge, ki jo je pripravil Uroš Perkan (Perkan et al., 2023) in rezultate primerjamo z rezultati drugih raziskav na področju globalnega srednjeročnega napovedovanja vremena.

## Model ConvCastNet


Model ConvCastNet (angl. *Convolutional Forecasting Network*) temelji na konvolucijskih nevronske mrežah. Za razumevanje njegovega delovanja si v tem poglavju najprej ogledamo teorijo konvolucijskih nevronske mrež, nato pa opišemo proces učenja in arhitekturo modela ConvCastNet.

### Konvolucijske nevronske mreže

Izrek o neobstoju brezplačnega kosila (angl. *no free lunch theorem*) pravi, da nobena statistična metoda ni superiorna ostalim na vseh podatkovnih množicah (Wolpert & Macready, 1997). Posledično je izbira metode odvisna od podatkovne množice  $S$  oz. bolj natančno od lastnosti njenih vhodnih in ciljnih spremenljivk. Izbira tipa nevronske mreže sloni na pričakovani kakovosti in fleksibilnosti arhitekture ter na računski zmogljivosti strojne opreme, ki jo imamo na voljo. Sami smo konvolucijske nevronske mreže izbrali zaradi njihovih sposobnosti prepoznavanja vzorcev v atmosferskih poljih in sicer tako lokalnih značilnosti vremena na majhnih prostorskih skalah, kot globalnih povezav (t. i. telekonekcij), ki jih lahko prepozna v globljih plasteh nevronske mreže. Konvolucijske nevronske mreže imajo tudi sposobnost aproksimacije diferencialnih operatorjev, npr. 2D-Laplaceovega operatorja. Poleg tega smo imeli za učenje modela na voljo eno NVIDIA GeForce RTX 3090 grafično kartico, zato so bili iz izbire izvzeti vision transformerji, saj ti zahtevajo več velikostnih redov večjo računsko zmogljivost.

Konvolucijske nevronske mreže delujejo na podatkih v obliki tenzorjev z dimenzijami  $(C, H, W)$ , kjer je  $(H, W)$  matrika z dimenzijama višine  $H$  in širne  $W$ ,  $C$  pa je število kanalov (tj. število slojev matrik v tenzorju). V modelu ConvCastNet uporabljamo 3-stopinjsko ločljivost, zato je matrika atmosferskih polj oblike  $(60, 120)$ , na vhodu pa uporabljamo

skupno  $C=27$  različnih polj, saj so podatki predstavljeni na več višinskih nivojih. Delovanje konvolucijske nevronske mreže za napovedovanje vremena razložimo s pomočjo slike 1. Prikazan je konvolucijski kodirnik (angl. *convolutional encoder-decoder*), v katerem vhodne plasti najprej kodiramo v nižje dimenzionalne skrite plasti, nato pa dekodiramo nazaj na velikost vhodne plasti.



Slika 1: Prikazana je shema konvolucijske nevronske mreže v obliki konvolucijskega kodirnika. Velikost izhodne plasti je v tem primeru enaka vhodni, vmesne, skrite plasti pa so običajno manjše. Povezave med plastmi so lahko operatorji konvolucije, združevanja maksimalnih vrednosti ali operatorji, ki povečujejo ločljivost plasti.

Stanje nevrona v  $l$ -ti plasti  $v^{(l)}$  iz izhodov plasti  $l-1$   $y^{(l-1)}$  izračunamo kot (Goodfellow et al., 2016):

$$v_{i,j,k}^{(l)} = w_{0i}^{(l)} + \sum_{c=1}^C \sum_{m=1}^{k_1} \sum_{n=1}^{k_2} w_{i,c,m,n}^{(l)} y_{c,j+m-1,k+n-1}^{(l-1)}, \quad (1)$$

kjer je  $w_{0i}^{(l)}$  predsodek  $i$ -tega izhodnega kanala,  $y_{c,j+m-1,k+n-1}^{(l-1)}$  vrednost vhodnega tenzorja na položaju  $c$ -tega kanala, na višini  $j+m-1$  in širini  $k+n-1$ ,  $w_{i,c,m,n}^{(l)}$  pa vrednost 4D tenzorja uteži na  $(m,n)$ -tem položaju konvolucijskega jedra velikosti  $k_1 \times k_2$ , ki povezuje  $i$ -ti kanal izhodne plasti s  $c$ -tim kanalom vhodne plasti. Izhod nevrona  $y$  iz njegovega stanja  $v$  izračunamo kot  $y_{i,j,k}^{(l)} = \alpha(v_{i,j,k}^{(l)})$ , kjer smo z  $\alpha$  označili nelinearno aktivacijsko funkcijo. V našem primeru je  $\alpha(x) = \text{LeakyReLU}(x) = \begin{cases} x; & x > 0 \\ kx; & x \leq 0 \end{cases}$ , kjer je  $k = 0.01$ . Ta v nevronske mreže vpelje nelinearnost, zaradi katere se močno poveča njena sposobnost reprezentacije zapletenih nelinearnih funkcij. Stanja nevronov  $l$ -te plasti izračunamo tako, da po tenzorju izhodov nevronov  $l-1$  plasti v horizontalnih smereh s poljubnim korakom premikamo konvolucijsko jedro velikosti  $(C, k_1, k_2)$  (na sliki 1 shematsko prikazano s svetlo modrim kvadrom) in na vsakem položaju pomnožimo komponente uteži in istoležne izhode nevronov (t. i. operacija navzkrižne korelacije oz. v literaturi globokega učenja zaradi velike podobnosti pogosto imenovana konvolucija) ter tako dobimo vrednosti značilnk v enem kanalu  $l$ -te plasti. Uteži so med premikanjem po tenzorju konstantne. Za vsako izhodno plast uporabimo svoj nabor uteži, ki lahko v vhodnih poljih prepoznavajo druge vzorce.

Poleg konvolucijskega lahko uporabljamo tudi operator združevanja maksimalnih vrednosti (angl. *max pooling*). Ta matriko nevronov agregira tako, da podmatrike oz. jedra sosednjih nevronov velikosti  $n \times n$  združi v eno število, tako da izbere maksimalno vrednost med stanji nevronov znotraj jedra. Na ta način zmanjša število nevronov v naslednji plasti in nevronska mreža se je primorana učiti posploševanja vzorcev, ki jih dobi na vhodu nevronske mreže. Na sliki 1 vidimo, da je možno dimenzije plasti nevronov tudi povečevati. To storimo z operatorjem transponirane konvolucije, ki deluje podobno kot običajna konvolucija, saj se spremeni samo pomen parametra korakanja. Ta ne predstavlja več velikosti koraka horizontalnega premika jedra, ampak število dodanih ničel med stanja posameznih nevronov v vhodni plasti. Transponirana konvolucija poskrbi za ustrezno

velikost obleganja vhodnega tenzorja značilnik (tj. dodajanja novih stolpcev in vrstic na robovih tenzorja), tako da postane izhodna plast večja od vhodne.

## Gradientni spust

Vrednosti uteži modela želimo nastaviti tako, da minimizirajo napako napovedi. Napaka modela je funkcija uteži nevronske mreže  $E(w)$ , kjer je  $w$  vektor vseh uteži. Izračunamo jo s pomočjo poljubne odvedljive funkcije  $L$ , za katero velja  $L = L(y, \hat{y}) \geq 0 \forall y, \hat{y}$  in  $L = 0$ , ko  $y = \hat{y}$ . Pri tem smo z  $y$  označili ciljno oz. resnično vrednost, ki jo želimo dobiti kot izhod nevronske mreže, z  $\hat{y}$  pa napoved nevronske mreže. Takšni funkciji rečemo funkcija izgube (angl. *loss function*). Napaka je povprečna vrednost funkcije izgube na podatkovni množici  $S$ :

$$E = \frac{1}{|S|} \sum_{p \in S} L_p,$$

pri čemer  $|S|$  označuje število primerov v podatkovni množici,  $p \in S$  označuje posamezne primere iz  $S$  in  $L_p$  označuje vrednost funkcije izgube na primeru  $p$ . Pogosto izbrana funkcija izgube pri regresijskih modelih, tj. modelih, katerih zaloga vrednosti je kontinuum realnih števil, je vsota kvadratov razlik med modelsko napovedjo  $\hat{y}$  in resnično vrednostjo  $y$  (MSE). V nekoliko modificirani obliki jo za lepši zapis njenega odvoda zapišemo kot

$$L = \frac{1}{2} \sum_j (\hat{y}_j - y_j)^2.$$

V splošnem velja, da v primeru  $\frac{\partial E}{\partial w} > 0$  z večanjem uteži  $w$  večamo tudi napako  $E$ , v primeru  $\frac{\partial E}{\partial w} < 0$  pa z večanjem  $w$  napako manjšamo. Uteži zato popravljamo po enačbi

$$w_{t+1} = w_t - \eta \nabla_w E(w_t),$$

kjer je  $w_{t+1}$  vektor posodobljenih uteži,  $w_t$  vektor uteži pred posodobitvijo,  $\eta > 0$  parameter stopnje učenja (angl. *learning rate*),  $\nabla_w E(w_t)$  pa vektor odvodov funkcije napake po vseh utežeh. Takšno posodabljanje uteži zagotavlja, da se bo napaka na učni množici manjšala.

Če se uteži posodablajo tako, da sledijo smeri največjega gradienta funkcije napake, izračunanega na celotni podatkovni množici, temu algoritmu pravimo gradientni spust. Za učenje modela ConvCastNet uporabimo optimizirano različico algoritma gradientnega spusta, imenovano Adam (Kingma & Ba, 2017). Ta poleg gradientov pri posodabljanju uteži upošteva tudi njihov prvi in drugi moment. Poleg tega med učenjem spreminjamo tudi velikost parametra stopnje učenja. V ta namen uporabimo načrtovanje stopnje učenja ReduceLROnPlateau (ReduceLROnPlateau, 2023) ki deluje tako, da spremlja spremembe funkcije izgube in se za spremembe stopnje učenja odloča na podlagi števila epoh, tj. števila iteracij skozi vso učno množico, v katerih se napoved modela ni izboljšala. Določiti mu moramo mero potrpežljivosti (angl. *patience*) in faktor zmanjšanja stopnje učenja (angl. *factor*). Faktor določa vrednost, s katero pomnožimo stopnjo učenja ob njenem zmanjšanju, tj.  $\eta \rightarrow \eta \cdot \text{factor}$ , potrpežljivost pa določa število epoh brez izboljšav, po katerih stopnjo učenja pomnožimo z izbranim faktorjem. Poleg tega ima na voljo še nekaj dodatnih parametrov, s katerimi lahko dodatno optimiziramo njegovo delovanje. Za učenje modela

smo izbrali mero potrpežljivosti 6, faktor 0,01 in parameter praga zaznavanja sprememb  $10^{-4}$ .

Modificirali smo tudi funkcijo izgube. Eksperimenti so pokazali, da so rezultati učenja boljši pri uporabi funkcije  $L = 0,1 \cdot MSE^{\frac{1}{256}}$ . Pri učenju so v vhodnem tenzorju uporabljena polja pri eni sami časovni instanci, z vključitvijo polj ob večih preteklih časih pa ne pridemo do velike izboljšave napovedi, zato je spomin na grafičnem procesorju boljše uporabljen pri vključitvi večih spremenljivk, kot z dodajanjem časovnih instanc obstoječim spremenljivkam. Učenje izvajamo v treh delih. Najprej 20 epoch model učimo napovedovati naslednji časovni korak, nato 20 epoch model učimo z dvema avtoregresivnima korakoma, za tem pa še 20 epoch s štirimi avtoregresivnimi koraki. Na ta način ga postopno učimo kakovostnega večdnevnega napovedovanja vremena. Pri tem vsakič znova ponastavimo načrtovanje stopnje učenja, zato se ta ciklično spreminja in omogoča modelu, da se izogne lokalnim minimumom funkcije napake. Posamezen korak napovedi opišemo kot

$$X(t+1) = \mathcal{S}^{-1}[\mathcal{M}(\mathcal{S}[X(t)])],$$


kjer je  $X(t)$  tenzor nestandardiziranih spremenljivk ob času  $t$ ,  $\mathcal{S}$  standardizacija podatkov,  $\mathcal{S}^{-1}$  inverzna transformacija standardizacije in  $\mathcal{M}$  model ConvCastNet. Standardizacijo  $\mathcal{S}$  izračunamo prek enačbe

$$X \rightarrow \frac{X - X_{povp}}{X_{std} + \epsilon},$$

kjer je  $X_{povp}$  časovno povprečje,  $X_{std}$  časovna standardna deviacija, izračunana v vsaki točki mreže,  $\epsilon = 10^{-7}$  pa parameter za izboljšavo numerične stabilnosti.

### Arhitektura modela ConvCastNet


Model ConvCastNet je konvolucijski kodirnik, shematsko prikazan na sliki 2.



Slika 2: Skica osnovne arhitekture konvolucijskega kodirnika ConvCastNet. Sestavljen je iz vhodnega in izhodnega tenzorja nevronov ter vmesnih modulov  $M_i$ . V splošnem je lahko modulov poljubno mnogo. Vhodno polje vsebuje  $C_{in}$ , izhodno polje  $C_{out}$ , modul  $M_i$  pa  $C_i$  kanalov. Pri manjšanju ločljivosti med moduli uporabimo operator združevanja maksimalnih vrednosti (max pool), pri večanju pa transponirano konvolucijo (transp conv). Zadnjo plast dobimo iz zadnjega modula s konvolucijo z jedrom velikosti  $1 \times 1$ . Med moduli so tudi preskočne povezave (angl. skip connections).

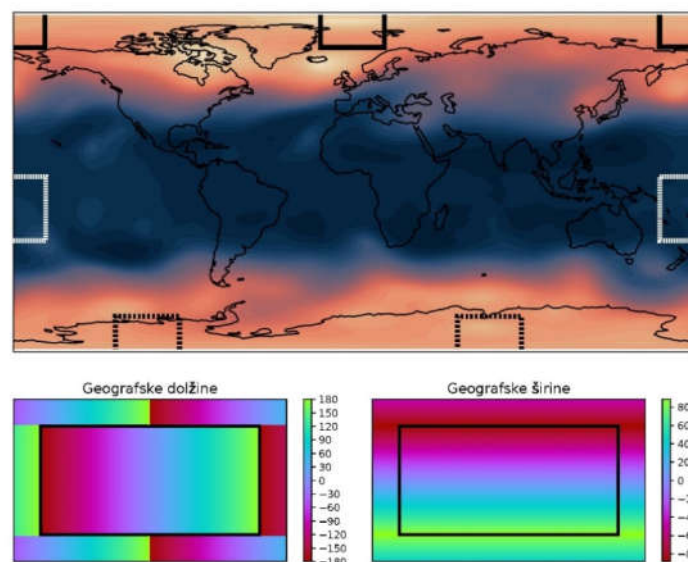


Sestavljen je iz petih modulov v kodirniku in štirih modulov v dekodirniku. Posamezen modul je sestavljen iz štirih zaporednih blokov, katerih zgradba je prikazana na sliki 3. V prvih treh modulih kodirnika in vseh modulih dekodirnika je velikost konvolucijskih jeder  $k_1 = k_2 \equiv k = 7$ , v ostalih pa  $k = 3$ .



Slika 3: Skica osnovnega bloka v modulih. Vhodno polje  $x$  najprej oblegamo (RP-robni pogoji). Nato uporabimo operator konvolucije (Conv) in LeakyReLU aktivacijsko funkcijo, na koncu pa izvedemo še normalizacijo paketov (BN).

Zmanjšanje velikosti konvolucijskega jedra je v modulih  $M_4$  in  $M_5$  uporabljeno zaradi manjše ločljivosti skritih plasti (npr. v modulu  $M_5$  so te velike  $3 \times 7$ ), zaradi česar bi konvolucijsko jedro velikosti  $7 \times 7$  pokrilo velik del ali vso plast nevronov. Posamezna jedra se po vhodnem tenzorju premikajo s korakom velikosti ena. Znotraj modulov so med bloki uporabljene preskočne povezave s skupnim virom (tj. tenzor izhodov prvega bloka je dodan vhodom vseh ostalih blokov znotraj modula), preskočne povezave pa so uporabljene tudi med moduli kodirnika in dekodirnika (tj. tenzorji izhodov modula v kodirnem delu nevronske mreže so dodani vhodom v dekodirnem delu). Število kanalov  $C$  je v vseh modulih enako, saj smo opazili, da imajo uteži kanalov manjši prispevek h končni napovedni zmogljivosti kot tiste, ki jih dobimo s povečanjem velikosti konvolucijskih jeder. Pri tem smo izbrali  $C = 350$ . Med posameznimi moduli kodirnika je uporabljen operator združevanja največjih vrednosti, med moduli dekodirnika pa so uporabljeni operatorji transponirane konvolucije. Oboji uporabljajo jedra velikosti  $2 \times 2$  in korak 2.



Slika 4: Na zgornjem grafu je prikazano, katere podatke bi morala vključevati konvolucijska jedra, da bi pravilno upoštevala sferične robne pogoje. Na spodnjih grafih so označene geografske širine (levo) in dolžine (desno) podatkov, s katerimi moramo obložiti vhodne podatke, da bo nevronska mreža pravilno upoštevala robne pogoje v Zemljini sferični geometriji. Matrika neobleganih podatkov je na njih prikazana s črnim pravokotnikom, obleganje pa je izvedeno na njenih robovih.0

Znotraj vsakega bloka je vhodno polje  $x$  najprej oblegano, tj. na robovih vhodnih polj so dodane vrstice in stolpci, ki poskrbijo, da konvolucijska jedra na robovih prekrivajo ustrezne geografske širine in dolžine, tako da je upoštevana Zemljina sferična geometrija, kot je prikazano na sliki 4. Mejne ploskve matrik se pred obleganjem nahajajo pri geografskih širinah  $\varphi = \pm 88,5^\circ$  in geografskih dolžinah  $\lambda = \pm 180^\circ$ . Posamezna konvolucijska jedra na robovih vhodnih matrik zato nimajo dostopa do ustreznih značilk na drugi strani meja, zaradi česar na teh območjih niso sposobna realistično napovedovati razvoja vremena. Pri prehodu poldnevnik  $\lambda = 180^\circ$  se geografska širina  $\varphi$  ohranja, spremeni pa se geografska dolžina  $\lambda \rightarrow \lambda \pm 360^\circ$ , kjer je predznak odvisen od smeri, iz katere se približujemo robu. Posledično mora ustrezno konvolucijsko jedro na mejnem območju prekrivati tiste elemente matrike, ki jih prikazuje beli črtkani kvadrater. Nekoliko drugače je na območju polov, kjer upoštevamo, da se robne vrstice matrik ne nahajajo na polu, temveč tik pod njim (na  $\varphi = \pm 88,5^\circ$ ). Ob prehodu čez pol se geografska širina ohranja, geografska dolžina pa se spremeni za  $\pm 180^\circ$ . Ustrezna pokritja konvolucijskih jeder so za ta primer na sliki prikazani s črnimi črtkanimi pravokotniki. Kombinacijo obeh pa je treba upoštevati v ogliščih, kjer mora del konvolucijskega jedra prečkati pol, del pa poldnevnik  $180^\circ$ . Konvolucijsko jedro mora v tem primeru prekrivati območje, predstavljeno s črnim pravokotnikom. Ustrezne geografske širine in dolžine podatkov, ki jih moramo oblegati matrikam so prikazane na spodnjih grafih. V enačbi 1 vidimo, da konvolucijsko jedro na  $(i, j)$  tem položaju vhodne matrike s konvolucijo izračuna stanje  $(i, j)$ -tega nevrona izhodne plasti. Sosednje značilke vhodnih polj se torej po konvoluciji preslikajo v sosednje značilke skritih plasti, zato pričakujemo, da bodo tudi v teh bližnji nevroni opisovali bližnje vremenske pojave. Posledično ne oblegamo le tenzorjev vhodnih, ampak tudi skritih plasti.

## Podatki

Osnovo vseh statističnih analiz predstavlja podatkovna množica. Neodvisno od kakovosti izbrane metode bo končen rezultat odvisen od izbire in kakovosti podatkov. Pri učenju nevronske mreže za globalno napovedovanje vremena potrebujemo podatke o stanju celotne atmosfere v daljšem časovnem intervalu, ki bo vseboval kar največji možni nabor različnih stanj ozračja. V ta namen uporabimo rekonstrukcijo stanja atmosfere – t. i. reanalizo. Ta poleg meritev uporabi tudi fizikalni model atmosfere, s pomočjo katerega v končnem rezultatu dobimo časovno rekonstrukcijo meteoroloških polj po celotni atmosferi. To storimo v procesu asimilacije meritev, kjer definiramo cenilko, ki meri odstopanje stanja atmosfere od kratkoročne modelske napovedi in meritev, pri tem pa ovrednoti tudi sistematsko napako satelitskih meritev in upošteva sistematske napake napovednega modela v stratosferi in mezosferi. Nato s pomočjo znanih statistik napak vseh virov cenilko minimiziramo z algoritmom 4D-variacijske asimilacije (Courtier et al., 1994) in tako dobimo najbolj verjetno stanje atmosfere v danem trenutku.

ERA5 reanaliza je peta in trenutno najnovejša reanaliza ECMWF. Izračunana je za vsako polno uro dneva v obdobju med leti 1940 in 2023, pri tem pa je med drugim upoštevano tudi časovno spreminjanje termodinamskega ozadja zaradi naraščajočih koncentracij toplogrednih plinov in zmanjšanih koncentracij ozona, ki vpliva na model sevalnega prenosa toplote in posledično na diabatno gretje v termodinamski enačbi. Spreminja se tudi spodnji robni pogoj, tj. temperatura površine morja in koncentracija morskega ledu. Poleg tega se spreminja tudi število in kakovost upoštevanih meritev, ki so v zadnjih desetletjih veliko bolj številčne in natančne, kot sredi 20. stoletja. Posledično je tudi reanaliza skladno s kvaliteto meritev bolj kakovostna proti koncu prej omenjenega časovnega intervala. Poleg meritev k

napaki reanalize prispeva tudi napaka izračunov modela, ki izvira iz aproksimacije parcialnih diferencialnih enačb z njihovimi diskretnimi različicami, parametrizacija konvekcije, turbulenca v planetarni mejni plasti in še mnogo drugih faktorjev.

Vse uporabljene spremenljivke so navedene v preglednici 1.

Tabela 1: Uporabljene spremenljivke in njihovi višinski nivoji. Temperatura Zemeljskega površja opisuje temperature površja kopnega, morja in ledu.

Spremenljivke	Višinski nivoji
Geopotencial $\phi$ [ $m^2 s^{-2}$ ]	850, 700, 500, 250 [hPa]
Zonalen veter $u$ [ $ms^{-1}$ ]	10 [m], 900, 700, 500, 200 [hPa]
Meridionalen veter $v$ [ $ms^{-1}$ ]	10 [m], 900, 700, 500, 200 [hPa]
Temperatura zraka $T$ [K]	2 [m], 850, 500 [hPa]
Potencialna vrtinčnost $PV$ [ $Km^2 kg^{-1} s^{-1}$ ]	/
Zračni tlak preračunan na nivo morja $p$ [Pa]	/
Vsota padavin [m]	/
Temperatura Zemeljskega površja $T_s$ [K]	/
Sončno obsevanje na vrhu atmosfere [ $Wm^{-2}$ ]	/
Masa vodne pare v stolpcu atmosfere [ $kg m^{-2}$ ]	/
Geografska širina [°]	/
Nadmorska višina [m]	/
Masa kopno-morje []	/

Uporabljenih je 5 enonivojskih in 5 večnivojskih ter 3 statične spremenljivke. Slednje so bile dodane z namenom, da bi modelu olajšali implicitno učenje raznoraznih masnih in energijskih tokov (npr. izhlapevanje vode nad morjem in kopnim) in vremenskih pojavov, povezanih z orografijo in geografsko širino. Teh ne napovedujemo, ampak jih nevronska mreža dobiva samo na vhodu.

Podatki so razdeljena na učno, validacijsko in testno množico (glej tabelo 2).

Tabela 2: Leto začetka in konca podatkov v učni, validacijski in testni množici. Končno leto je vključeno v podatkovno množico.

Množica	Začetek	Konec
Učna	1970	2014
Validacijska	2015	2019
Testna	2020	2022

Na učni množici izvajamo posodabljanje uteži, na validacijski poteka testiranje modela med učenjem, na testni pa testiranje naučenega modela. Končni model izberemo na podlagi najmanjše napake napovedi na validacijski množici, izračunane s seštevkom ACC vseh spremenljivk na nestandardiziranih podatkih. V vhodnih poljih standardiziramo vsako spremenljivko posebej in pri tem ločeno obravnavamo vsako lokacijo. Pri tem uporabimo povprečno vrednost in standardni odklon iz obdobja 1950 - 2014. Podatkov iz validacijske in testne množice med standardizacijo ne upoštevamo, saj bi v tem primeru model nekaj

informacij o novih podatkih imel tudi med testiranjem, zaradi česar bi bili rezultati preveč optimistični.

## Rezultati

### Napovedna zmogljivost

Kakovost vremenskih napovedi se s časom spreminja in je med drugim odvisna od trenutnega dinamičnega stanja ozračja, letnega časa in počasi spreminjajočih se atmosferskih in oceanskih oscilacij, zaradi katerih obstajajo obdobja povečane in zmanjšanje napovedljivosti vremena (Mariotti et al, 2020; Cohen et al., 2019). Posledično se natančnejšo analizo napovedne zmogljivosti izvaja s povprečenjem napak vremenskih napovedi, izvedenih v daljšem časovnem obdobju. Model zato testiramo v testni množici, tako da napoved izvajamo vsak 5. dan in jo povprečimo za vsak dan napovedi posebej. Pri tem uporabljamo metrike površinsko uteženih vrednosti RMSE in ACC. Te izračunamo po enačbah:

$$RMSE = \sqrt{E[c_w(\hat{y} - y)^2]}$$


in

$$ACC = \frac{cov(\hat{y} - y_c, y - y_c)}{\sqrt{var(\hat{y} - y_c) var(y - y_c)}},$$

kjer je  $E$  pričakovana vrednost,  $c_w$  vektor površinskih uteži, ki jih izračunamo po enačbi

$$c_{wi} = \frac{\cos(\varphi_i)}{\frac{1}{N_\varphi} \sum_{j=1}^{N_\varphi} \cos(\varphi_j)},$$

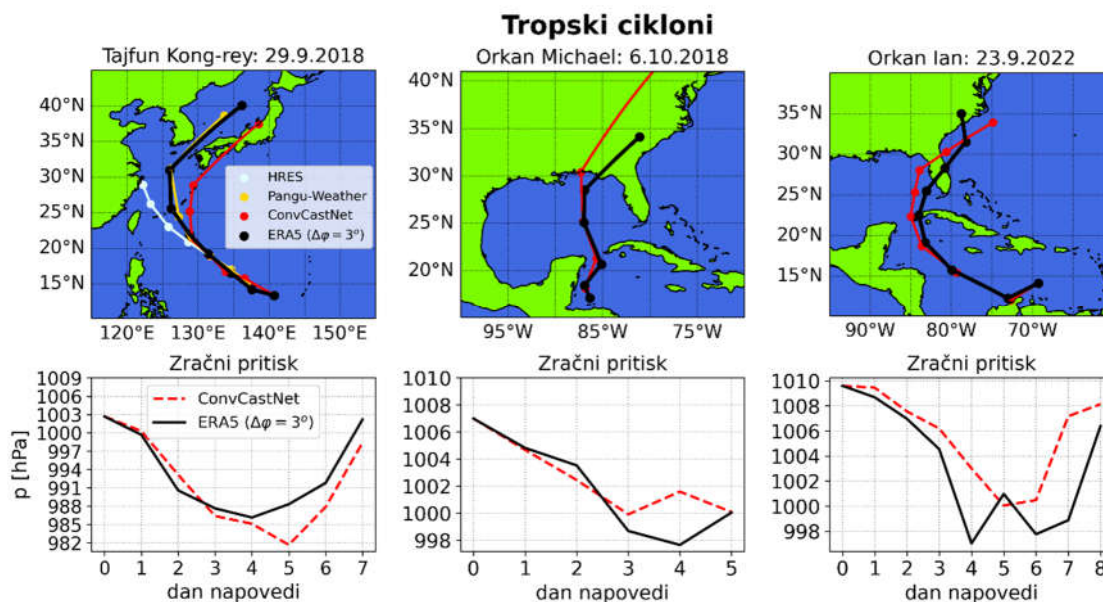
pri čemer  $N_\varphi$  predstavlja število upoštevanih točk v meridionalni smeri (smer sever-jug),  $\hat{y}$  napoved modela,  $y$  resnično vrednost iz ERA5 reanalize,  $y_c$  pa klimatološko povprečje na dan vremenske napovedi, izračunano v obdobju 1950-2014.



Slika 5: Globalna povprečna napaka na površinsko uteženih metrikah RMSE in ACC, izračunana v testni množici.

Površinske uteži upoštevamo tudi v variancah in kovariancah ACC, zato jih izračunamo po enačbah  $var(x) = E[c_w(x - \mu_x)^2]$  in  $cov(x,y) = E[c_w(x - \mu_x)(y - \mu_y)]$ . Rezultati povprečne napovedne zmogljivosti ConvCastNet so za višino geopotencialne ploskve na 500 hPa (z500) in temperaturo zraka na 850 hPa (T850) prikazani na sliki 5. Napako meteoroloških modelov pogosto primerjamo s klimatologijo, tj. napovedjo klimatološkega povprečja, in persistenco, ki privzame, da je stanje ozračja v prihodnosti enako stanju ozračja ob začetku napovedi. Napaka ConvCastNet napovedi je vseh 14 dni precej manjša od napake persistence in pri RMSE metriki več kot 9 dni manjša od napake klimatologije. Rezultati ConvCastNet modela so izrazito boljši od persistence tudi za ostale spremenljivke (ni prikazano), nekoliko slabši pa so pri napovedi vsote padavin, kjer ima že enodnevna napoved precejšnjo napako. Napoved  $z_{500}$  lahko primerjamo tudi z modelom DLWP, ki je analizo izvajal na površinsko neobteženih metrikah, kar njihove vrednosti nekoliko zmanjša. Deterministična napoved DLWP nivo RMSE klimatologije doseže po približno 7,5 dneh, kar je približno 1,5 dni prej, kot ConvCastNet. Ansambelska napoved DLWP pa v prvih 14 dneh ne doseže klimatologije, zato je njegova dolgoročna napoved boljša.


ConvCastNet smo testirali tudi pri napovedovanju poti in intenzitete tropskih ciklonov. Pri tem moramo upoštevati dejstvo, da tako modelska napoved kot ERA5 reanaliza prikazujeta dnevno povprečena in na  $3^\circ$  ločljivost interpolirana polja, zaradi česar tudi vrednosti zračnih tlakov v obeh primerih močno odstopajo od dejanskih, tj. globine ciklonov so močno podcenjene. Razvili smo algoritem za sledenje tropskim ciklonom, katerih središče definiramo v minimumu MSLP. Analizo napovedi smo izvedli na treh različnih tropskih ciklonih, ki so prikazani na sliki 6.



Slika 6: Primerjava napovedi tropskih ciklonov z ERA5 reanalizo. V zgornjih grafih so prikazane napovedane poti središč tropskih ciklonov, pri čemer so v prvem stolpcu prikazane tudi napovedane poti HRES in Pangu-Weather modela, pridobljene iz Bi et al., 2023. Točke so narisane s časovnim razmakom enega dne, pri čemer so za HRES in Pangu-Weather model narisane ob časih 12 UTC. V spodnji vrstici so prikazane vrednosti MSLP v središčih tropskih ciklonov.

Najprej si oglejmo napoved poti tajfuna Kong-rey. Ta je bila izračunana s pričetkom 29. 9. 2018, zato je primerljiva z napovedma modelov Pangu-Weather in HRES [13], ki sta bili inicializirani 30. 9. 2018 ob 00.00 UTC. Ker ConvCastNet napoveduje dnevno povprečna polja, sta napovedi obeh ostalih modelov prikazani ob časih 12 UTC. Najboljšo napoved je izvedel model Pangu-Weather, ki je pravo trajektorijo napovedal vseh 6 dni vnaprej. Pri tem je treba upoštevati, da je primer pridobljen iz njihovega članka (Bi et al., 2023), kjer so ga lahko samostojno izbrali, tako da je njihova napoved dosegla najboljše rezultate. Natančna primerjava množice tropskih ciklonov v letu 2018 je pokazala, da ni signifikantne razlike v kakovosti napovedovanja poti ciklonov med HRES in Pangu-Weather, medtem ko Pangu-Weather bistveno bolj podcenjuje globino ciklonov kot HRES (Ben-Bouallegue et al., 2023). Kakovostni sta bili tudi napovedi HRES in ConvCastNet modelov, ki dejanski trajektoriji pravilno sledita približno 3,5 dni. Za tem HRES tajfun premakne preveč na zahod, ConvCastNet pa na vzhod.

Prikazana je tudi napoved orkana Michael s pričetkom 6. 10. 2018. To lahko primerjamo z napovedjo 100-članskega ansambla modela FourCastNet (Pathak et al., 2022), ki je bila izvedena s pričetkom 7. 10. 2018 ob 00 UTC. V tem primeru je ConvCastNet prve 4 dni boljše sledil dejanski poti orkana kot FourCastNet. Ker sta obe opisani napovedi v našem modelu izvedeni znotraj validacijske množice, smo izvedli še napoved orkana Ian, ki se nahaja znotraj testne množice. Za začetni pogoj smo izbrali 23. 9. 2022, ko se je ta v začetni fazi razvoja nahajal v Karibskem morju. ConvCastNet je tudi v tem primeru pravilno ugotovil premik orkana proti vzhodu in napovedal, da bo ta vplival na zahod Kube in Florido. Na sliki 6 so prikazane tudi napovedane vrednosti MSLP v središčih tropskih ciklonov. Pri tem ponovimo, da se te pri 3° ločljivosti in dnevnem povprečenju precej razlikujejo od dejanskih. V vseh primerih je opaziti korelacijo med napovedanimi in resničnimi poglobitvami oz. oslavitvami tropskih ciklonov.



Slika 7: Prikazane so letno povprečne napake in naravna variabilnost  $z_{500}$  v letu 2022. V prvem stolpcu (a) je prikazana absolutna vrednost povprečne razlike med napovedjo in reanalizo, v drugem stolpcu (b) naravna variabilnost, v tretjem (c) pa z naravno variabilnostjo normirana absolutna vrednost povprečne napake. Izračunane so za 2., 6., 10., in 14. dan napovedi.

Da bi lažje našli izvore napak našega modela, smo izvedli analizo prostorske porazdelitve napak. Na sliki 7a opazimo, da so absolutne napake največje na območjih barokline nestabilnosti. Ker pa se na teh območjih vreme že naravno hitro spreminja, obravnava absolutne vrednosti napake ni merodajna za analizo izvora napak. Absolutne napake spremenljivk zato normiramo z njihovo naravno variabilnostjo, tj. standardnim odklonom od dolgoletnega povprečja za določeni dan v letu. Tako ugotovimo velikost napak relativno na pričakovano hitrost spreminjanja vremena. Povprečne napake napovedi, zagnane vsak peti dan v letu 2022, so za polje  $z_{500}$  prikazane na sliki 7. Polje naravne variabilnosti  $z_{500}$  se zaradi dolgoletnega povprečenja podatkov za obdobje napovedi po dnevih skoraj ne spreminja (slika 7b), pričakovano pa je variabilnost največja v visokih geografskih širinah. Tudi absolutna napaka najhitreje raste na območjih z veliko naravno variabilnostjo, zato se za popolnejši vpogled v izvore napak osredotočimo na normirano napako. V drugem dnevu napovedi opazimo, da je ta največja na območju ekvatorialnega zahodnega Pacifika in Oceanije. Normirana napaka začne po daljšem času napovedi enakomerno naraščati tudi po preostalih območjih planeta in postane največja na območjih ponavljajočih se proženj Rossbyevih valov.


Ogledali smo si tudi spreminjanje globalne normirane napake v obdobju osmih let pred začetkom podatkov učne množice (leto 1970) in obdobju sedmih let po koncu podatkov učne množice (leto 2015) (slika 8). Napaka je izračunana z globalnim povprečenjem letnih normiranih napak 2. dneva napovedi. Pri tem so izračuni ponovljeni vsaka dva meseca, zato da pridobimo boljši vpogled v trend napovedljivosti v izbranih obdobjih. Linearna regresija pri tem pokaže, da se z oddaljevanjem od podatkov učne množice napaka počasi povečuje, kar je skladno s povečevanjem napake napovedi z modelom Pangu-Weather (Ben-Bouallegue et al., 2023). Opazimo pa tudi oscilacije okrog linearnega trenda, ki imajo na izračunanih podatkih podobno periodo kot ENSO, vendar te ne sovpadajo povsem z indeksi ENSO intenzitete (ni prikazano). Napovedljivost je torej odvisna tudi od lokalnega stanja klimatskega sistema. Na podatkih po letu 2015 je ta v povprečju približno 60 % boljša, kot na podatkih starejših ERA5 reanaliz. To je deloma povezano s hiperparametri nevronske mreže (npr. stopnja učenja, velikost konvolucijskega jedra, število kanalov v skritih plasteh,...), ki so bili izbrani za optimizacijo rezultatov v validacijski množici, deloma pa s spremembo lastnosti ERA5 reanalize in klimatskega sistema.

## Razprava in zaključek

Ustvarili smo nov model za globalno srednjeročno napovedovanje vremena ConvCastNet, osnovan na arhitekturi konvolucijskega kodirnika. Razvili smo nov način upoštevanja sferičnih robih pogojev pri ekviangularni matrični reprezentaciji sferičnih podatkov v klasičnih konvolucijskih nevronskih mrežah. Obleganje matrik smo izvajali tako na meteoroloških poljih, kot tudi na izhodih skritih plasti. Pri tem smo upoštevali, da se sosednje značilke vhodnih plasti preslikajo v sosednje značilke izhodnih, zaradi česar so v skritih plasteh tudi kodirani vremenski pojavi blizu skupaj. Ugotovili smo, da se tako model nauči napovedovati razvoj vremena na robovih matričnih polj in da vremenske motnje v tem primeru lahko prehajajo prek njih.

Pri učenju modela smo izbrali optimizator Adam in empirično določili funkcijo izgube, ki pri učenju pripelje do najhitrejše konvergence. Uporabili smo načrtovanje stopnje učenja ReduceLROnPlateau, ki se je med preizkušeni izkazala za najboljšo. Med učenjem smo model testirali na validacijski množici, kjer smo za metriko uporabljali seštevek ACC vseh spremenljivk. Pri analizi napovedljivosti pred obdobjem učne množice in po njem smo pokazali, da je modelska napoved precej boljša v obdobju po letu 2015 kot pred 1970. To

bi lahko nakazovalo na preprileganje modela na novejša podataka ERA5 reanalize ali pa na večjo napako začetnega pogoja starejših ERA5 reanaliz.



Slika 8: Globalna povprečna normirana napaka 2. dneva napovedi z500 za obdobje 2015 - 2022 (a) in 1962 - 1969 (b). S križci so prikazane izračunane vrednosti napake, s polno rdečo črto glajeno povprečje, s črtkano črto pa linearna regresija. Križci so na časovni osi postavljeni v središča obdobj, v katerih so bili izračunani. Med sosednjimi izračuni je dvomesečen časovni korak. Domena vertikalne skale je na grafu (b) dvakrat večja kot na grafu (a).

Poleg tega se nevronske mreže naučijo napovedovati vreme le v razponu atmosferskih stanj, ki jih opisuje podatkovna množica. Sprememb dinamike atmosfere kot posledice sprememb v klimatskem režimu (npr. zaradi antropogenih podnebnih sprememb ali zaradi naravnih večdekadnih klimatskih oscilacij) zato niso sposobne predvideti, kar pa ne velja za fizikalne modele. Ti imajo na tem področju prednost pred statističnimi, saj fizikalni zakoni opisujejo večjo domeno faznega prostora in so zato aplikativni tudi pri napovedih v spremenjeni klimatologiji.

Model ConvCastNet smo učili na desetih dnevno povprečenih atmosferskih, morskih in površinskih spremenljivkah ter treh statičnih poljih, interpoliranih na 3° ločljivost. Pri napovedovanju poti tropskih ciklonov so napovedane poti več dni vnaprej uspešno sledile dejanski. Pri orkanu Michael je bila napoved ConvCastNet primerljiva napovedi modela FourCastNet (Pathak et al., 2022), pri tajfunu Kong-rey pa nekoliko slabša kot HRES in GraphCast (Lam et al., 2023). V vseh primerih pa so napovedi ConvCastNet zaradi dnevnega povprečenja polj, nizke ločljivosti in modelske napake močno podcenile dejansko intenziteto tropskih ciklonov. ConvCastNet je napram dnevno povprečeni ERA5 reanalizi, interpolirani na 3° ločljivost, napovedoval primerljive vrednosti zračnega tlaka. Iz tega sklepamo, da bi lahko z višjo ločljivostjo modela, izvajanjem direktnih vremenskih napovedi (brez dnevnega povprečenja polj) in z manjšim predsodkom zračnih tlakov v učnih podatkih, izboljšali tudi natančnost napovedi intenzitete tropskih ciklonov. To velja tako za model ConvCastNet kot ostale modele strojnega učenja. Težave pri napovedovanju vremena z modeli strojnega učenja povzročata tudi glajenje napovednih polj s časom. To v kombinaciji z nizko ločljivostjo



podatkov onemogoča izvajanje uporabne vremenske napovedi na mezoskalah ali konvektivnih skalah, kjer se pojavlja veliko ekstremnih vremenskih dogodkov, npr. intenzivni frontalni prehodi, nevihte in povezani ekstremni padavinski dogodki, pobočni viharji, vetrovi, vetrovi v tropskih ciklonih ...

Napovedno zmogljivost modela smo testirali na površinsko uteženih metrikah RMSE in ACC in do rezultatov prišli s povprečenjem napak napovedi, inicializiranimi v testni množici. Pri primerjavi rezultatov z ostalimi modeli moramo upoštevati dejstvo, da ConvCastNet zaradi uporabljene nižje ločljivosti in napovedovanja dnevno povprečenih polj podcenjuje napako napovedi, zato rezultati niso povsem primerljivi z ostalimi modeli. Napovedna zmogljivost ConvCastNet je v prvih dneh napovedi boljša od determinističnega in ansambelskega modela DLWP (Weyn et al., 2021), po daljšem času pa ansambelska napoved DLWP privede do manjše napake. ConvCastNet je na podlagi vrednosti ACC po 7 dneh slabši od GraphCast (Lam et al., 2023), FourCastNet (Pathak et al., 2022), Pangu-Weather (Bi et al., 2023), FengWu (Chen et al., 2023) in HRES (IFS), ki jih razvijajo večje kolaboracije v tehnoloških podjetjih in operativnih prognostičnih centrih in imajo pri tem na voljo sisteme z več velikostnimi redi večjo računsko zmogljivostjo.

Z analizo prostorske porazdelitve velikosti napak napovedi  $z_{500}$  smo prišli do zaključka, da je ta največja na območjih, kjer je njihova naravna variabilnost velika. Ta se v polju  $z_{500}$  nahaja na območjih zmernih geografskih širin, kjer prihaja do barokline nestabilnosti. Analizo smo izvedli tudi na napakah, ki so normirane z naravno variabilnostjo. Tako smo ugotovili, da se te pri ConvCastNet najprej pojavijo v tropskih območjih, kasneje pa se napaka močno poveča na območjih večje povprečne baroklinosti ozračja. Zakasnitev povečanja napake v zmernih geografskih širinah bi lahko bila posledica relativno bolj natančno določenega začetnega pogoja v zmernih geografskih širinah ali postopne propagacije napake iz tropov. Za zmanjšanje napake modelske napovedi bi lahko uporabili neekvangularno mrežo, kjer bi točke zgostili na območjih z razgibano orografijo, gosto poselitvijo ali na območjih s pričakovano večjo napako vremenskih napovedi. Namesto ekvangularne bi lahko uporabili tudi reducirano Gaussovsko mrežo ali ikozaedrsko mrežo, tj. mrežo v obliki ikozaedrske prizme, ki ohranja razdalje med točkami na sferi. Tako bi se znebili deformacij meteoroloških polj v ekvangularni mreži, ki v visokih geografskih širinah zaradi povečane hitrosti potovanja vremenskih motenj po matriki morebiti prispevajo k napaki modelskih napovedi. Izbira točk bi lahko temeljila tudi na podlagi lokacij izvajanja atmosferskih meritev, zato bi lahko tudi te vključili v proces napovedovanja vremena ali asimilacije meritev. Pri tem bi lahko bila bolj praktična uporaba grafovskih nevronske mreže, kjer je izbira položajev vozlišč poljubna.

V magistrskem delu smo pokazali, da lahko tudi s konvolucijskimi nevronske mrežami naučimo model za globalno napovedovanje vremena, ki se v nekaterih pogledih primerja z novejšimi modeli strojnega učenja. Ena izmed njegovih največjih pomanjkljivosti je nizka ločljivost njegovih napovedi, zaradi česar te niso neposredno uporabne za napovedovanje ekstremnih vremenskih pojavov z velikim vplivom na družbo, ki se tipično dogajajo na mezoskali. Večina novih modelov strojnega učenja iz literature že uporablja  $0,25^\circ$  ločljivost, zaradi katere lahko napovedujejo tudi vremenske pojave na manjši prostorski skali. Kljub temu se vsi modeli strojnega učenja spopadajo s težavo glajenja napovedanih meteoroloških polj, zaradi česar po daljšem času niso sposobni natančno napovedovati mezoskalnih in konvektivnih ekstremnih vremenskih dogodkov. ConvCastNet poleg tega napoveduje dnevno povprečna meteorološka polja, kar na področju srednjeročnega napovedovanja vremena ni nujno zelo uporabno. Za razliko od fizikalnih numeričnih modelov pa so njegovi izračuni hitri in energijsko veliko bolj učinkoviti. Povečanje ločljivosti in odstranitev dnevnega povprečenja meteoroloških polj bi rezultate morebiti izboljšalo, vendar to pripelje predvsem do izzivov, povezanih z računsko zmogljivostjo strojne opreme. V prihodnje

načrtujemo izvedbo prve 4-D variacijske asimilacije meritev, izvedene izključno na podlagi modelov strojnega učenja. To želimo doseči z združitvijo modela ConvCastNet in modela strojnega učenja za izvedbo 3-D variacijske asimilacije meritev (Melinc in Zaplotnik, 2023). Uspešnost izvedbe asimilacije meritev z modeli strojnega učenja bi lahko imela še večji doprinos k napovedovanju vremena kot optimizacija napovednega modela samega, saj v operativnih centrih za napovedovanje vremena večino računskih zmogljivosti posvečajo pripravi začetnega pogoja, zato bi z vpeljavo metod strojnega učenja morda lahko sprostili veliko računskih moči. Razvili smo torej model strojnega učenja, katerega kombinacija nizke računske potratnosti in zadovoljive napovedne zmogljivosti vzpodbuja k njegovemu nadaljnjemu izpopolnjevanju in uporabi na področju raziskovanja in analize napovedovanja vremena.

## Literatura

- Bauer, P. et al. (2015). The quiet revolution of numerical weather prediction, *Nature* 525, 47-55.
- Ben-Bouallegue, Z. et al. (2023). The rise of data-driven weather forecasting, arXiv:2307.10128.
- Bi, K. et al. (2023). Accurate medium-range global weather forecasting with 3D neural networks, *Nature* 619, 533-538.
- Bonavita, M. (2023). On some limitations of data-driven weather forecasting models, arXiv:2309.08473.
- Bonev, B. et al. (2023). Spherical Fourier Neural Operators: Learning Stable Dynamics on the Sphere, arXiv:2306.03838.
- Charney, J. G. et al. (1950). Numerical Integration of the Barotropic Vorticity Equation, *Tellus* 2, 237-254.
- Chen, K. et al. (2023). FengWu: Pushing the Skillful Global Medium-range Weather Forecast beyond 10 Days Lead, arXiv:2304.02948.
- Cohen, J. et al. (2019). S2S reboot: An argument for greater inclusion of machine learning in subseasonal to seasonal forecasts, *WIREs Climate Change* 10, e00567.
- Courtier, P. et al. (1994). A strategy for operational implementation of 4D-Var, using an incremental approach, *Quarterly Journal of the Royal Meteorological Society* 120, 1367- 1387.
- Dueben, P. D. & Bauer, P. (2018). Challenges and design choices for global weather and climate models based on machine learning, *Geosci. Model Dev.* 11, 3999–4009.
- ECMWF, IFS Documentation CY43R3 - Part III: Dynamics and numerical procedures, <https://www.ecmwf.int/en/elibrary/80319-ifs-documentation-cy43r3-part-iii-dynamics-and-numerical-procedures> (1.12.2023) .
- Goodfellow, I. et al. (2023). *Deep Learning* (MIT Press, 2016) book in preparation for MIT Press.
- Hersbach, H. et al. (2020). The ERA5 global reanalysis, *Quarterly Journal of the Royal Meteorological Society* 146, 1999-2049 .
- Keisler, R. (2022). Forecasting Global Weather with Graph Neural Networks, arXiv:2202.07575.
- Kingma, D. P. & Ba, J. (2017). Adam: A Method for Stochastic Optimization, arXiv:1412.6980.
- Kochkov, D. et al. (2023). Neural General Circulation Models, arXiv:2311.07222.
- Lam, R. et al. (2023). Learning skillful medium-range global weather forecasting, *Science* 0.
- Mariotti, A. et al. (2020). Windows of Opportunity for Skillful Forecasts Subseasonal to Seasonal and Beyond, *Bulletin of the American Meteorological Society* 101, E608–E625.
- Melinc & Zaplotnik (2023). Neural-Network Data Assimilation using Variational Autoencoder, arXiv:2308.16073.
- Pathak, J. et al. (2022). FourCastNet: A global data-driven high-resolution weather model using adaptive fourier neural operators, arXiv:2202.11214.
- Perkan, U. (2023): Napovedovanje vremena s konvolucijskimi nevronskimi mrežami (Weather forecasting with convolutional neural networks). Master's thesis, Univerza v Ljubljani, FMF (in Slovenian).

- Rabier, F. (2023). The AIFS is launched. <https://www.ecmwf.int/en/newsletter/177/editorial/aifs-launched> (20.11.2023) .
- Rasp, S. et al. (2018). Deep learning to represent subgrid processes in climate models, PNAS 115, 9684-9689.
- Rasp, S. et al.. (2023). WeatherBench 2: A benchmark for the next generation of data-driven global weather models, arXiv:2308.15560.
- ReduceLRonPlateau (2023). [https://pytorch.org/docs/stable/generated/torch.optim.lr\\_scheduler.ReduceLRonPlateau.html](https://pytorch.org/docs/stable/generated/torch.optim.lr_scheduler.ReduceLRonPlateau.html) (21.11.2023).
- Richardson, L. F., Lynch, P. (1922). Weather Prediction by Numerical Process, Cambridge University Press.
- Weyn, J. A. et al. (2019). Can Machines Learn to Predict Weather? Using Deep Learning to Predict Gridded 500-hPa Geopotential Height From Historical Weather Data, Journal of Advances in Modeling Earth Systems 11, 2680-2693.
- Weyn, J. A. et al. (2021). Sub-Seasonal Forecasting With a Large Ensemble of Deep-Learning Weather Prediction Models, Journal of Advances in Modeling Earth Systems 13 .
- Wolpert, D. H. & Macready, W. G. (1997). No free lunch theorems for optimization, IEEE Transactions on Evolutionary Computation 1, 67-82.



# Emulacija variacijske asimilacije meritev pri napovedovanju vremena z variacijskim avtokodirnikom

Boštjan Melinc\*, Žiga Zaplotnik\*\*

## Povzetek

Variacijska asimilacija je pogosto uporabljena metoda za določitev začetnih pogojev za numerično napoved vremena. Metoda določa cenilko, ki upošteva prejšnjo vremensko napoved in nedavne meritve ozračja, upoštevajoč njihove napake, z minimizacijo te cenilke pa dobimo optimalni začetni pogoj, analizo. V članku predstavimo predelavo tradicionalne tridimenzionalne variacijske asimilacije (3D-Var), tako da se minimizacija njene cenilke izvede v reduciranem latentnem prostoru variacijskega avtokodirnika (VAE) namesto v polnem fizičnem prostoru modelskih točk. Za primer preproste persistenčne napovedi v latentnem prostoru demonstriramo, da je njej pripadajoča kovariančna matrika napake ozadja kvazidiagonalna. Z eksperimenti asimilacije posameznih psevdomeritev pokažemo, da ista kovariančna matrika napake ozadja za naš asimilacijski postopek ustrezno opiše tako ravnovesja v tropih, kot v zmernih geografskih širinah, poleg tega tudi ustrezno prenese vpliv merjene fizikalne količine na njej sklopljeno fizikalno količino. Ocenjena napaka ozadja v fizičnem prostoru je odvisna predvsem od letnega časa, nekoliko pa tudi od trenutnega stanja atmosfere. Z boljšim prognostičnim modelom bi lahko svojo metodo razširili na 4D-Var.

**Ključne besede:** asimilacija meritev, nevronske mreže, variacijski avtokodirnik, kovariančna matrika napake ozadja, 3D-Var, inkrement analize

**Keywords:** data assimilation, neural networks, variational autoencoder, background-error covariance matrix, 3D-Var, analysis increment

## Uvod

Od prvega zapisa diferencialnih enačb za dinamiko atmosfere (Bjerknes, 1904) in uspešne vremenske napovedi z njihovo integracijo (Charney in sod., 1950) temelji operativno napovedovanje vremena na numeričnem reševanju fizikalno pogojenih parcialnih diferencialnih enačb. Dueben in Bauer (2018) sta pred vsega petimi leti kot prva omenila možnost napovedovanja vremena z nevronskimi mrežami (NN), ki nimajo nobene eksplicitno podane informacije o fiziki atmosfere, temveč njihova napoved temelji zgolj na učenju preslikav med polji atmosferskih spremenljivk, ki so nekaj ur (npr. 3, 6, 24 ur) narazen. Vremensko napoved torej dobimo avtoregresivno s serijo takšnih preslikav. Zaradi dostopnosti kvalitetnih podatkov (npr. reanaliz, tj. rekonstrukcij vremena za nazaj s sodobnimi numeričnimi modeli) za učenje tovrstnih modelov je sledil ekstremno hiter razvoj tovrstnih modelov, ki so v vsega štirih letih dosegli enak napredek v kvaliteti svoje napovedi kot klasični numerični modeli v več desetletjih, s koncem leta 2022 pa je bil objavljen prvi model (Bi in sod., 2023), ki je po nekaterih objektivnih metrikah (koren povprečne napake in anomalni korelacijski koeficient za številne fizikalne količine) dosegel najboljše sodobne deterministične numerične modele.

---

\*Univerza v Ljubljani, Fakulteta za matematiko in fiziko, Jadranska ul. 12, Ljubljana

\*\*Evropski center za srednjeročne vremenske napovedi (ECMWF)

Največja težava trenutnih napovednih modelov z NN je njihovo glajenje izhodnih polj, s čimer se izgubi njihova uporabnost za operativno napovedovanje vremena. Modeli nevronske mreže tako na primer dobro napovedo pot tropskega ciklona, vendar močno podcenjujejo njegovo globino in posledično vetrove v njegovem središču (Bouallegue in sod., 2023). Prav tako podcenjujejo divergentno komponento horizontalnega vetra, ki v ozračju spodbuja vertikalna gibanja in padavine. S časom so tako modelske padavine vedno šibkejšje (Bonavita, 2023). Kljub vsemu klasični dinamični eksperimenti prilagajanja ozračja na umetno vnesene motnje, torej eksperimenti, ki se v učni množici ne nahajajo, jasno pokažejo, da se modeli nevronske mreže naučijo realistične fizike (Hakim in Masanam, 2023).

Druga težava trenutnih napovednih modelov z NN je v samostojni pripravi začetnih pogojev za izračun napovedi - te namreč še vedno jemljejo iz operativnih vremenskih centrov. Slednji izračunajo najboljši približek trenutnega stanja atmosfere, ki služi kot začetni pogoj za naslednjo napoved, z *asimilacijo meritev*, v kateri statistično objektivno združijo predhodno kratkoročno napoved stanja atmosfere z novimi meritvami (Kalnay, 2003; Lahoz in Schneider, 2014). Kljub temu da so meritve običajno precej natančne, same po sebi ne zadoščajo za pripravo začetnega pogoja, saj jih je premalo, poleg tega so v prostoru neenakomerno razporejene in nekaterih atmosferskih spremenljivk sploh ne moremo pomeriti neposredno.

*Variacijska asimilacija* je ena izmed najpogostejših metod za asimilacijo meritev v operativnih centrih (uporabljajo jo npr. na Evropskem centru za srednjeročne vremenske napovedi (ECMWF, 2023)). Njena tridimenzionalna verzija (3D-Var) temelji na izračunu najverjetnejšega stanja atmosfere preko metode največjega verjetja (angl. *maximum likelihood approach*) ob predpostavki, da so predhodna kratkoročna napoved (zanjo bomo uporabili izraz *ozadje*) in nove (sočasne) meritve med seboj neodvisne ter da za oboje veljajo gaussovske lastnosti (Kalnay, 2003). To metodo se lahko razširi na 4D-Var, ki upošteva meritve, ki so veljavne ob različnih časih, vanjo pa mora biti vključen tudi model za razvoj stanja atmosfere v času.

V tem delu se bomo osredotočili na izvedbo variacijske asimilacije v latentnem prostoru variacijskega avtokodirnika (VAE). Zaradi izjemne računske potratnosti (več v poglavju *3D-Var v latentnem prostoru*) se stanje atmosfere pri klasični asimilaciji običajno transformira v manjši prostor z določenimi analitičnimi predpostavkami (Bannister, 2008b). Slednje pogosto temeljijo na poenostavitvah atmosferske dinamike, ki imajo omejeno aplikativnost. Zato je ideja naše metode zamenjava analitičnih transformacij z nevronske mreže, ki bi se sama naučila optimalne transformacije iz stanja atmosfere v *fizičnem prostoru* v manjši *latentni prostor*, ter v nasprotni smeri.

Doslej je bilo v literaturi predstavljenih zelo malo primerov o asimilaciji meritev v latentnem prostoru, dobljenem z NN. Mack in sod. (2020) so predstavili teoretični algoritem za 3D-Var v latentnem prostoru standardnega avtokodirnika (AE), ki pa ima nekaj omejitev. Število meritev mora biti enako dimenziji latentnega prostora ali pa je treba meritve interpolirati v latentni prostor, kar storijo z dodatno NN za interpolacijo opazovanj. To je smiselna rešitev za primer, ko je za asimilacijo vedno na voljo enako število opazovanj na istih lokacijah, nikakor pa ne za numerično napovedovanje vremena, kjer število opazovanj in njihova lokacija vseskozi varira, kar bi pomenilo vnovični trening NN za vsako novo postavitev. Tej težavi so se izognili Peyron in sod. (2021), ki so implementirali Kalmanov filter v latentnem prostoru AE za Lorenzov '96 model. Implementacijo Kalmanovega filtra v latentnem prostoru AE za bolj praktičen primer so izvedli Amendola in sod. (2021), in sicer za asimilacijo meritev v modelu onesnaženosti zraka v zaprtem prostoru, kjer so znova lahko predpostavili konstantno število meritev (ves čas so imeli na voljo meritve iz sedmih senzorjev). Prvi primer asimilacije z nevronskimi mrežami za napovedovanje vremena sta

predstavila Melinc in Zaplotnik (2024) za asimilacijo meritev temperature na tlačni ploskvi 850 hPa. Njun pristop se lahko uporabi za poljubno število meritev na poljubnih lokacijah brez vnovičnega treniranja nevronske mreže, v tem članku pa ga bomo razširili na asimilacijo meritev v multivariatnem primeru z asimilacijo poljubne količine izmed trojice zonalni veter, meridionalni veter ter geopotencial na tlačni ploskvi 200 hPa.

## Podatki

Ker smo asimilacijske eksperimente izvajali na dveh množicah fizikalnih količin, smo natrenirali dva variacijska avtokodirnika – enega za avtokodiranje temperature na nivoju 850 hPa (T850; v nadaljevanju *univariatni primer*) in enega za avtokodiranje trojice zonalni veter, meridionalni veter ter geopotencial, vse na višini 200 hPa (u200, v200, Z200; v nadaljevanju *multivariatni primer*). Vse podatke za treniranje smo dobili iz reanalize ERA5 (Hersbach in sod., 2020). Za vsako količino smo izračunali njeno dnevno povprečje na njihovi izvorni regularni mreži z resolucijo  $0.25^\circ$ . Slednja ima težave s singularnostmi pri polih, ki predstavljajo težavo za trening nevronskih mrež s konvolucijskimi plastmi (Perkan, 2023), zato smo podatke interpolirali na regularno mrežo z enako resolucijo, vendar brez polov.

Vhodi v nevronske mreže so bili standardizirani, tako da smo jim za vsak posamezen dan v letu odšteli lastno klimatološko povprečje za obdobje 1981-2010 ter jih delili s klimatološkim standardnim odklonom za isto obdobje. Klimatološko povprečje in standardni odklon sta bila računana za vsako točko na mreži in vsak dan v letu posebej.

Podatke smo razdelili na sledeči način: obdobje 1979-2014 je bilo uporabljeno kot množica za trening nevronske mreže, obdobje 2015-2018 kot validacijska množica ter obdobje 2019-2022 kot testna množica.

## Variacijski avtokodirnik

Za razumevanje koncepta variacijskega avtokodirnika (angl. *variational autoencoder*, VAE) najprej razložimo delovanje standardnega avtokodirnika (angl. *autoencoder*, AE). AE je nevronska mreža, katere cilj je na izhodu poustvariti vhod vanjo. Sestavljena je iz dveh delov: kodirnik  $E$  pretvori vhod  $\mathbf{x}^{\text{in}}$  v latentni vektor  $\mathbf{z}$  v prostoru zmanjšane dimenzije (t. i. *latentni prostor*), torej  $\mathbf{z} = E(\mathbf{x}^{\text{in}})$ , dekodirnik  $D$  pa pretvori latentni vektor ponovno v izvorni prostor vhoda (*fizični prostor*), torej  $\mathbf{x} = D(\mathbf{z}) = D(E(\mathbf{x}^{\text{in}}))$ , kjer je  $\mathbf{x}$  izhod iz AE. Za izhod iz popolnega AE bi veljalo  $\mathbf{x} = \mathbf{x}^{\text{in}}$ .

Tako kot AE je tudi VAE sestavljen iz kodirnika in dekodirnika, vendar tokrat kodirnik ne vrne točne vrednosti elementov latentnega vektorja temveč parametre normalnih porazdelitev, iz katerih se te žreba kot (Kingma in Welling, 2022)

$$z_i = \mu_i + \hat{z}_i \sigma_i, \quad \hat{z}_i \sim \mathcal{N}(0, 1), \quad (1)$$


kjer je  $i$  indeks elementa latentnega vektorja,  $\mu_i$  in  $\sigma_i$  sta povprečje in standardni odklon iz kodirnika,  $\hat{z}_i$  pa je izžreban po standardni normalni porazdelitvi. Izžrebani latentni vektor  $\mathbf{z}$  nato vstopi v dekodirnik, izhod iz dekodirnika pa je ponovno v fizičnem prostoru. Zaradi žreba je VAE stohastičen – za dva enaka vhoda bo vrnil dva različna izhoda, ki sta perturbirani verziji vhoda. Če je VAE reprezentativen, je vsak njegov izhod fizikalno smiseln, množica njegovih izhodov pa ima smiselne statistične lastnosti (v našem primeru to pomeni, da mora množica izhodov slediti klimatološkim značilnostim za izbrani datum).

Zaradi stohastičnih lastnosti VAE ima funkcija izgube  $\mathcal{L}$ , ki jo minimiziramo med treniranjem nevronske mreže, dva člena (Kingma in Welling, 2019): *rekonstrukcijski člen*  $\mathcal{L}^{\text{rec}}$  in *regularizacijski člen*  $\mathcal{L}^{\text{reg}}$ , skupaj torej

$$\mathcal{L} = \mathcal{L}^{\text{rec}} + \mathcal{L}^{\text{reg}}. \quad (2)$$

$\mathcal{L}^{\text{rec}}$  je enak edinemu členu v funkciji izgube za AE: njegov cilj je, da je izhod iz nevronske mreže čim bolj podoben vhodu.  $\mathcal{L}^{\text{reg}}$  pa spodbuja stohastične lastnosti VAE (tj. večja  $\sigma_i$ ) in vsiljuje predpisano porazdelitev latentnega vektorja kot celote. Običajno to pomeni, da je porazdelitev vrednosti vseh elementov z čim bolj podobna standardni normalni porazdelitvi (Goodfellow in sod., 2016; Kingma in Welling, 2019).  $\mathcal{L}^{\text{reg}}$  posredno zagotovi tudi gladkost latentnega prostora. To pomeni, da z dekodiranjem dveh latentnih vektorjev, ki sta si relativno blizu v latentnem prostoru, dobimo dve polji v fizičnem prostoru, ki sta si prav tako relativno blizu. To nam omogoča (1) generiranje novih fizikalno smiselnih polj v fizičnem prostoru zgolj z žrebanjem celotnega  $z$  po standardni normalni porazdelitvi; (2) generiranje celotnega ansambla napovedi na podlagi enega samega člana, ki ga pripeljemo na vhod VAE (demonstrirano v Grooms (2021)); (3) asimilacijo meritev s cenilko definirano v latentnem prostoru, kar bomo pokazali v tem članku. Gladkost latentnega prostora je pri asimilaciji meritev glavna prednost VAE pred standardnimi AE. Brez te lastnosti lahko že majhna sprememba latentnega vektorja vodi v velike spremembe polja v fizičnem prostoru (Grooms, 2021), pri asimilaciji meritev pa povzročamo ravno popravke latentnega vektorja.

Arhitektura naše nevronske mreže je prikazana na sliki 1 in temelji na arhitekturi iz Brohan (2022) z nekaj manjšimi prilagoditvami. Pri VAE za T850 je imel latentni vektor  $N = 100$  elementov, za multivariatni primer (u200, v200, Z200) pa smo uporabili  $N = 200$ . Kodirnik je bil večinoma sestavljen iz 2D konvolucijskih, dekodirnik pa 2D transponiranih konvolucijskih plasti, v obeh primerih pa so te plasti vsebovale jedra velikosti  $3 \times 3$ , večanje in manjšanje vmesnih polj pa je bilo doseženo z ustreznim korakanjem teh jeder. V 2D konvolucijskih plasteh je bilo poskrbljeno za oblaganje vmesnih plasti v skladu z robnimi pogoji ob datumski meji in na polih. Na izhodnih plasteh iz kodirnika in dekodirnika je bila uporabljena linearna aktivacijska funkcija, v gosti plasti dekodirnika je bila uporabljena aktivacijska funkcija ReLU, povsod drugod pa ELU. Tehnični pojmi iz tega odstavka so pojasnjeni v Perkan (2023).

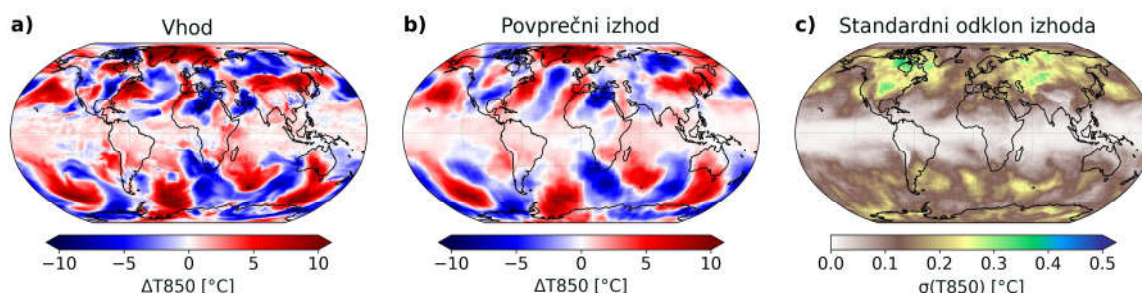


Slika 1: Arhitektura variacijskega avtokodirnika za vhodno polje T850. Vhodno (sivo) polje s  $720 \times 1440$  točkami v zonalni in meridionalni smeri vstopi v kodirnik. Ta z 2D konvolucijskimi plastmi postopno zmanjšuje velikost polja in mu dodaja kanale. Vmesna polja so obarvana modro, številke pod njimi predstavljajo velikost teh polj in število kanalov. Končno polje vstopi v gosto povezano plast (črna puščica) z 200 nevroni, ki predstavljajo po 100 povprečij ( $\mu$ ) in logaritmov varianc ( $\log \sigma^2$ ), tj. po en par  $(\mu_i, \log \sigma_i^2)$



za vsak element latentnega vektorja. Ti elementi so nato žrebani po normalni porazdelitvi s pripadajočimi parametri ( $\mu_i, \log \sigma_i^2$ ) (zeleno črtkane puščice). Vhod v dekodirnik je z gosto povezano plastjo transformiran v polje dimenzije  $45 \times 45 \times 80$ , ki je nato z 2D transponiranimi konvolucijskimi plastmi postopno pretvorjeno (vmesna polja so obarvana rdeče) v izhod (vijolično), ki je enake oblike kot vhod. V multivariatnem primeru (vhodna polja (u200, v200, Z200)) je bilo število kanalov v vmesnih plasteh mreže podvojeno, prav tako je bilo zaradi dvakrat večjega latentnega prostora podvojeno število nevronov na izhodu iz kodirnika in vhodu v dekodirnik. (Prirejeno po: Melinc in Zaplotnik, 2024)

Na sliki 2 je prikazano značilno obnašanje izhoda iz našega VAE. Zaradi boljše preglednosti je namesto T850 risano polje njenih anomalij (tj. odstopanj od klimatološkega povprečja)  $\Delta T850$ . Podobno kot pri številnih poskusih rekonstrukcij vremenskih polj z nevronskimi mrežami (npr. Weyn in sod., 2020) je tudi naše povprečno izhodno polje zglajena verzija vhodnega. VAE dobro opiše prostorske variacije temperature na veliki, sinoptični prostorski skali, variacij na majhnih skalah pa v rekonstruiranem izhodnem polju večinoma ni. Ponekod so opazne pravokotne strukture, ki so posledica konvolucijskih plasti v kodirniku in dekodirniku in bi se jim lahko izognili z uporabo drugačnih plasti. Značilne vrednosti standardnega odklona izhodnega polja so red velikosti manjše od značilnih vrednosti povprečja izhodnega polja in s tem praktično zanemarljive.



Slika 2: (a) Vhodno polje v VAE (predpostavljena resnica za  $\Delta T850$  iz ERA5 reanalize za 15. 4. 2019). (b) Povprečno izhodno polje iz VAE. (c) Standardni odklon izhodnih polj iz VAE. Povprečje in standardni odklon sta računana na podlagi 150 izhodov iz VAE. (Prirejeno po: Melinc in Zaplotnik, 2024)

## Asimilacija psevdomeritev v latentnem prostoru variacijskega avtokodirnika

### 3D-Var v latentnem prostoru

Cilj 3D-variacijske asimilacije (3D-Var) je poiskati čim bolj točen približek dejanskemu stanju ozračja (predstavimo ga z vektorjem  $\mathbf{x}$ ), pri čemer statistično objektivno združimo naše poznavanje atmosfere iz predhodne napovedi (zanj uporabimo izraz *ozadje* in ga označimo z  $\mathbf{x}_b$ ) z opazovanji ( $\mathbf{y}$ ), kar doseže z minimizacijo cenilke (Lorenz, 1986; Kalnay, 2003)

$$\begin{aligned} \mathcal{J}(\mathbf{x}) &= \mathcal{J}_b + \mathcal{J}_o = \\ &= (\mathbf{x} - \mathbf{x}_b)^T \mathbf{B}^{-1} (\mathbf{x} - \mathbf{x}_b) + \{\mathbf{y} - H(\mathbf{x})\}^T \mathbf{R}^{-1} \{\mathbf{y} - H(\mathbf{x})\}, \end{aligned} \quad (3)$$

kjer člen ozadja  $\mathcal{J}_b$  meri razdaljo med stanjem atmosfere in ozadjem, člen opazovanj  $\mathcal{J}_o$  pa meri razdaljo med opazovanji in iskanim stanjem atmosfere, ki ga z operatorjem

opazovanj  $H$  propagiramo v t. i. prostor opazovanj,  $\mathbf{B}$  je matrika kovarianc napak ozadja ter  $\mathbf{R}$  matrika kovarianc napake meritev. Stanju, ki da minimum cenilke (3), pravimo *analiza* ( $\mathbf{x}_a = \arg \min_{\mathbf{x}} \mathcal{J}(\mathbf{x})$ ) in služi kot začetni pogoj za novo napoved vremena, razliki med analizo in ozadjem pa *inkrement analize* ( $\delta\mathbf{x} = \mathbf{x}_a - \mathbf{x}_b$ ).

V operativnem napovedovanju vremena predstavlja glavno težavo pri iskanju minimuma cenilke (3) izračun inverza matrike  $\mathbf{B}$ , saj ima  $\mathbf{x} \sim 10^9$  elementov ter zato  $\mathbf{B}$  dimenzijo  $\sim 10^9 \times 10^9$  in s tem  $\sim 10^{18}$  elementov, kar bi bilo za numerični izračun  $\mathbf{B}^{-1}$  pogubno. Zato se v operativnih centrih zatekajo k transformaciji stanja  $\mathbf{x}$  v reducirano stanje  $\xi$  (transformaciji pravimo *transformacija kontrolnih spremenljivk*, reduciranemu prostoru pa *kontrolni prostor*) z bistveno manjšim številom elementov (Bannister, 2008b, 2021), kar dosežejo z analitičnimi poenostavitvami atmosferskih tokov, npr. z nelinearno ravnotežno enačbo, kvazi-geostrofsko omega enačbo in termodinamskimi ravnovesji (ECMWF, 2023).

Transformacijo stanja  $\mathbf{x}$  v nižje-dimenzionalni prostor lahko dosežemo tudi z nevronske mreže. Za izpeljavo cenilke za 3D-Var potrebujemo predpostavki, da so ozadje in opazovanja med seboj neodvisni ter da je napaka obojih gaussovsko porazdeljena. Nobena izmed teh dveh predpostavk ni kršena, če je ozadje definirano v latentnem prostoru VAE. Zato definiramo 3D-Var cenilko v latentnem prostoru VAE, kjer člen ozadja  $\mathcal{J}_{bz}$  tokrat meri razdaljo med vektorjem stanja atmosfere v latentnem prostoru  $\mathbf{z}$  in ozadjem v latentnem prostoru  $\mathbf{z}_b$ , člen opazovanj  $\mathcal{J}_{oz}$  pa razdaljo med opazovanji  $\mathbf{y}$  in stanjem  $\mathbf{z}$ , ki ga propagiramo nazaj v fizični prostor:

$$\begin{aligned} \mathcal{J}_z(\mathbf{z}) &= \mathcal{J}_{bz} + \mathcal{J}_{oz} = \\ &= (\mathbf{z} - \mathbf{z}_b)^\top \mathbf{B}_z^{-1} (\mathbf{z} - \mathbf{z}_b) + [\mathbf{y} - H\{D(\mathbf{z})\}]^\top \mathbf{R}^{-1} [\mathbf{y} - H\{D(\mathbf{z})\}], \end{aligned} \quad (4)$$

kjer je  $\mathbf{B}_z$  matrika kovarianc napak ozadja v latentnem prostoru,  $D$  je dekodirnik,  $H$  pa v našem primeru predstavlja bilinearno interpolacijo dekodiranega polja na lokacijo opazovanja. Kot v primeru klasičnega 3D-Var dobimo analizo z minimizacijo cenilke (4),  $\mathbf{z}_a = \arg \min_{\mathbf{z}} \mathcal{J}_z(\mathbf{z})$ .

Podobno kot v primeru analitične transformacije v kontrolni prostor smo s premikom minimizacijskega problema v latentni prostor močno olajšali njegovo numerično zahtevnost. Vektor  $\mathbf{x}$  bi že v univariatnem primeru imel  $720 \times 1440 = 1\,036\,800$  elementov, pripadajoča matrika  $\mathbf{B}$  posledično več kot  $10^{12}$  elementov, latentni vektor  $\mathbf{z}$  pa ima 100 elementov in njemu pripadajoča polna matrika  $\mathbf{B}_z$  le še  $10^4$  elementov.

## Postavitev eksperimenta

Shema naših eksperimentov za asimilacijo psevdomeritev v latentnem prostoru VAE je predstavljena na sliki 3. Tako ozadje kot opazovanja smo generirali iz ERA5 reanalize, ki smo jo predpostavili kot absolutno resnico, analizo pa smo dobili z minimizacijo cenilke (4).

Opazovanja za dan  $d$  na izbrani lokaciji smo dobili tako, da smo resnico za ta dan  $\mathbf{x}_t^d$  interpolirali s  $H$  na to lokacijo, nato pa meritvi dodali naključni šum  $\varepsilon_o$ , izžreban iz normalne porazdelitve s povprečjem 0 in standardnim odklonom  $\sigma_o$  ( $\varepsilon_o \sim \mathcal{N}(0, \sigma_o)$ ). Vektor meritev je torej bil

$$\mathbf{y} = H(\mathbf{x}_t^d) + \varepsilon_o. \quad (5)$$

V tem članku so sicer prikazani samo rezultati eksperimentov za študijo vpliva posameznih opazovanj, kjer smo ta raje generirali tako, da smo interpolirani vrednosti iz ozadja za dan  $d$  prišteli konstantni *inkrement opazovanja*  $\delta\mathbf{y}^o$ , torej

$$\mathbf{y} = H(\mathbf{x}_b^d) + \delta\mathbf{y}^o + \varepsilon_o. \quad (6)$$


Zaradi preprostosti smo za ozadje v latentnem prostoru za dan  $d$  predpostavili, da je to enako resnici v tem prostoru za predhodnji dan  $d - 1$ , torej

$$\mathbf{z}_b^d = \mathbf{z}_t^{d-1} = E(\mathbf{x}_t^{d-1}). \quad (7)$$

Običajen izraz za predpostavko o konstantnosti stanja atmosfere je *persistenčni model*. Tudi latentnemu vektorju za ozadje smo dodali naključni gaussovski šum, kjer smo  $\sigma_{bi}$  dobili kot koren  $i$ -tega elementa diagonale matrike  $\mathbf{B}_z$ , povprečje pa iz izhoda iz kodirnika:

$$z_{bi} = \mu_i + \hat{z}_i \sigma_{bi}. \quad (8)$$

Končni rezultat smo dobili iz ansambla asimilacij (EDA, Bonavita in sod., 2012), kjer smo za 150 parov zašumljenih vektorjev opazovanj in ozadja izračunali minimum cenilke (4).



Slika 3: Postavitev simuliranega eksperimenta. (Prirejeno po: Melinc in Zaplotnik, 2024)

### Modeliranje kovariančne matrike napake ozadja v latentnem prostoru

Kovariančno matriko napake ozadja po definiciji dobimo s povprečenjem vnanjega produkta napake ozadja same s seboj preko številnih parov,

$$\mathbf{B} = \left\langle (x_t - x_b) (x_t - x_b)^T \right\rangle, \quad (9)$$

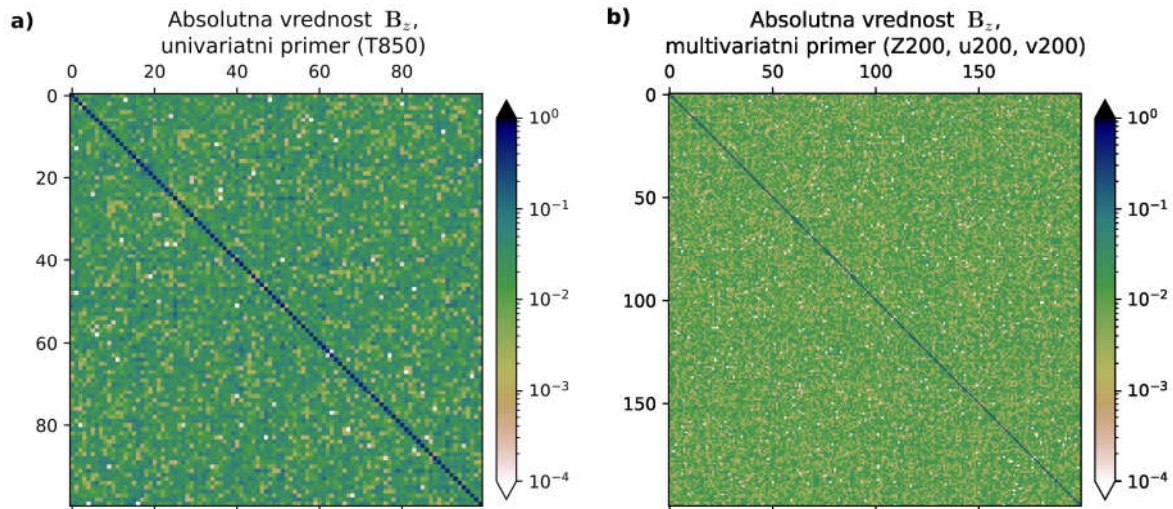
kjer z  $x_t$  označujemo resnično stanje atmosfere. Enačbo (9) lahko za primer, ko je ozadje definirano v latentnem prostoru, prepišemo kot

$$\begin{aligned} \mathbf{B}_z &= \left\langle (z_t - z_b) (z_t - z_b)^T \right\rangle \\ &= \left\langle (z_t^d - z_t^{d-1}) (z_t^d - z_t^{d-1})^T \right\rangle, \end{aligned} \quad (10)$$

kjer smo v drugi vrstici upoštevali naš način modeliranja ozadja (persistenčni model).

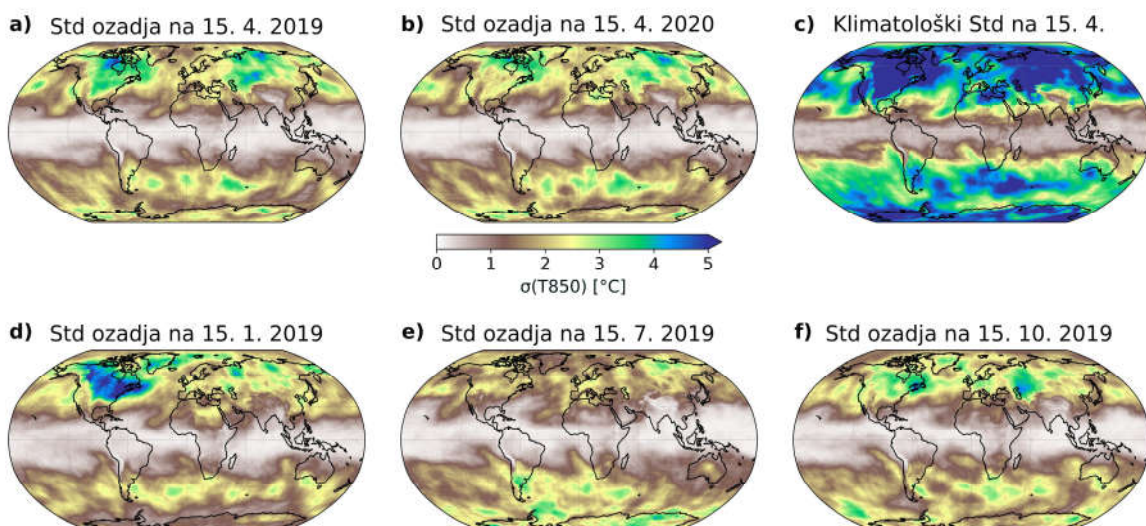
Na sliki 4 sta prikazani matriki  $\mathbf{B}_z$  za univariatni in multivariatni primer, ki smo ju dobili s povprečenjem po celotni validacijski množici in ju nato uporabili pri asimilacijskih eksperimentih. Izračun inverza matrike  $\mathbf{B}_z$ , ki ga potrebujemo pri minimizaciji cenilke (4) bi bil poceni že za polno matriko dimenzije  $100 \times 100$  (oz.  $200 \times 200$ ), vendar se zavedamo, da bi bila v primeru operativnega napovedovanja vremena velikost latentnega prostora zagotovo precej večja. S slike 4 je očitno, da so diagonalni elementi matrike  $\mathbf{B}_z$  precej večji

od izvendiagonalnih, zato smo si že v naših eksperimentih privoščili predpostavko o diagonalni strukturi  $\mathbf{B}_z$ , saj to bistveno olajša izračun njenega inverza. V nekaj korakih smo tako računsko potraten problem obračanja matrike dimenzije  $10^6 \times 10^6$  (oz.  $3 \cdot 10^6 \times 3 \cdot 10^6$ ) poenostavili na izračun obratnih vrednosti vsega stotih (oz. dvestotih) skalarjev.



Slika 4: Matrika  $\mathbf{B}_z$ , dobljena z enačbo (10) s povprečenjem po vseh datumih v množici za validacijo (1. 1. 2015-31. 10. 2018) za (a) univariatni primer in (b) multivariatni primer. (Panel (a) prirejen po: Melinc in Zaplotnik, 2024)

Kljub temu da pri zašumljenju ozadja v latentnem prostoru (enačba (8)) vedno uporabimo isto  $\mathbf{B}_z$  in je zato standardni odklon ozadja v latentnem prostoru ves čas enak, to ne velja za standardni odklon ozadja v fizičnem prostoru  $\sigma_b$ . Na sliki 5 vidimo, da je slednji odvisen predvsem od dneva v letu oz. klimatološkega standardnega odklona za ta dan. To je posledica standardizacije vhoda v VAE, ki je odvisna od dneva v letu. Vendar pa se  $\sigma_b$  zaradi nelinearnosti dekodirnika nekoliko razlikuje tudi na isti zaporedni dan v letu v različnih letih, kar se na panelih (a) in (b) vidi predvsem nad Severno Ameriko in južnim Atlantskim oceanom. Zaključimo lahko, da statična  $\mathbf{B}_z$ -matrika v latentnem prostoru zaradi nelinearnosti dekodirnika opiše v fizičnem prostoru napake ozadja, ki so odvisne od trenutnega stanja ozračja, opisanega z latentnim vektorjem  $\mathbf{z}$ .




Slika 5: Standardni odklon ozadja na različne datume in klimatološki standardni odklon na 15. april. Barvna lestvica na sredini slike velja za vse panele. Standardni odkloni ozadja so bili izračunani na podlagi 150 članov ansambla. (Prirejeno po: Melinc in Zaplotnik, 2024)

## Rezultati

### Asimilacija posamezne meritve v sistemu (T850)

Atmosferska dinamika v tropih se precej razlikuje od dinamike zmernih širin, kar je predvsem posledica Coriolisove sile, ki je odvisna od geografske širine. V zmernih širinah zato na sinoptičnih skalah prevladuje ravnovesje termalnega vetra, ki povezuje vertikalno spreminjanje geostrofskega vetra s horizontalnim spreminjanjem temperature, značilne vzorce na velikih razdaljah pa predstavljajo planetarni Rossbyjevi valovi. V tropih pa prevladuje ravnovesje med vertikalnim vetrom in diabatnim gretjem s kondenzacijo, zato tam povezave na velikih skalah določajo ekvatorialni valovi (Matsuno, 1966). Zato se analitične funkcije, s katerimi bi opisali ravnovesja v  $\mathbf{B}$ -matriki, močno razlikujejo in se v praksi v operativnem napovedovanju vremena upoštevajo samo tista za zmerne širine (Bannister 2008b, 2021; EMCWF 2023). Z naslednjimi primeri bomo pokazali, da  $\mathbf{B}_z$ -matrika smiselno upošteva tako ravnovesja v zmernih širinah kot ravnovesja v tropih.



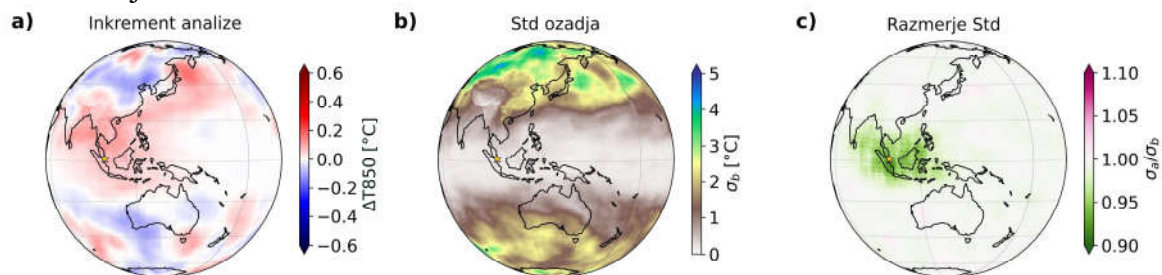
Slika 6: Asimilacija meritve T850 nad Ljubljano z  $\delta y^o=3$  K in  $\sigma_o=1$  K z ozadjem za 15. 4. 2019. (a) Povprečni inkrement analize (tj. povprečna analiza v fizičnem prostoru, ki ji odštejemo povprečno ozadje v fizičnem prostoru). (b) Standardni odklon ozadja v fizičnem prostoru ( $\sigma_b$ ). (c) Razmerje med standardnim odklonom analize in standardnim odklonom ozadja ( $\sigma_a / \sigma_b$ ). Lokacija opazovanja je označena z zlato zvezdo. Asimilacija je bila izvedena za 150 članov ansambla. (Prirejeno po: Melinc in Zaplotnik, 2024)

Opazovanja v univariatnem sistemu (T850) smo generirali po enačbi (6), kjer smo nastavili  $\delta y^o = 3$  K in  $\sigma_o = 1$  K. Na sliki 6 je primer asimilacije meritve v zmernih širinah, in sicer nad Ljubljano. Panel (a) prikazuje inkrement analize. Ta je smiselna zaradi sledečih lastnosti:

1. Ima največjo vrednost v točki opazovanja in relativno veliko vrednost nad celino, kjer je tudi standardni odklon ozadja  $\sigma_b$  nekoliko večji kot nad Sredozemljem (panel (b)), večji  $\sigma_b$  teoretično pomeni manjši vpliv ozadja na analizo, zaradi česar lahko meritev bolj popravi ozadje). Zmanjšanje  $\sigma_b$  nad morjem je značilno za klimatološke  $\mathbf{B}$  matrike zaradi sorazmerno počasnega spreminjanja temperature površine morja, ki vpliva na temperaturo v spodnji troposferi.

2. Območje s pozitivnim inkrementom analize je raztegnjeno v smeri jugozahod-severovzhod, kar pojasnimo z značilnim jugozahodnim vetrom na tem območju in advekcijo z njim.
3. Območje s pozitivnim inkrementom analize obkroža plitkejša območje negativnega inkrementa. To ponovno pojasnimo s klimatološkim izvorom  $\mathbf{B}_z$  matrike, ki pozitivni inkrement opazovanja povezuje s prostorskim premikom planetarnega Rossbyjevega vala (Fisher, 2003).

Amplituda inkrementa analize naprej od območja negativnega inkrementa je zanemarljivo majhna v primerjavi s standardnim odklonom analize. Iz panela (c) lahko sklepamo, da je opazovanje resno vplivalo na analizo zgolj na območju pozitivnega inkrementa, saj samo tam beležimo resen upad razmerja med standardnim odklonom analize  $\sigma_a$  in ozadja.




Slika 7: Kot slika 6, le da je meritev nad Singapurjem.  
(Prirejeno po: Melinc in Zaplotnik, 2024)

Na sliki 7 je primer asimilacije v tropih, in sicer za meritev nad Singapurjem. Za klimatološke  $\mathbf{B}$  matrike je značilno, da je njihov  $\sigma_b$  podcenjen v tropih in precenjen v zmernih širinah (Bannister, 2008a), kar je demonstrirano v panelu (b), posledice tega pa se odražajo v majhni magnitudi inkrementa analize na lokaciji meritve. Tam je namreč  $\sigma_b \approx 0.19$  in s tem  $\sigma_o \gg \sigma_b$ . V zmernih širinah pa je magnituda inkrementa analize kljub oddaljenosti primerljiva z magnitudo na lokaciji meritve. Tam je namreč  $\sigma_o \ll \sigma_b$ , ozadje je torej manj natančno določeno in meritev ga lahko popravi toliko bolj.

V zmernih širinah pa ne pride do njenega upada, kljub temu da je meritev od njih precej oddaljena. Zanimiva je asimetrična oblika inkrementa analize (predvsem raztegnjenost pozitivnega inkrementa proti Japonski in Severni Ameriki), ki spominja na odziv na diabatno segrevanje nad Malajskim otočjem v obliki Rossbyjevega valovnega vlaka (Matsuno, 1966; Gill, 1980; Kosovelj in sod., 2019). Poleg tega je upad  $\sigma_a$  v primerjavi s  $\sigma_b$  rahlo raztegnjen proti vzhodu, kar povezujemo s tipičnimi vzhodnimi vetrovi nad Singapurjem in vzhodno od njega.

Še en primer asimilacije v tropih je predstavljen na sliki 8, kjer je opazovanje generirano vzhodno od obale Ekvadorja. Inkrement analize nad Tihim oceanom se sklada z značilno obliko El-Nino južne oscilacije (ENSO), upad  $\sigma_a$  v primerjavi s  $\sigma_b$  pa je močno razpotegnjen proti zahodu, tj. po celotnem območju spodnje veje vzhodnega krila Pacifiške Walkerjeve cirkulacije.



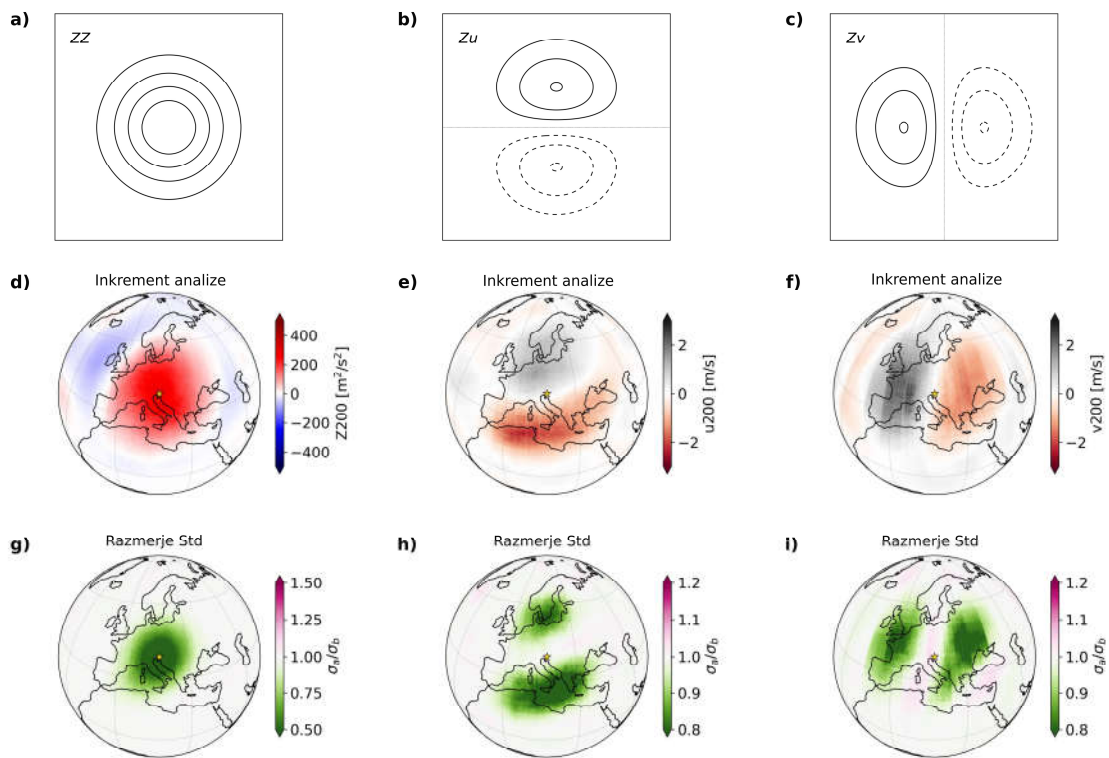
Slika 8: Kot slika 6, le da je meritev vzhodno od obale Ekvadorja.  
(Prirejeno po: Melinc in Zaplotnik, 2024)

Slike 6, 7 in 8 dokazujejo, da z matriko  $\mathbf{B}_z$  dobimo smiselne inkremente analize tako v zmernih širinah kot v tropih. Z drugimi besedami,  $\mathbf{B}_z$  matrika uspešno upošteva tako ravnovesja v zmernih širinah kot ravnovesja v tropih.

#### Asimilacija posamezne meritve v sistemu (u200, v200, Z200)


Spremenljivke v atmosferi so med seboj povezane. Na 200 hPa tlačni ploskvi je v zmernih širinah npr. polje horizontalnega vetra (u200, v200) dobro sklopljeno s poljem geopotenciala (Z200) prek geostrofskega ravnovesja. Podobno kot spremenljivke so med seboj povezane tudi napake teh spremenljivk. Kovariance napak opišemo v matriki  $\mathbf{B}$ . Posledično meritev neke količine v ozračju ne vpliva le na lastno analizo, temveč tudi na analizo ostalih, sklopljenih količin. Pri eksperimentih, opisanih v tem razdelku, smo z VAE predstavili globalna polja (u200, v200, Z200) z enim samim latentnim vektorjem z 200 elementi. V nadaljevanju zato pokažemo nekaj primerov multivariatne asimilacije meritev u200, v200 in Z200 v zmernih širinah.

Najprej na sliki 9 prikažemo primer asimilacije meritve geopotenciala v tem sistemu. V panelih (a), (b) in (c) so narisane korelacijske funkcije sklopljenih polj ob predpostavljene geostrofskem ravnovesju in konstantnem standardnem odklonu ozadja (metodologija je razložena v poglavju 5.4.2 dela Kalnay (2023)). S korelacijskimi funkcijami si lahko med drugim pomagamo pri napovedovanju oblike inkrementa analize po asimilaciji posamezne meritve. Če je inkrement opazovanja Z200 pozitiven (kar velja za primer na tej sliki), potem pozitivna/negativna vrednost korelacijske funkcije v zgornji/spodnji polovici panela (b) napove pozitiven/negativen inkrement analize u200 severno/južno od lokacije meritve Z200. Točno tak odziv je prikazan v panelu (e), medtem ko panel (h) potrjuje, da je vpliv meritve omejen ravno na območji s pričakovanim teoretičnim inkrementom analize. Paneli (a), (d) in (g) potrjujejo tudi ustreznost odziva Z200, paneli (c), (f) in (i) pa ustreznost odziva v200. Rahlo popačenost odzivov v primerjavi s teoretičnimi lahko pripišemo (1) nehomogenosti standardnega odklona ozadja, ki jo predpostavi teorija, in (2) lastnosti nevronske mreže, da prilagodi odziv lokalnim značilnostim območja v bližini meritve. Podobno skladnost rezultatov vidimo tudi v primeru meritve u200 na sliki 10 in v200 na sliki 11.

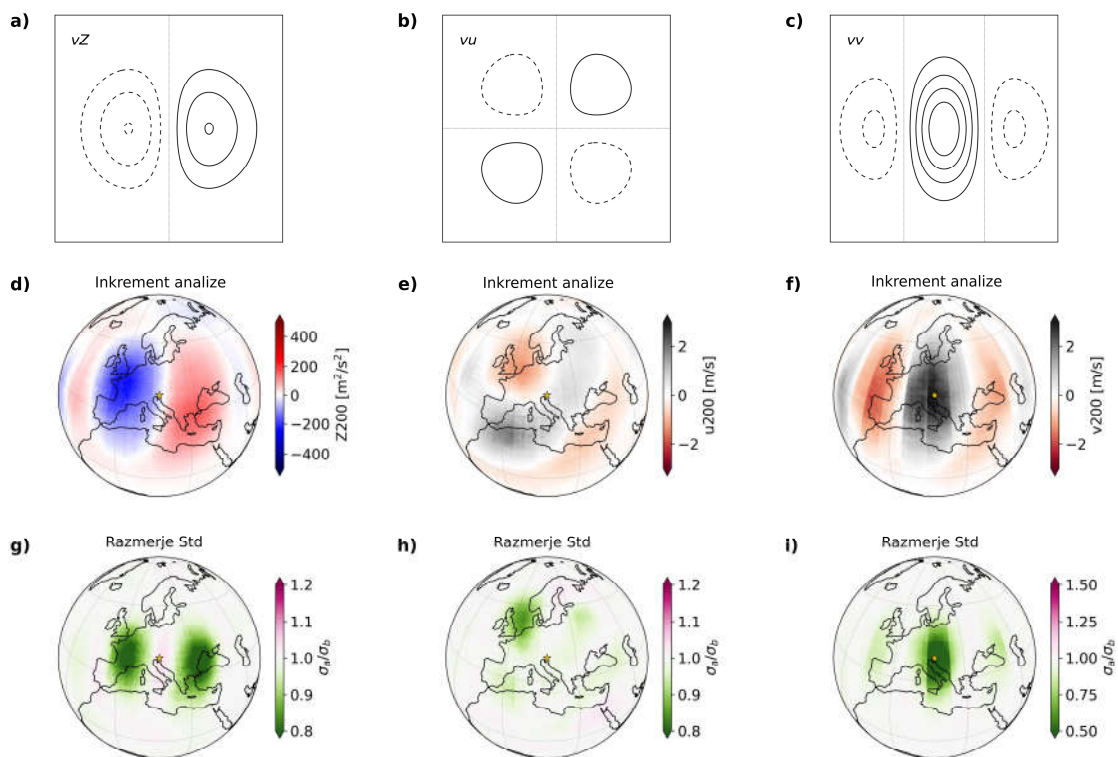


Slika 9: Asimilacija meritve Z200 nad Ljubljano z  $\delta y^o = 300 \text{ m}^2 / \text{s}^2$  in  $\sigma_o = 100 \text{ m}^2 / \text{s}^2$  z ozadjem za 15. 4. 2019. (a, b, c) Pričakovani odziv Z200, u200 ter v200 v primeru meritve Z200 v središču panela. Risane so izolinije korelacijske funkcije ob predpostavki geostrofskega inkrementa s konstantnim standardnim odklonom ozadja (konture pozitivne korelacije so risane s polnimi črtami, negativne s črkanimi črtami, nična korelacija pa s tanko pikčasto črto, korak med izolinijami je 0.2). (d, e, f) Povprečni inkrementi analize Z200, u200, v200. (g, h, i) Razmerje med standardnim odklonom analize in standardnim odklonom ozadja za količine v enakem zaporedju kot pri (a, b, c) in (d, e, f). Lokacija opazovanja je označena z zlato zvezdo. Asimilacija je bila izvedena za 150 članov ansambla.





Slika 10: Kot slika 9, le da za meritev  $u_{200}$  z  $\delta y^0 = 3 \text{ m}^2 / \text{s}^2$  in  $\sigma_0 = 1 \text{ m}^2 / \text{s}^2$



Slika 11: Kot slika 9, le da za meritev  $v_{200}$  z  $\delta y^0 = 3 \text{ m}^2 / \text{s}^2$  in  $\sigma_0 = 1 \text{ m}^2 / \text{s}^2$ .

## Zaključki

V članku smo demonstrirali koncept variacijske asimilacije meritev ozračja z nevronskimi mrežami, tako da smo pokazali množico asimilacijskih eksperimentov z eno samo meritvijo različnih atmosferskih spremenljivk na različnih lokacijah.

Najprej smo s pomočjo podatkov reanalize ERA5 natrenirali kovolucijski variacijski avtokodirnik (VAE), ki smo ga uporabili za predstavitev polj temperature na 850 hPa (T850) v latentnem prostoru, tj. prostoru z močno zmanjšano dimenzijo (sliki 1 in 2). V tem prostoru smo definirali tudi 3D-Var cenilko (4), ki sestoji iz člena ozadja in člena opazovanj. Prvi meri razdaljo med vektorjem nekega stanja atmosfere in vektorjem prejšnje kratkoročne napovedi stanja atmosfere (ozadjem), ki sta oba definirana v latentnem prostoru, drugi pa meri razdaljo med dekodiranim vektorjem iskanega latentnega stanja in opazovanji. Z minimizacijo te cenilke smo dobili statistično optimalno oceno iskanega stanja ozračja, analizo, v latentnem prostoru.

Ključni prednosti VAE pred standardnim AE pri definicijo 3D-Var cenilke v latentnem prostoru sta njegova gladkost in gaussovskost. 3D-Var cenilko (4) smo definirali nekoliko drugače kot pretekle študije (Mack in sod., 2020; Amendola in sod., 2021). Člen opazovanj smo iz vrednotili v prostoru meritev, tako da smo dekodirali latentni vektor v fizični prostor, na katerega deluje operator opazovanj na enak način kot pri klasični cenilki (3). S tem smo se izognili poddeterminiranemu problemu interpolacije meritev v fizični prostor in njegovi težko uporabni alternativni, tj. neposrednemu kodiranju meritev, ki zahteva ponovno treniranje nevronske mreže za vsako spremembo njihove postavitve. Naša metoda torej omogoča asimilacijo meritev ne glede na njihovo število, lokacijo ali natančnost, kar je nujna lastnost za numerično napovedovanje vremena.

Ker je bilo ozadje definirano v latentnem prostoru, smo v tem prostoru definirali tudi matriko kovarianc napak ozadja  $\mathbf{B}_z$  (10), ki smo jo izmerili na enodnevnih razlikah kodiranih polj v časovnem obdobju 2015-2018. Pokazali smo, da je tako definirana  $\mathbf{B}_z$  kvazi-diagonalna. Izvendiagonalni elementi so bili red velikosti manjši od diagonalnih, zato smo uporabili le slednje, kar je dodatno pospešilo minimizacijo cenilke (4). Kljub temu da je matrika  $\mathbf{B}_z$  statična v latentnem prostoru, to ne velja za standardni odklon ozadja v fizičnem prostoru. Pokazali smo, da je slednji močno odvisen od dneva v letu, zaradi nelinearnosti dekodirnika pa tudi od trenutnega stanja atmosfere.

Z eksperimenti, v katerih smo za univariatni primer (T850) asimilirali posamezno meritev (slike 6, 7 in 8), smo pokazali, da matrika  $\mathbf{B}_z$  opiše tako ravnovesja v zmernih širinah kot ravnovesja v tropih, slednjih pa trenutno sistemi za operativno napovedovanje vremena ne upoštevajo.

Avtokodirnik smo naučili tudi predstavitev vektorskega polja horizontalnega vetra na 200 hPa tlačni ploskvi in geopotenciala (u200, v200, Z200), pri čemer smo ustrezno povečali velikost latentnega vektorja. Pokazali smo, da matrika  $\mathbf{B}_z$  uspešno razširi vpliv meritve tako v prostoru v okolici meritve kot tudi na druge količine (slike 9, 10 in 11). Na podlagi teh rezultatov menimo, da bo podoben princip deloval tudi za asimilacijo množice spremenljivk na različnih tlačnih nivojih.

V nadaljnjih raziskavah bomo, poleg razširitve na več tlačnih nivojev, poskusili dodati še količine, ki so v trenutnih prognozičnih modelih znane kot težko napovedljive, npr. intenziteta padavin. Tu se bomo oprli na nevronske mreže iz Perkan (2023), ki napoveduje časovni razvoj petih enonivojskih in petih večnivojskih spremenljivk. To mrežo bomo tudi uporabili za propagacijo naših polj v času, s čimer bomo lahko 3D-Var razširili na 4D-Var, ki lahko upošteva nesočasne meritve. Z ansambelsko napovedjo s 4D-Var bi lahko skonstruirali še napovedni del matrike  $\mathbf{B}_z$ , ki bi bil odvisen izključno od negotovosti trenutnega stanja atmosfere in ne več od klimatoloških značilnosti (Bonavita in sod., 2016).

S tem bi naš pristop zelo približali operativnemu napovedovanju vremena, kjer je matrika **B** sestavljena kot linearna kombinacija klimatološkega in napovednega dela (ECMWF, 2023).

## Literatura

- Amendola, M., Arcucci, R., Mottet, L., Casas, C. Q., Fan, S., Pain, C., Linden, P. in Guo, Y. K.. (2021). Data Assimilation in the Latent Space of a Convolutional Autoencoder. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12746 LNCS:373–386.
- Bannister, R. N. (2008a). A review of forecast error covariance statistics in atmospheric variational data assimilation. I: Characteristics and measurements of forecast error covariances. *Quarterly Journal of the Royal Meteorological Society*, 134, 1951–1970.
- Bannister, R. N. (2008b). A review of forecast error covariance statistics in atmospheric variational data assimilation. II: Modelling the forecast error covariance statistics. *Quarterly Journal of the Royal Meteorological Society*, 134, 1971–1996.
- Bannister, R. N. (2021). Balance conditions in variational data assimilation for a high-resolution forecast model. *Quarterly Journal of the Royal Meteorological Society*, 147, 2917–2934.
- Bi, K., Xie, L., Zhang, H., Chen, X., Gu, X. in Tian, Q. (2023). Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, 619(7970), 533–538.
- Bjerknes, V. (1904). Das Problem der Wettervorhersage, betrachtet vom Standpunkte der Mechanik und der Physik. *Meteorologische Zeitschrift*, 21, 1–7.
- Bonavita, M., Hólm, E., Isaksen, L. in Fisher, M. (2016). The evolution of the ECMWF hybrid data assimilation system. *Quarterly Journal of the Royal Meteorological Society*, 142, 287–303.
- Bonavita, M., Isaksen, L. in Hólm, E. (2012). On the use of EDA background error variances in the ECMWF 4D-Var. *Quarterly Journal of the Royal Meteorological Society*, 138(667), 1540–1559.
- Bonavita, M. (2023). On the limitations of data-driven weather forecasting models. <https://doi.org/10.48550/arXiv.2309.08473>
- Bouallegue, Z. B. in sod. (2023). The rise of data-driven weather forecasting. <https://doi.org/10.48550/arXiv.2307.10128>
- Brohan, P. (2022). Machine Learning for Data Assimilation (v1.0.0). [https://github.com/philip-brohan/Proxy\\_20CR](https://github.com/philip-brohan/Proxy_20CR)
- Charney, J. G., Fjørtoft, R. in von Neuman, J. (1950). Numerical integration of the barotropic vorticity equation. *Tellus*, 2(4), 237–254.
- Dueben, P. D. in Bauer, P. (2018). Challenges and design choices for global weather and climate models based on machine learning. *Geoscientific Model Development*, 11(10), 3999–4009.
- ECMWF (2023). IFS Documentation CY48R1 - Part II: Data Assimilation. IFS Documentation CY48R1, no. 2. ECMWF, Reading, UK.
- Fisher, M. (2003). Background error covariance modelling. *Seminar on Recent Development in Data Assimilation*, p. 45–63. ECMWF, Reading, UK.
- Gill, A. E. (1980). Some simple solutions for heat-induced tropical circulation. *Quarterly Journal of the Royal Meteorological Society*, 106(449), 3759–3777.
- Goodfellow, I., Bengio, Y. in Courville, A. (2016). *Deep Learning*. MIT Press.
- Grooms, I. (2021). Analog ensemble data assimilation and a method for constructing analogs with variational autoencoders. *Quarterly Journal of the Royal Meteorological Society*, 147, 139–149.
- Hakim G. J. in Masanam S. (2023). Dynamical tests of a deep-learning weather prediction model. <https://doi.org/10.48550/arXiv.2309.10867>
- Hersbach, H., in sod. (2020). The ERA5 Global Reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146, 1999–2049.
- Kalnay, E. (2003) *Atmospheric modeling, data assimilation, and predictability*. Cambridge University Press.
- Kingma, D. P. in Welling M. (2019). An introduction to variational autoencoders. *Foundations and Trends in Machine Learning*, 12, 307–392.

- Kingma, D. P. in Welling M. (2022). Auto-Encoding Variational Bayes. <https://doi.org/10.48550/arXiv.1312.6114>
- Kosovelj, K., Kucharski, F., Molteni, F. in Žagar, N. (2019). Modal Decomposition of the Global Response to Tropical Heating Perturbations Resembling MJO. *Journal of the Atmospheric Sciences*, 76(5), 1457–1469.
- Lahoz, W. A. in Schneider, P. (2014). Data assimilation: making sense of Earth Observation. *Frontiers in Environmental Science*, 2, 16.
- Lorenc, A. C. (1986). Analysis methods for numerical weather prediction. *Quarterly Journal of the Royal Meteorological Society*, 112, 1177–1194.
- Matsuno, T. (1966). Quasi-geostrophic motions in the equatorial area. *Journal of the Meteorological Society of Japan*, 44, 25–43.
- Mack, J., Arcucci, R., Molina-Solana, M. in Guo, Y. K. (2020) Attention-based Convolutional Autoencoders for 3D-Variational Data Assimilation. *Computer Methods in Applied Mechanics and Engineering*, 372, 113291.
- Melinc, B. in Zaplotnik, Ž. (2024). 3D-Var Data Assimilation using a Variational Autoencoder. <https://doi.org/10.48550/arXiv.2308.16073>
- Perkan, U. (2023): Napovedovanje vremena s konvolucijskimi nevronskimi mrežami (Weather Forecasting with Convolutional Neural Networks). Master Thesis, Univerza v Ljubljani, FMF, 92 p. (in Slovenian).
- Peyron, M., Fillion, A., Gürol, S., Marchais, V., Gratton, S., Boudier, P. in Goret, G. (2021). Latent space data assimilation by using deep learning. *Quarterly Journal of the Royal Meteorological Society*, 147(740), 3759–3777

# Floods in the SW USA in August and September 2023

## Poplave v JZ delu ZDA v avgustu in septembru 2023

Stanka Šebela<sup>1</sup>, Barbara Luke<sup>2</sup>

### Povzetek

Zaradi orkana Hilary so v JZ delu ZDA razglasili prvo opozorilo v zgodovini. Od 19. do 20. avgusta 2023 je v južni Nevadi padlo 234 mm padavin, kar je nov rekord in predstavlja podvojitve starega rekorda iz leta 1906. Tudi v zveznih državah Montana, Idaho in Oregon so preseгли stare rekorde za okrog 25 mm. Dne 22. avgusta 2023 je bil zaprt tudi dostop do Grand Canyon South Rim, saj je v dveh do treh urah padlo 50 do 76 mm padavin, kar je povzročilo poplavo v kraju Tusayan (Arizona). Obilne padavine so se nadaljevale tudi 1. in 2. septembra, ko je tropska nevihta s 50 do 100 mm dežja na območju Las Vegasa povzročila poplave. Okrog 20 in 30 km JZ od Las Vegasa so v dveh urah zabeležili 81 mm padavin, v 45 minutah kar 60 mm. Zaradi obilnega dežja in naplavin so bili zaprti številni narodni parki kot tudi avtocesta med Las Vegasom in Los Angelesom. Monsunsko deževje v poznem poletju je v JZ delu ZDA sicer reden pojav, vendar se je v avgustu 2023 intenziteta padavin močno povečala, kar pripisujejo klimatskim spremembam in vplivu El Niño.

**Ključne besede:** poplave, puščava, JZ ZDA.

### Abstract

Due to the Hurricane Hilary, the Southwestern United States received its first-ever official hurricane warning. From August 19-20, 2023, as much as 234 mm of precipitation fell in southern Nevada, which is a new record and represents a doubling of the old record from 1906. The states of Montana, Idaho and Oregon also exceeded the old records by about 25 mm. On August 22, 2023, access to the Grand Canyon South Rim was closed as 50-76 mm of rain fell in 2-3 hours, causing flooding in Tusayan (Arizona). Heavy rainfall continued on September 1-2, when a tropical storm with 50-100 mm of rain caused flooding in the Las Vegas area. About 20-30 km SW of Las Vegas, 81 mm of rain was recorded in two hours, 60 mm in just 45 minutes. Due to heavy rain and debris, many national parks were closed as well as the main highway between Las Vegas and Los Angeles. Monsoon rains in late summer in the SW part of the USA are a regular phenomenon, but in August and September 2023 the intensity of precipitation increased significantly, which is attributed to climate change and the influence of El Niño.

**Keywords:** floods, desert, SW USA.

### Introduction

In the framework of the bilateral project ARIS BI-US/22-24-074 "Micro-climatic monitoring in tourist caves, comparison of Grand Canyon Caverns with Slovenian caves" in the period from 17-29 August 2023 we visited UNLV (University of Nevada, Las Vegas). As Hurricane Hilary was approaching the SW part of the USA, we were forced to change the planned field trips and adapt to the extraordinary weather conditions. We witnessed heavy rain and flooding in the otherwise dry desert southwestern part of the USA.

---

<sup>1</sup> Inštitut za raziskovanje krasa ZRC SAZU, Titov trg 2, Postojna

<sup>2</sup> Prof.dr. emerita University of Nevada, Las Vegas, ZDA

Hurricane Hilary, which developed from a weather disturbance south of Mexico, entered the Pacific Ocean on August 12, 2023 from Central America. It was named Tropical Storm Hilary on August 16, 2023, and a Category 4 hurricane on August 17, 2023, with winds of up to 236 km/h. The cyclone weakened to a tropical storm over the next few days and made landfall 345 km S-SE of San Diego on 20 August 2023 (Wikipedia, 2023a).

In the states of Arizona, California, Nevada and Utah, 26 million residents were exposed to bad weather. On August 18, 2023, the National Hurricane Center (NHC, 2023), which was established in 1965, issued its first-ever warning for the desert valleys of Southern California.

Between August 19-20, 2023, the following national parks were fully closed or at least partially closed: Joshua Tree National Park, Death Valley National Park, Mojave National Preserve, Lake Mead National Recreation Area, and Red Rock Canyon National Conservation Area. Portions of I-15, the major highway connecting Los Angeles and Las Vegas, were closed to traffic several times during this period due to flooding.

In the Lee Canyon area (Spring Mountains, Clark County, Nevada, including Mount Charleston (3633 m)), 234 mm of precipitation fell during this period, which is a new record for Nevada and doubles the old record from 1906 (Prociv, 2023). Also, in the Western US states of Montana (old record from 1976), Idaho (old record from 1982) and Oregon (old record from 1976) the rainfall exceeded the old records by around 25 mm in August 2023 (Prociv, 2023).

A tropical storm like Hilary, which brought torrential rain across four states, is unusual and only two similar cases have been recorded in the past. Hurricane Carla produced record rainfall in Iowa, Wisconsin, and Michigan in 1961, and Kathleen produced record rainfall in California, Oregon, and Idaho in 1976. Hurricane Hilary did not exceed the 1976 rainfall record for California, which remains 451 mm (Prociv, 2023).

Heavy rainfall continued in September as a tropical storm dropped 50-100 mm of rain in the Las Vegas area on September 1-2, 2023 (Table 1), flooding many roads especially in the E and S parts of the city. At the hydrological station located 8 km SW of Jean (Figure 1), which is about 20-30 km SW of Las Vegas, 81 mm of precipitation was recorded in two hours, and 60 mm in just 45 minutes (Table 1) (Clemons, 2023).

Table 1. Precipitation in southern Nevada for the period August 19-20, 2023 (after Clemons, 2023).  
Preglednica 1. Količina padavin v južni Nevadi za obdobje 19-20 avgust 2023 (po Clemons, 2023).

	mm (48 h)
Flamingo Wash near Nellis Boulevard, Las Vegas	96
Grapevine Springs 2, 100 km NW of Las Vegas	85
Jean, 20-30 km SW of Las Vegas	84
Las Vegas Wash in Las Vegas	80
Red Rock Canyon, 30 km W of Las Vegas	66
Center of Las Vegas	55

Floods in the metropolitan area of Las Vegas (610 m above sea level, Figure 1), which has more than 2 million inhabitants, threatened its unhoused people, who are said to number at least 1,500 (Signer, 2023). The number of unhoused people is said to have increased in recent years due to the opioid crisis and the corona virus pandemic (Signer, 2023). At least 500 live in more than 100 km of labyrinths and tunnels built under the city to reduce surface

flooding and drain floodwater to the eastern part of the city and into the 19-km long Las Vegas Wash. The Wash carries the majority of stormwater along with treated wastewater from the Las Vegas Valley through wetlands and finally into Lake Mead, a major reservoir on the Colorado River (Torres-Cortez, 2023). The Las Vegas Wash is an urban river, existing at its current extent because of the urban population. The drainage works in a systemic connection with the wetland in Clark County Wetlands Park, which covers 11.7 km<sup>2</sup> in the eastern part of the Las Vegas Valley (Clark County Wetlands Park, 2023).

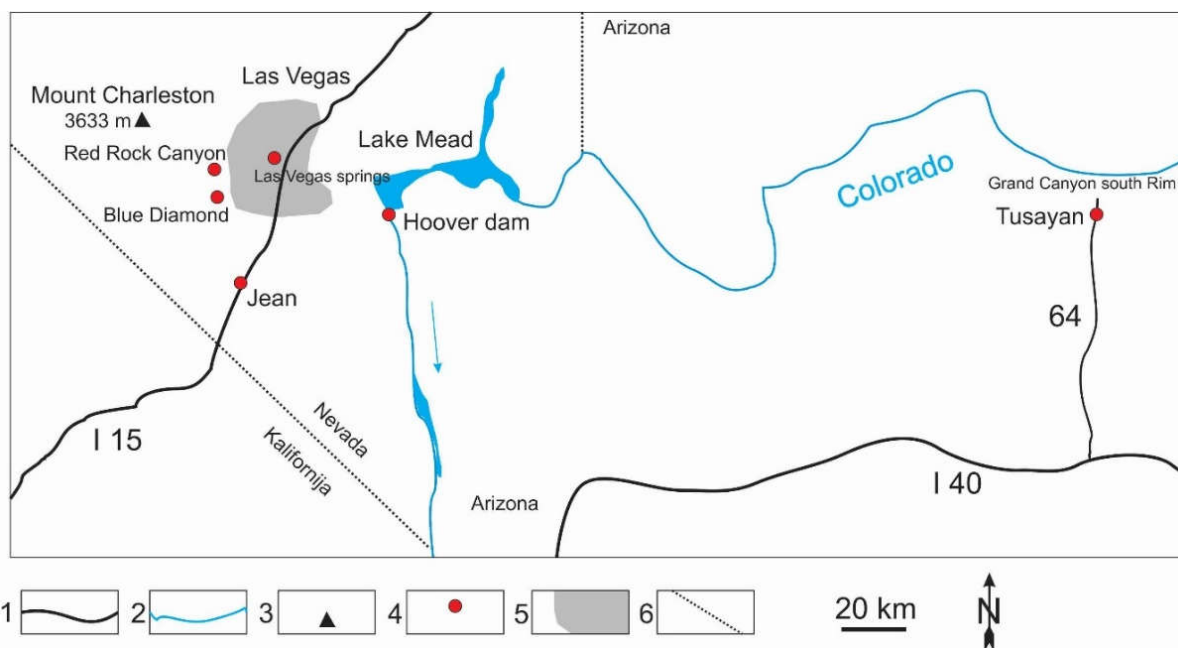


Figure 1 – The territory of Nevada and Arizona in the SW USA, which were visited in August 2023. 1-road, 2-river, 3-mountain top, 4-location described in the paper, 5-city of Las Vegas, 6-state border to the two US states (cartography: S. Šebela)

Slika 1 – Ozemlje Nevade in Arizone na JZ ZDA, ki smo ga obiskali v avgustu 2023. 1-cesta, 2-reka, 3-vrh gore, 4-lokacija opisana v prispevku, 5-mesto Las Vegas, 6-meja med zveznima državama (kartografija: S. Šebela)

### Las Vegas Springs

The name Las Vegas comes from the Spanish meaning grassy meadows. Originally, natural springs flowed in what is today the heart of Las Vegas (Figure 1). The springs ensured the survival of the original inhabitants and became instrumental to exploration and trade routes across the desert landscape. But by 1962 the surface flow stopped due to the lowering of the groundwater level due to the pumping of water to supply the growing local population.

Today, the historic springs area is managed as a park which hosts museums, a botanical garden, hiking trails and historical interpretations (Springs Preserve, 2023), along with a working well field that contributes about 10% of the metropolitan water supply.

### Red Spring – Calico Basin

One active spring area is the BLM's (National Conservation Lands, Bureau of Land Management) Calico Basin, located just a few miles north of the Red Rock Canyon Visitor

Center. There are three permanent springs in the Calico Basin area: Red Spring (Red Spring Picnic Area, 2023), Calico Spring, and Ash Spring. Next to the source of Red Spring, we find a grassy swamp (Figure 2A) with rich animal and plant life. This place was also favorable for the original inhabitants - the Indigenous People who are said to have lived here as early as 6000 years ago, as evidenced by petroglyphs, artifacts and other archaeological remains. Heavy rains during the period August 19-20, 2023 increased the flow of the Red Spring, which was seen as inundated grass (Figure 2B), and brought a lot of debris onto the roads.




Figure 2 – A - Red Spring Calico Basin, August 21, 2023 (photo: S. Šebela), B - Red Spring Calico Basin after heavy rains, August 21, 2023 (photo: S. Bonzanni), C - Red Rocks, August 25, 2023 (photo: S. Šebela), D - Red Rocks, August 21, 2023 (photo: S. Šebela)

Slika 2 – A - Red Spring Calico Basin, 21. avgust 2023 (foto: S. Šebela), B - Red Spring Calico Basin po večjem deževju, 21. avgust 2023 (foto: S. Bonzanni), C - Red Rocks 25. avgust 2023 (foto: S. Šebela), D - Red Rocks, 21. avgust 2023 (foto: S. Šebela)

### Blue Diamond

We spent quite a few days in Blue Diamond (Figure 1), which is a small independent settlement on the way from Las Vegas to the west. It is located in the Red Rock Canyon National Conservation Area, which sees more and more visitors every year. The settlement of around 280 inhabitants lies at an altitude of 1130 m and is located 41 km SW of Las Vegas. It developed in the 1940's as a settlement to support a nearby gypsum mine that has been in operation since 1924 (Blue Diamond Elementary School, 2023), next to Cottonwood Spring (also called Ojo de Cayetana or Pearl Spring), located between the springs in the Spring Mountains and the springs in Las Vegas.

Cottonwood Spring was a rest stop and stop along the Old Spanish Trail, which ran for about 1,100 km, connecting the area around Santa Fe, New Mexico, and southern California. Spanish conquistadors are said to have explored this area in the late 16th century, and merchants used this route intensively in the period 1830-1848 (Weimer Purkey, 1994). Later the route was called the Mormon Road.



Cottonwood Spring, as well as many other springs, was used by Native Americans as well as early settlers of the American West. Today, the spring is used to irrigate a verdant park and for drinking water. The water rights are privately owned.

During periods of heavy rain in Red Rock and the Spring Mountains, the customarily dry streambed that separates the village of Blue Diamond from State Road 159, which passes through the Red Rock Canyon, fill with water (Figure 2C and D and Figure 3A and B).



Figure 3 – A - Blue Diamond, Arroyo road - flood on July 1, 2016 (photo: S. Šebela), B - Blue Diamond, Arroyo road - flood on August 21, 2023 (photo: S. Bonzanni), C - Hoover Dam and Lake Mead on August 24, 2023. We can see the decreased water level in the lake. The Colorado River constitutes the border between Arizona on the E and Nevada on the W (photo: S. Šebela), D - Storm clouds at the Grand Canyon south Rim, August 22, 2023 (photo: S. Bonzanni)

Slika 3 – A - Blue Diamond, Arroyo road - poplava 1. julija 2016 (foto: S. Šebela), B - Blue Diamond, Arroyo road - poplava 21. avgusta 2023 (foto: S. Bonzanni), C - Hoover dam in jezero Mead 24. avgusta 2023, opazimo lahko nivo znižanja vode v jezeru, reka Kolorado je tudi mejna reka med Arizono na V in Nevado na Z (foto: S. Šebela), D - nevihtni oblaki na Grand Canyon south Rim, 22 avgust 2023 (foto: S. Bonzanni)

### Lake Mead

At the beginning of the 20th century, due to the flooding of the Colorado River, the inhabitants of the SW part of the United States began to build a massive dam on the river in order to contain the floods, obtain electricity, and manage water for drinking and irrigation. At least 3,500 workers worked each month on the project, which was begun in 1931 and completed in 1935, and renamed from the original name Boulder Dam to Hoover Dam, in honor of the 31st US President (Weimer Purkey, 1994).

Lake Mead (Figure 3C) with its peak surface area of 640 km<sup>2</sup> represents 90% of the surface water in southern Nevada (Lothead, 2023). Only two percent of the flow of the

Colorado River as it passes through Lake Mead is contractually allocated to southern Nevada (Lothead, 2023). This amounts to 12 m<sup>3</sup>/s which satisfies about 90% of demand for the Las Vegas Valley (Luke et al., 2022).

The Lake Mead reservoir provides water for 25 million people, as well as agricultural and natural ecosystem needs for Nevada, California, Arizona, and northern Mexico (Luke et al., 2022). If the lake was full of water, it would reach an altitude of 374 m and a maximum depth of 162 m. However, the level of the reservoir has been decreasing sharply and in June 2022 reached an altitude of 317 m above sea level, which means a decrease of 56 m from the highest water level, reduction in volume retained by about 70%, and the lowest level since 1936, when it was first filled (Luke et al., 2022).

Flooding in August and early September 2023 made only a minor contribution to the rise in Lake Mead, as 90-95% of the water for the Colorado River comes from snowmelt in mountains far to the north. A rise of the lake level by about 6 m in the period from March to September 2023 is attributed mainly to releases from the upstream Glen Canyon Dam which forms Lake Powell (Lothead, 2023).

## **Grand Canyon**

On August 22, 2023, an interesting adventure awaited us in the Grand Canyon South Rim area, where we went after the main part of Tropical Storm Hilary passed through the Las Vegas area.

In the small town of Tusayan, which has about 600 inhabitants, lies at an altitude of 2,015 m, and is about 9 km from the Grand Canyon South Rim, we experienced a road closure due to flooding. On the afternoon of August 22, 2023, we visited the Grand Canyon National Park, where it rained from time to time, and it was heavily cloudy in the east, which allowed us to take beautiful photos (Figure 3D). When we wanted to return to the motel in Tusayan around 06:00 p.m., the main road through the place was already under water. Since there was not much rain in the area, some people thought it was a leaking water pipe.

In fact, 50-76 mm of rainfall fell within a few hours (2-3 h) in the Coconino Wash area about 10 km east of Tusayan (Sutton et al., 2023), causing flooding on the lowest part of Route 64 which passes through Tusayan. In Tusayan some motels and other infrastructure elements were also flooded, and there was no electricity. The Grand Canyon South Rim exit on Route 64 was closed until 9:30 p.m. on August 22, 2023, when the water receded. The inhabitants of this place did not recollect similar floods.

## **Concluding thoughts**

The so-called monsoon rains in the SW part of the USA are a regular occurrence in the summer and early autumn, but in August 2023 the intensity of precipitation increased significantly, as for the first time since 1965, a tropical storm or hurricane warning was issued for the desert areas of Southern California.

The effect of El Niño on the warming of the Pacific Ocean is estimated to affect the climate of the entire planet. Extreme weather conditions are being recorded in many places around the world: At the beginning of August 2023, Slovenia was hit by its worst weather disaster (Wikipedia, 2023b), as 200 mm of precipitation (150-200 L/m<sup>2</sup>) fell over 12 hours in some places. At the beginning of September 2023, a record amount of precipitation fell in a few hours in parts of Greece. In the same month, the collapse of a dam in Libya caused a disaster of epic proportions after heavy rains. All this demonstrates to us that so-called

hundred-year floods are now occurring more frequently and, very intensively, affecting larger areas.

During our bilateral exchange in Nevada (as well as in the Grand Canyon, Arizona), we received multiple audio and text alerts on our cell phones that more rain and wind were approaching.

Simultaneously with Hurricane Hilary, on August 20, 2023, a magnitude 5.1 earthquake with numerous aftershocks was recorded in Southern California in the vicinity of Los Angeles. The term "hurriquake" appeared on social networks (Wikipedia, 2023a). Although the two events are not related, the earthquake caused a lot of speculation about the connection with the extreme weather.

The personal experience of floods and the adaptation of field work to weather conditions were an interesting experience that, from the point of view of study of natural phenomena on a dynamic planet, complemented the bilateral exchange oriented to karst geology.

### Acknowledgements

The field work was made possible with the help of the bilateral project "Micro-climate monitoring in tourist caves, comparison of Grand Canyon Caverns with Slovenian caves" (ARIS BI-US/22-24-074), with the help of the infrastructure program "Co-financing of the implementation of the international infrastructure project EPOS" (ARIS I0-E017) and the research program "Karst Research" (ARIS P6-0119).

### References

- Blue Diamond Elementary School (2023). <https://www.bluediamondes.com/our-history>, Accessed: 21. 9. 2023
- Clark County Wetlands Park (2023). [https://www.clarkcountynv.gov/government/departments/parks\\_recreation/wetlands\\_park/index.php](https://www.clarkcountynv.gov/government/departments/parks_recreation/wetlands_park/index.php) Accessed: 21. 9. 2023
- Clemons, M. (2023). Wet carpets anyone? Las Vegas Valley's 48-hour rainfall totals, Las Vegas Review-Journal, September 3, 2023. [https://www.reviewjournal.com/local/weather/wet-carpets-anyone-las-vegas-valleys-48-hour-rainfall-totals-2898650/?utm\\_campaign=widget&utm\\_medium=topnews&utm\\_source=homepage&utm\\_term=Wet%20carpets%20anyone%3F%20Las%20Vegas%20Valley%E2%80%99s%2048-hour%20rainfall%20totals](https://www.reviewjournal.com/local/weather/wet-carpets-anyone-las-vegas-valleys-48-hour-rainfall-totals-2898650/?utm_campaign=widget&utm_medium=topnews&utm_source=homepage&utm_term=Wet%20carpets%20anyone%3F%20Las%20Vegas%20Valley%E2%80%99s%2048-hour%20rainfall%20totals), Accessed: 20. 9. 2023
- Lohead, C. (2023). Rainfall and Lake Mead water levels, explained. Las Vegas Review-Journal, September 7, 2023. [https://www.reviewjournal.com/local/local-nevada/rainfall-and-lake-mead-water-levels-explained-2900492/?utm\\_campaign=widget&utm\\_medium=topnews&utm\\_source=homepage&utm\\_term=Rainfall%20and%20Lake%20Mead%20water%20levels%2C%20explained](https://www.reviewjournal.com/local/local-nevada/rainfall-and-lake-mead-water-levels-explained-2900492/?utm_campaign=widget&utm_medium=topnews&utm_source=homepage&utm_term=Rainfall%20and%20Lake%20Mead%20water%20levels%2C%20explained), Accessed: 15. 9. 2023
- Luke, B., Hunt, S., Bailey, J. (2022). Lake Mead Intake No. 3 and Low Lake Level Pumping Station, Nevada. AEG News, 65, 4, 37-46.
- NHC (2023). <https://www.nhc.noaa.gov/>, Accessed: 23. 9. 2023
- Prociv, K. (2023). Four states broke rainfall records because of Tropical Storm Hilary. <https://www.nbcnews.com/news/weather/four-states-broke-rainfall-records-tropical-storm-hilary-rcna101234>, Accessed: 15. 9. 2023
- Red Spring Picnic Area (2023). <https://www.blm.gov/visit/red-spring-picnic-area-0>, Accessed: 15. 9. 2023

- Signer, D. (2023). The misery in the underground of America's glitzy metropolis. The Neue Zürcher Zeitung (or NZZ) August 8, 2023, <https://www.nzz.ch/english/the-misery-of-the-homeless-in-las-vegas-living-in-tunnels-ld.1708954>, Accessed: 23. 9. 2023
- Springs Preserve (2023). <https://www.springspreserve.org/>, Accessed: 23. 9. 2023
- Sutton, J., Salahieh, N., Mascarenhas, L. (2023). Heavy flooding near Grand Canyon's southern rim prompted power outages and over 100 evacuations. CNN 1:25 PM EDT, Wed August 23, 2023. <https://edition.cnn.com/2023/08/23/us/arizona-grand-canyon-tusayan-flooding/index.html>, Accessed: 20. 9. 2023
- Torres-Cortez, R. (2023). 'Never come back': Flooding highlights dangers to homeless living in tunnels. Las Vegas Review-Journal, September 11, 2023, [https://www.reviewjournal.com/local/never-come-back-flooding-highlights-dangers-to-homeless-living-in-tunnels-2902655/?utm\\_campaign=widget&utm\\_medium=latest&utm\\_source=homepage&utm\\_term=%E2%80%98Never%20come%20back%E2%80%99%3A%20Flooding%20highlights%20dangers%20to%20homeless%20living%20in%20tunnels](https://www.reviewjournal.com/local/never-come-back-flooding-highlights-dangers-to-homeless-living-in-tunnels-2902655/?utm_campaign=widget&utm_medium=latest&utm_source=homepage&utm_term=%E2%80%98Never%20come%20back%E2%80%99%3A%20Flooding%20highlights%20dangers%20to%20homeless%20living%20in%20tunnels), Accessed: 23. 9. 2023
- Weimer Purkey, B., Duenbendorfer, E. M., Smith, E. I., Price, J. G., Castor, S. B. (1994). Geologic tours in the Las Vegas area. Nevada Bureau of Mines and Geology Special Publication 16, University of Nevada, Reno, 1-156.
- Wikipedia (2023a). Hurricane Hilary. [https://en.wikipedia.org/wiki/Hurricane\\_Hilary](https://en.wikipedia.org/wiki/Hurricane_Hilary), Accessed: 20. 9. 2023
- Wikipedia (2023b). Poplave v Sloveniji. [https://sl.wikipedia.org/wiki/Poplave\\_v\\_Sloveniji\\_\(2023\)](https://sl.wikipedia.org/wiki/Poplave_v_Sloveniji_(2023)), Accessed: 20. 9. 2023

# Installation of creepmeters on the western Dinaric Faults

## Vgradnja creepmetrov na zahodne Dinarske prelome

Uroš Novak<sup>1</sup>, Roger Bilham<sup>2</sup>

### Abstract

Hall effect creepmeters represent a cost-effective and fairly easy to maintain extensometers that record shallow slip or creep on active faults and are primarily positioned on the world's more seismically active faults with fast deformation rates. As of the year 2022 a project of creep monitoring of the western Dinaric Faults in Slovenia (Idrija, Raša, Predjama) started, with the installment of 3 creepmeters on Idrija and Raša Faults. The aims of the project are to investigate wherever the Dinaric Faults aseismically creep or if the fault segments are locked in the interseismic period. Such insights into the mechanics of Dinaric Faults could potentially improve insights of earthquake hazard in the Dinarides.

### Povzetek

Creepmetri, ki temeljijo na Hall-ovem učinku, predstavljajo ekstenzometre, ki so stroškovno učinkoviti in precej enostavni za vzdrževanje. Instrumenti so namenjeni beleženju plitvih zdrsov ali lezenja, aktivnih prelomov. Povečini so nameščeni na svetovno seizmično bolj aktivnih prelomih z hitrimi stopnjami deformacij. Leta 2022 se je začel projekt spremljanja lezenja zahodnih dinarskih prelomov v Sloveniji (Idrija, Raša, Predjama), s postavitvijo treh creepmetrov na prelomih Idrija in Raša. Cilj tega projekta je raziskati ali zahodni dinarski prelomi aseizmično lezejo oziroma ali so segmenti prelomov zaklenjeni v medseizmičnem obdobju. Takšen vpogled v mehaniko dinarskih prelomov bi lahko potencialno izboljšal razumevanje potresne nevarnosti v Dinarskem gorstvu.

**Ključne besede:** creepmeter, lezenje, premiki prelomov, aktivna tektonika, Dinarski prelomni sistem, Slovenija.

**Keywords:** creepmeter, creep, fault displacements, active tectonics, Dinaric Fault system, Slovenia.

### Fault shallow creep

Laboratory investigations of rock friction indicate that rocks typically display velocity-strengthening behavior under low temperature and normal stress conditions (Blanpied et al., 1991 Lindsey et al., 2014, *passim*). This suggests that the near-surface regions of active faults are prone to experiencing stable sliding or creep during the interseismic period (Lindsey et al., 2014). This hypothesis is supported from numerical simulations of faults controlled by rate-state friction. Even if friction is not inherently velocity-strengthening, these models demonstrate stable sliding at low normal stress (Kaneko et al., 2013, Lindsey et al., 2014).

---

<sup>1</sup> ZRC SAZU Inštitut za raziskovanje krasa, Titov trg 2, Postojna; Univerza v Novi Gorici, Vipavska 13, Nova Gorica

<sup>2</sup> Cooperative Institute for Research in Environmental Sciences at the University of Colorado Boulder, 216 UCB, University of Colorado Boulder campus, Boulder, CO 80309, ZDA

Observations of shallow interseismic creep align with the models and are documented on several seismically active faults (Lindsey et al., 2014). Examples include segments of the San Andreas Fault (the Rodgers Creek Fault, Hayward Fault, Imperial Fault and Superstition Hills Fault) in California, as well as a segment of the North Anatolian Fault (Lindsey et al., 2014) and Eastern Anatolian Fault in Turkey (Bilham et al., 2023). Additionally, some faults exhibit continuous creep across the entire seismogenic layer, such as the northern section of the San Andreas Fault (SAF) near Parkfield (Tong et al., 2013) and a portion of the Haiyuan Fault in China (Jolivet et al., 2013).

However, it's worth noting that such behaviour is not ubiquitous, given that numerous other faults don't experience interseismic creep at the surface (Lindsey et al., 2014). For instance, the Southern San Andreas Fault (SAF; Tong, 2013), the majority of the North Anatolian Fault, and the Altyn Tagh Fault in Tibet exhibit little to no interseismic creep. Because the accumulation of potential seismic moment may be significantly reduced by the occurrence of shallow creep, the latter plays an important role in our understanding of fault mechanics and earthquake hazard (Lindsey et al., 2014, Bilham et al., 2023).

### Creepmeter instrumentation

Each creepmeter installed is an extensometer that uses a 6 mm diameter carbon-fiber rod as a length standard, buried obliquely across the surface trace of an active fault (Fig. 1, 2). The 10–20 m long carbon rod slides within a 2 cm diameter PVC conduit buried 30–50 cm deep across the fault, and one end is fastened rigidly to a buried anodized aluminum quadropod (passive end).

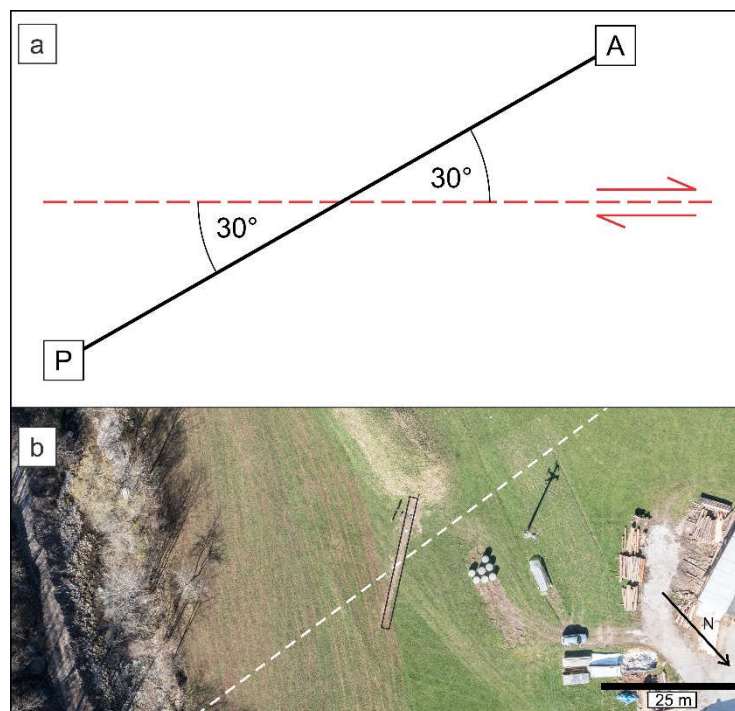


Figure 1: Creepmeter deployment scheme across a fault. a) Idealized diagram of the deployment. b) The rig deployment on the Idrija Fault (photograph author: Žan Kafol).

The free end (active end) of the rod is held in 1 N tension by a 0.1 mm diameter, multistrand, stainless-steel wire wrapped once around the 3.175 mm diameter shaft of a 360°

continuous rotation, Hall effect sensor with a linearity of  $<0.3\%$ . The effective circumference of the shaft including a correction for the thickness of the 19 strand, nylon coated, stainless-steel wire is approximately 10 mm. The free end of the wire is fed by a constant tension spring motor with 1–3 m of range.

Slip on the fault pulls the rod through the conduit, which results in rotation of the shaft of the sensor (Fig. 2). The resulting 0–5 V 12-bit output is recorded by a 16-bit data logger yielding a fault-slip resolution of 2  $\mu\text{m}$  (Bilham and Castillo, 2020). Monotonic slip exceeding 10 mm resets the 0–5 V signal to zero, and hence the creepmeter has a wide cumulative measurement range, and, unless an earthquake with  $>1$  m slip occurs, no adjustments are needed during its lifetime (Bilham and Castillo, 2020).

Extensometers discussed here were installed by two or more people in 3 days using just a shovel and a pick, one site with an excavator. Initial settlement is rapid, and stable readings are usually available within a day of installation. Despite their shallow burial (20–50 cm), temperature effects are small ( $<2 \mu\text{m}=\text{C}=\text{m}$ ) due to the similar expansion coefficients of carbon-fiber composites and surface soils.




Figure 2: Schematic view of the extensometer.

Where telemetry is inadvisable due to potential vandalism, the creepmeter can be totally buried and will operate for a year from disposable alkaline batteries. To conserve power, the autonomous data logger switches the power to the sensor for 0.1 s once per minute. An obliquely installed extensometer is an imperfect measure of fault creep because it assumes that the two sides of the fault act as rigid blocks separated by an infinitely thin fault plane. If the length standard remains straight, fault creep = extension/cos(obliquity). In the extensometers described here, this geometry is approximated by a fault shear zone that after sufficient fault slip has occurred will impose an arctan curve on the initially straight rod. In practice, although the assumption of block-like motion is violated,  $\approx 1\%$  measurement accuracy can be obtained, because fault slip (5 mm) is typically much smaller than the width of the fault zone (e.g., 5 m; Bilham and Castillo, 2020).

Creepmeters often underestimate fault-zone slip because the fault is frequently associated with a shear zone that extends beyond the aperture sensed by the instrument, the deformation zone of the fault is wider than the instrument rig (Bilham and Castillo, 2020). Although the mechanical arrangement described earlier results in a large dynamic range, it comes with a measurement penalty because of frictional components in the sensor that result in stiction. Stiction is a stick-slip instrumental artifact caused by friction between the rod and its conduit, and from the bearings in the Hall sensor and tensioning pulleys. In a newly installed instrument, these effects are observed to be less than 10  $\mu\text{m}$ , and when present occur with time durations of less than 1 s. Offsets occur in the data at the time of downloading due to manual disturbances to the instrument; however, a truck may be driven over the buried instrument without inducing stiction jumps (Bilham and Castillo, 2020).

## Creepmeters on the western Dinaric Faults

Hall-effect creepmeters have been installed in major active seismogenic faults of the world: San Andreas Fault (USA), Eastern and North Anatolian Fault, Chaman Fault (Pakistan), Dead Sea Fault (Israel). All are faults with strong, frequent seismicity and fast deformation rates.

In contrast to western Dinarides, ie. western Dinaric Faults, exhibit moderate instrumental and strong historical seismicity and slow deformation rates of 2-4 mm/year (Serpelloni et al., 2018, Vičić et al., 2019). In order to identify potential shallow creep a project of installing creepmeters on them started in summer 2022. At the moment there are 3 instruments installed.

Two instruments on the Idrija Fault (Fig. 1), and one on the Raša Fault. The micro locations of the instruments were chosen on the basis of paleoseismic trenching and geologic field investigations along with remote sensing techniques. The telemetry-enabled instruments, logging data at 1-minute intervals and transmitting updates every hour, hold the promise of capturing even the subtlest indications of fault creeping activity.

The instrument on the Raša Fault is installed on a fault scarp, identified as a surface rupture via paleoseismological trenching (Aoudia, 2023: unpublished work of ICTP) in colluvial sediments. First instrument on the Idrija Fault was installed in alluvial sediments, identified surface rupture via paleoseismological trenching; Grützner et al., 2021), the second one is installed on a colluvial wedge.

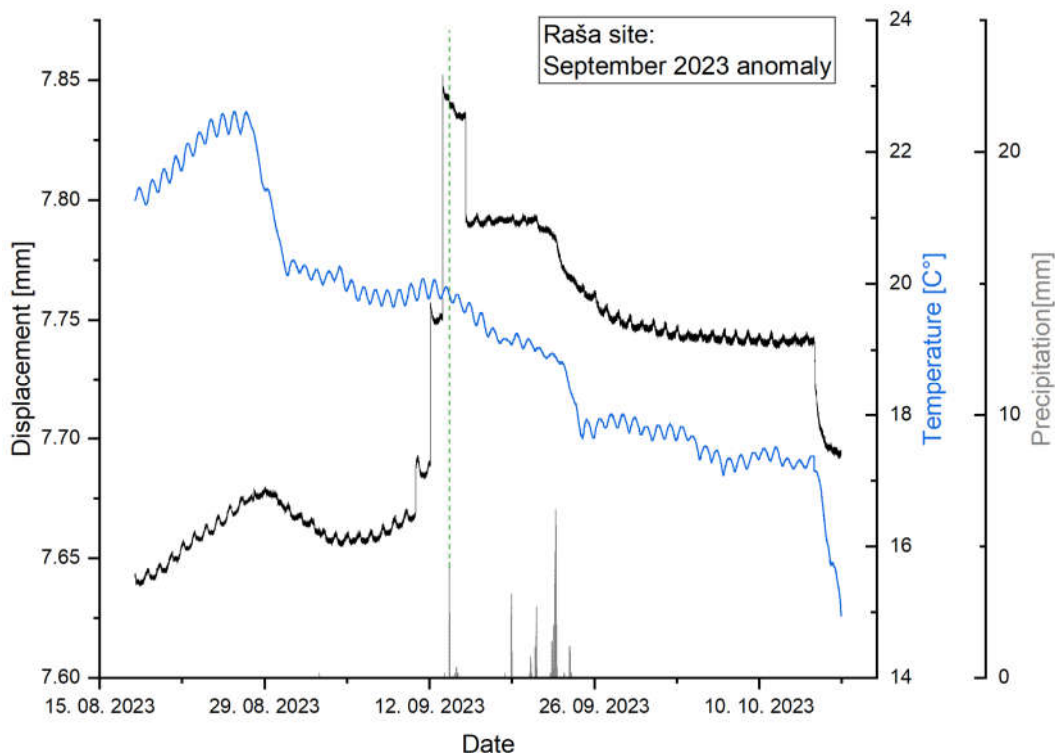


Figure 3: Anomalous displacements in September of 2023. Green dashed line marks the peak precipitation after the anomalous displacement.

The deployment of Hall-effect creepmeters on the western Dinaric Faults marks a crucial step in understanding the seismic behavior and deformation patterns of this region. Although no definitive evidence of creeping behavior has been observed thus far due to the absence of



major seismic events, anomalous displacements unrelated to heavy rainfall or temperature effects suggest the importance of continuous monitoring. As the project progresses, these Hall-effect creepmeters provide invaluable insights into the dynamic geological processes shaping the western Dinarides, contributing to enhanced seismic hazard assessments and the development of more effective risk mitigation strategies in this seismically active region.

The study is carried out within the framework of the Karst Research Programme (P6-0119) and Infrastructure Programme (I0-E017), all financially supported by the Slovenian Research and Innovation Agency and the project operation "Development of research infrastructure for the international competitiveness of the Slovenian RRI space - RI-SI-EPOS" and EC Horizon 2020 project EPOS SP.

## Literature

- Aoudia, A. (2023). Surface ruptures on the Raša Fault; unpublished work of ICTP.
- Bilham, R., Ayruk, T. E., Turğut, M., İrgüren, R., Köküm, M., Elhisso, A., Farımaz, İ., Doğan, U. (2023). Afterslip and triggered slip following the 6 Feb 2023 Kahramanmaraş earthquakes, East Anatolian Fault, Türkiye. Conference Proceedings of MedGU 2023, Istanbul.
- Bilham, R., Castillo, B. (2020). The July 2019 Ridgecrest, California, Earthquake Sequence Recorded by Creepmeters: Negligible Epicentral Afterslip and Prolonged Triggered Slip at Teleseismic Distances. *Seismological Research Letters*; 91 (2A): 707–720. doi: <https://doi.org/10.1785/0220190293>.
- Blanpied, M. L., Lockner, D. A., Byerlee, J. D. (1991), Fault stability inferred from granite sliding experiments at hydrothermal conditions, *Geophys. Res. Lett.*, 18(4), 609–612, doi:10.1029/91GL00469.
- Serpelloni, E., Pintori, F., Gualandi, A., Scoccimarro, E., Cavaliere, A., Anderlini, L., et al. (2018). Hydrologically induced karst deformation: Insights from GPS measurements in the Adria-Eurasia plate boundary zone. *Journal of Geophysical Research: Solid Earth*, 123, 4413–4430. <https://doi.org/10.1002/2017JB015252>.
- Grützner, C., Aschenbrenner, S., Jamšek Rupnik, P., Reicherter, K., Saifelislam, N., Vičič, B., Vrabec, M., Welte, J., and Ustaszewski, K. (2021). Holocene surface-rupturing earthquakes on the Dinaric Fault System, western Slovenia, *Solid Earth*, 12, 2211–2234, <https://doi.org/10.5194/se-12-2211-2021>.
- Jolivet, R., Lasserre, C., Doin, M. P., Peltzer, G., Avouac, J. P., Sun, J., Dailu, R. (2013). Spatio-temporal evolution of aseismic slip along the Haiyuan Fault, China: Implications for fault frictional properties, *Earth Planet. Sci. Lett.*, 377–378, 23–33, doi: 10.1016/j.epsl.2013.07.020.
- Kaneko, Y., Fialko, Y., Sandwell, D. T., Tong, X., Furuya, M. (2013). Interseismic deformation and creep along the central section of the North Anatolian Fault (Turkey): InSAR observations and implications for rate-and-state friction properties, *J. Geophys. Res. Solid Earth*, 118, 316–331, doi:10.1029/2012JB009661.
- Lindsey, E. O., Fialko, Y., Bock, Y., Sandwell, D. T., and Bilham, R. (2014). Localized and distributed creep along the southern San Andreas Fault, *J. Geophys. Res. Solid Earth*, 119, 7909–7922, doi:10.1002/2014JB011275.
- Tong, X., Sandwell, D. T., Smith-Konter, B. (2013). High-resolution interseismic velocity data along the San Andreas Fault from GPS and InSAR, *J. Geophys. Res. Solid Earth*, 118, 369–389, doi:10.1029/2012JB009442.
- Vičič, B., Aoudia, A., Javed, F., Foroutan, M., Costa, G. (2019). Geometry and mechanics of the active fault system in western Slovenia 2019. *Geophysical Journal International*, Volume 217, 3, 1755–1766. <https://doi.org/10.1093/gji/ggz118>.



# Analiza vplivnih dejavnikov na kinetično energijo dežnih kapljic

Katarina Zabret<sup>\*,\*\*</sup>, Lana Radulović<sup>\*</sup>, Mark Bryan Alivio<sup>\*</sup>, Nejc Bezak<sup>\*</sup>, Mojca Šraj<sup>\*</sup>

## Povzetek

Erozivnost padavin, ki vpliva na premikanje, odnašanje in spiranje površinskih zemljinskih slojev ter s tem na degradacijo tal in različne okoljske probleme, je odvisna predvsem od kinetične energije dežnih kapljic. Pri tem veliko vlogo igra tudi vegetacija s prestrežanjem padavin, saj se v procesu prestrežanja spremeni mikrostruktura dežnih kapljic, t.j. velikost, hitrost in njihovo število. Za ugotavljanje vpliva različnih dejavnikov na kinetično energijo dežnih kapljic, smo analizirali podatke o lastnostih padavinskega dogodka, kot so količina, trajanje in intenziteta padavin, število dežnih kapljic ter tudi meteorološke dejavnike kot sta temperatura zraka in hitrost vetra. Analize smo izdelali z modelom ojačanih regresijskih dreves, in sicer posebej za meritve lastnosti padavin nad krošnjami dreves ter pod krošnjo breze in krošnjo črnega bora. Ugotovili smo, da je spremenljivka, ki ne glede na lokacijo in vegetacijsko obdobje najbolj vpliva na kinetično energijo kapljic, količina padavin. Ta je povezana s številom dežnih kapljic, katerih vpliv na kinetično energijo je bil prepoznan predvsem za prepuščene padavine pod drevesi. Poleg tega v obdobju vegetacije na kinetično energijo prepuščenih dežnih kapljic pomembno vpliva tudi čas trajanja padavin, ki je povezan z nasičenjem, potrebnim za začetek kapljanja prestreženih padavin z drevesnih krošenj.

**Ključne besede:** prepuščene padavine, erozivnost padavin, kinetična energija, prestrežanje padavin, mikrostruktura padavin

**Key words:** throughfall, rainfall erosivity, kinetic energy, rainfall interception, rainfall microstructure

## Uvod

Velik del površine Slovenije je podvržen eroziji zemljine (Lazarevič, 1981), zaradi katere letno izgubimo več milijonov ton prsti (Komac in Zorn, 2005; Bezak et al., 2021). Eden izmed bistvenih dejavnikov erozije, pri kateri prihaja do premikanja, odnašanja in spiranja površinskih zemljinskih slojev, je delovanje vode, pri čemer upoštevamo tudi erozijo, do katere pride zaradi padavin. Ko so tla zasičena, padavine pričnejo tvoriti površinski odtok, ki spira zemljino (Bezak et al., 2021). Poleg tega pa dežne kapljice povzročajo tudi erozijo zaradi škropljenja, ko padejo na zemljino in razpršijo med seboj nepovezane delce (Lv et al., 2023; Zambon et al., 2021). Kolikšna je erozivnost padavin, je odvisno predvsem od lastnosti padavinskega dogodka in lastnosti zemljine (Fernández-Raga et al., 2017; Zambon et al., 2021; Beczek et al., 2022; Zore et al., 2022).

Vpliv lastnosti zemljine na erozivnost padavin raziskovalci naslavljajo z različnih vidikov, izpostavljajo pa predvsem lastnosti substrata ter nasičenost zemljine. Goebes in sodelavci (2014) tako na primer predlagajo, da bi za posamezne substrate kot so grobi in fini peski ter mulji upoštevali različne za ta substrat specifične parametre erozivnosti. Da je erozivnost padavin močno odvisna tudi od heterogenosti velikosti in porazdelitve kamninskih drobcov v zemljini, pa so s primerjavo laboratorijskih testov in terenskih meritev ugotovili Jomaa in sodelavci (2012). Beczek in sodelavci (2022) so proces erozije zaradi

---

\* Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Jamova 2, Ljubljana

\*\* Inštitut za vode Republike Slovenije, Einspielerjeva 6, Ljubljana

škropljenja obravnavali kot dvofazni proces razpršitve trdnih delcev in tekočine, ki jo prispeva že padel dež. Pri tem so ugotovili, da je prenos kinetične energije iz dežnih kapljic na razpršene delce konstanten. Zambon in sodelavci (2021) pa so na primeru analize vpliva začetne zasičenosti tal na erozivnost padavin ugotovili, da hidravlična prevodnost nasičene zemljine z naraščanjem kinetične energije padavin upada.

Kinetična energija je tako poleg intenzitete prepoznana kot bistvena lastnost padavin, ki določa količino sprane zemljine (Angulo-Martínez et al., 2012). Dežne kapljice z večjo kinetično energijo, imajo večjo erozivno moč (Lv et al., 2023). Zambon in sodelavci (2021) so v simulatorju padavin spremljali erozivnost kapljic in ugotovili, da na kinetično energijo bolj kot velikost vpliva hitrost kapljic. Tako na hitrost kot tudi na velikost dežnih kapljic, ki dosežejo tla, pa pomembno vpliva vegetacija, ki tla prekriva (Ghahramani et al., 2011; Lüpke et al., 2019; Zore et al., 2022; Alivio et al., 2023; Ryzak et al., 2023). Dežne kapljice, ki pridejo v stik z vegetacijo, se na listih in vejah lahko zadržijo, tal ne dosežejo, po končanih padavinah pa izhlapijo. Te padavine imenujemo prestrežene padavine (Zabret et al., 2018). Del padavin, ki tla dosežejo tako, da prikapljujejo z vej in listov, imenujemo prepuščene padavine, odtok po deblu pa tla doseže tako, da sicer prestrežene padavine odtečejo po vejah in deblu (Zabret et al., 2018). Pri tem se poleg sprememb v količini in intenziteti padavin, ki tla dosežejo, bistveno spremenijo tudi lastnosti dežnih kapljic (Lüpke et al., 2019; Zore et al., 2022). Na to vplivajo predvsem lastnosti dreves in mikrolokacija, saj so na primer Lüpke in sodelavci (2019) pod bukvijo in smreko zabeležili v povprečju večje kapljice kot na odprtem, med tem ko so Zore in sodelavci (2022) pod brezo in borom izmerili v povprečju manjše kapljice. Spremembe v mikrostrukturi dežnih kapljic pa bistveno vplivajo tudi na spremembe v njihovi kinetični energiji (Zore et al., 2022).


Erozivnost padavin je naravni proces, ki vpliva na stanje in količino zemljine. Na erozivno moč dežnih kapljic zaradi sprememb v njihovi mikrostrukturi vpliva prerazporeditev padavin po stiku z vegetacijo. Na to, kolikšen del padavin doseže tla pod vegetacijo, vplivajo različne lastnosti padavinskega dogodka (Zabret et al., 2018; Zabret in Šraj, 2021). Da pa bi lahko ovrednotili, kako te lastnosti vplivajo na samo kinetično energijo dežnih kapljic in posledično na erozivnost padavin, smo izvedli analizo z modelom ojačanih regresijskih dreves. Cilj raziskave je določiti lastnosti padavinskega dogodka in meteoroloških pogojev med dogodkom, ki najbolj vplivajo na kinetično energijo dežnih kapljic ter ugotoviti morebitne razlike med vplivnimi dejavniki za padavine na prostem in prepuščene padavine pod drevesi.

### **Opis raziskovalne ploskve in metode**

Meritve padavin, prepuščenih padavin ter mikrostrukture padavin izvajamo na raziskovalni ploskvi, ki obsega 600 m<sup>2</sup> in se nahaja v manjšem mestnem parku v Ljubljani ob stavbi Oddelka za okoljsko gradbeništvo UL FGG. Na zahodnem delu ploskve raste dve skupini dreves, navadni brezi (*Betula pendula* Roth.) in črna borovca (*Pinus nigra* Arnold), katerih krošnje se med seboj ne prekrivajo, vzhodni del ploskve pa obsega čistina, prekrita s travnato površino (slika 1). Brezi sta visoki 18,8 m in 19,3 m, bora pa 18,6 m in 14,6 m. Izmerjene vrednosti indeksa listne površine LAI (Li-Cor Inc., LAI-2200) za brezo se gibljejo med 0,5 m<sup>2</sup>/m<sup>2</sup> v obdobju mirovanja in 2,9 m<sup>2</sup>/m<sup>2</sup> v obdobju vegetacije, pri boru pa med 3,4 in 4,3 m<sup>2</sup>/m<sup>2</sup> v posameznih vegetacijskih obdobjih.

Padavine na prostem merimo z dvema avtomatskima dežemeroma Onset RG2-M (angl. tipping bucket), ki sta postavljena na čistini. Pod vsako skupino dreves spremljamo količino prepuščenih padavin, ki predstavljajo padavine, ki dosežejo tla pod drevesi s kapljanjem z listov in vej oziroma padejo skozi odprtine drevesne krošnje. Prepuščene padavine merimo

z dvema ostrorobnima koritoma površine 0,75 m<sup>2</sup>, enim z avtomatskim merilnikom in enim z ročnim odčitavanjem. Za oceno prostorske porazdelitve prepuščenih padavin te dodatno zbiramo še z 11 premičnimi lijakastimi merilniki z ročnim praznjenjem in tehtanjem zbranih padavin. Mikrostrukturo padavin (število, hitrost in velikost dežnih kapljic) spremljamo z disdrometri (OTT Parsivel), ki so nameščeni na strehi stavbe ter pod vsako skupino dreves (slika 1). Merilna površina posameznega disdrometra je enaka 54 cm<sup>2</sup>, izmerjene lastnosti dežnih kapljic pa so porazdeljene v razrede po velikosti (med 0,312 mm in 24,5 mm) in hitrosti (med 0,05 m/s in 20,8 m/s) (Zabret et al., 2017).



Slika 1 – Lokacija merilnikov padavin, prepuščenih padavin ter mikrostrukture padavin na raziskovalni ploskvi

Za analizo vpliva meteoroloških spremenljivk na kinetično energijo dežnih kapljic na prostem, pod krošnjo breze in krošnjo bora smo uporabili statistični model ojačanih regresijskih dreves. Analizo smo izvedli v programskem okolju R z uporabo paketa »gbm« (Greenwell et al., 2022). Iskali smo odvisnost med kinetično energijo (KE) dežnih kapljic na odprtem oziroma prepuščenih dežnih kapljic pod drevesi z različnimi vplivnimi spremenljivkami, ki podajajo lastnosti padavinskega dogodka. Te spremenljivke, ki smo jih v analizi upoštevali, so bile količina padavin (Pa), trajanje padavinskega dogodka (Pd), povprečna intenziteta padavin med dogodkom (Pi), maksimalna 1-minutna intenziteta padavin tekom dogodka (Pi\_max), vsota števila dežnih kapljic na dogodek (DropNr), največje število dežnih kapljic na minuto tekom dogodka (DropNr\_max), povprečna (Ws) in maksimalna hitrost vetra (Ws\_max) dogodka ter povprečna (T) in maksimalna temperatura zraka (T\_max) dogodka. Kinetično energijo padavin smo določili računsko z uporabo empirične enačbe, ki temelji na podatkih o mikrostrukturi padavin (npr. Petan, 2010; Zore, 2022; Radulović, 2023):

$$KE = \frac{\pi \cdot \rho}{12 \cdot 10^3 \cdot F \cdot \Delta t} \cdot \sum_i n_i \cdot \frac{1}{D_{b,i} - D_{a,i}} \cdot \int_{D_{a,i}}^{D_{b,i}} D_i^3 dD \cdot \frac{1}{v_{b,i} - v_{a,i}} \cdot \int_{v_{a,i}}^{v_{b,i}} v_i^2 dv \quad (1)$$

Kjer je  $\rho$  [kg/m<sup>3</sup>] gostota vode,  $F$  [mm] merilna površina disdrometra,  $\Delta t$  [1/60 h] interval trajanja,  $n_i$  [-] število zaznanih kapljic znotraj  $i$ -tega velikostnega razreda,  $D_{a,i}$  [mm] spodnja meja premera kapljic znotraj  $i$ -tega velikostnega razreda,  $D_{b,i}$  [mm] zgornja meja premera kapljic znotraj  $i$ -tega velikostnega razreda,  $D_i$  [mm] premer kapljic znotraj  $i$ -tega razreda,  $v_{a,i}$  [m/s] spodnja meja hitrosti padanja kapljic znotraj  $i$ -tega hitrostnega razreda,  $v_{b,i}$  [m/s]

zgornja meja hitrosti padanja kapljic znotraj i-tega hitrostnega razreda ter  $v_i$  [m/s] hitrost padanja kapljic znotraj i-tega razreda.


Podatke o količini, trajanju in intenziteti padavin ter lastnosti dežnih kapljic na odprtem smo pridobili iz meritev disdrometra na strehi. Za podatke o lastnostih prepuščenih dežnih kapljic pod drevesi pa smo uporabili meritve disdrometrov pod posamezno skupino dreves (slika 1). Podatke o vetru in temperaturi zraka smo izmerili na meteorološki postaji (Lufft WS700-UMB Smart Weather Sensor), locirani na stavbi Fakultete na Jamovi, oddaljeni približno 800 m od raziskovalne ploskve. Upoštevali smo eno leto meritev, in sicer padavinske dogodke, zabeležene med 12. 7. 2022 in 19. 7. 2023, ki smo jih med seboj ločili z vsaj štiriurnim obdobjem brez padavin na prostem ali prepuščenih padavin pod drevesi (Zabret et al., 2018; Zabret in Šraj, 2021). Dogodke smo razdelili na vegetacijsko obdobje, ko je krošnja breze olistana, ter na obdobje mirovanja vegetacije, ko je krošnja breze brez listov (22. 11. 2022 – 25. 4. 2023).

## Rezultati in diskusija

Spomladi 2022 so na raziskovalni ploskvi pričeli delovati vsi trije disdrometri, ki omogočajo spremljanje mikrostrukture dežnih kapljic tako na odprtem kot tudi pod drevesi z različnimi lastnostmi (listavci in iglavci). V analizi smo zajeli dogodke v obdobju enega leta med 12. 7. 2022 in 19. 7. 2023. Predstavljene vrednosti so bile izmerjene z disdrometri, zato se lahko razlikujejo od vrednosti, ki so izmerjene z avtomatskimi prekucnimi merilniki.


### Lastnosti obravnavanih padavinskih dogodkov

V obravnavanem obdobju smo na raziskovalni ploskvi zabeležili 101 dogodek, pri katerem smo poleg padavin na odprtem zabeležili tudi prepuščanje padavin pod drevesi. Izmed teh dogodkov je bilo pet takih s sneženimi padavinami, ki smo jih izločili iz nadaljnje analize. Tako smo v obdobju vegetacije zabeležili 62 dogodkov, v obdobju mirovanja pa 22 dogodkov. Količina padavin vseh obravnavanih dogodkov je znašala 1930,4 mm in se je gibala med 1 mm in 356,5 mm na dogodek (slika 2). Dogodki so v povprečju trajali 17,0 h, najdaljši dogodek je bil zabeležen v sredini decembra 2022 in je trajal približno 3 dni (74,4 h). Povprečna intenziteta padavin pa je bila enaka 1,66 mm/h, z največjo doseženo minutno intenziteto 4,1 mm/min v avgustu 2022.




Slika 2 – Vrednosti meteoroloških spremenljivk obravnavanih padavinskih dogodkov

V celotnem analiziranem obdobju smo pod brezo izmerili 1342,6 mm prepuščenih padavin, kar predstavlja 69,5 % padavin, izmerjenih na odprtem. V povprečju je delež prepuščenih padavin znašal 56,8 % padavin na dogodek (slika 3). Padavine pod brezo smo v povprečju zabeležili približno 38 minut po začetku padavin na odprtem. Breza pričakovano prepusti manj padavin, ko je krošnja polno olistana, to je v obdobju vegetacije, ko je povprečen delež prepuščenih padavin na dogodek znašal 53,6 %. V obdobju mirovanja, ko je krošnja breze brez listja, pa je delež prepuščenih padavin v povprečju znašal 66,2 % (slika 3). Pod borom je bil delež prepuščenih padavin nižji, saj smo v celotnem obdobju izmerili 604,7 mm prepuščenih padavin, kar predstavlja 31,3 % vsote vseh padavin, izmerjenih na odprtem. V povprečju je bor prepustil 17,3 % padavin na dogodek (slika 3), med začetkom padavin na prostem in prepuščanjem padavin pod drevesom pa je v povprečju minilo skoraj dve uri (117 min). Ker je bor zimzeleno drevo, večjih razlik v deležu prepuščenih padavin po posameznih vegetacijskih obdobjih nismo opazili (slika 3). Delež prepuščenih padavin pod brezo in pod borom ustreza vrednostim v razponu, ki so jih za raziskovalno ploskev za različna obdobja meritev poročali Zabret in Šraj (2021), Zore in sodelavci (2022) ter Alivio in sodelavci (2023).



Slika 3 – Deleži prepuščenih padavin, izmerjeni pod brezo in borom v celotnem analiziranem obdobju ter v odboju vegetacije in mirovanja

Prestrežanje padavin poleg zmanjšane količine dežja, ki tla doseže pod drevesi, pomembno vpliva tudi na lastnosti dežnih kapljic (slika 4). Manjša količina prepuščenih padavin v primerjavi s padavinami na odprtem se odraža tudi v manjšem številu dežnih kapljic, ki v povprečju na dogodek dosežejo tla pod drevesi. V povprečju smo tekom dogodka na odprtem zabeležili 172.659 dežnih kapljic, pod brezo 12 %, pod borom pa kar 58 % dežnih kapljic manj. Spremenile so se tudi lastnosti dežnih kapljic (slika 4). Povprečna mediana volumskega premera dežnih kapljic na odprtem je znašala 2,5 mm na dogodek, pod brezo so bile kapljice v povprečju malenkost večje (2,8 mm), pod borom pa manjše (2,2 mm). Povprečna hitrost dežnih kapljic pa je bila podobna na odprtem in pod brezo (3,9 m/s oziroma 3,8 m/s), pod borom pa je bila opazno nižja (2,2 m/s).



Slika 4 – Povprečne lastnosti dežnih kapljic po posameznem dogodku

Podobne spremembe v mikrostrukturi dežnih kapljic pod brezo so zabeležili tudi Zore in sodelavci, ki so opazili 20 % zmanjšanje števila in 7 % zmanjšanje hitrosti prepuščenih kapljic, poleg tega pa so opazili tudi 27 % zmanjšanje premera prepuščenih dežnih kapljic pod brezo. Manjše vrednosti vseh treh parametrov pa so pod brezo zabeležili tudi Alivio in sodelavci (2023). Spremembo mikrostrukture dežnih kapljic pod listavcem in iglavcem (bukvijo in smreko) pa so opazovali tudi Lüpke in sodelavci (2019), ki so prav tako zabeležili v povprečju večje kapljice pod listavcem kot pod iglavcem, kar pripisujejo transformaciji dežnih kapljic v prepuščene padavine pretežno s kapljanjem z vej in listov. Podobno so za rdeči kitajski bor opazili tudi Li in sodelavci (2019). Ta pojav je najverjetneje tudi razlog, da smo za analizirano obdobje zabeležili v povprečju največje kapljice pod brezo in ne na prostem, kot v predhodnih študijah (slika 4).

Kinetična energija dežnih kapljic, ki neposredno vpliva na erozivnost padavin, je odvisna od velikosti kapljic in njihove hitrosti. Nižja povprečna hitrost dežnih kapljic prepuščenih padavin pod drevesi v primerjavi s hitrostjo dežnih kapljic padavin na odprtem se tako odraža tudi v nižji povprečni kinetični energiji (KE) prepuščenih dežnih kapljic. Povprečna vrednost KE kapljic tekom padavinskega dogodka v obravnavanem obdobju je namreč pod brezo za 21 % nižja, pod borom pa kar za 82 % nižja kot na odprtem (slika 4). Zabeležene vrednosti zmanjšanja kinetične energije dežnih kapljic pod drevesi so podobne 30 % zmanjšanju vrednosti pod brezo v olistani dobi (Zore et al., 2022) in 33,7 % zmanjšanju



povprečne vrednosti KE prepuščenih padavin pod brezo v celotnem analiziranem obdobju (Alivio et al., 2023).


### Vpliv meteoroloških spremenljivk na kinetično energijo dežnih kapljic

Vpliv lastnosti padavinskega dogodka na kinetično energijo dežnih kapljic smo ovrednotili z uporabo modela ojačanih regresijskih dreves. Poleg napovedovanja ciljne spremenljivke (v tem primeru KE), s tem modelom lahko dobimo tudi informacijo o tem, kakšen je vpliv posamezne vplivne spremenljivke (v tem primeru lastnosti padavinskega dogodka) na ciljno spremenljivko. Vrednost vpliva spremenljivke namreč podaja faktor vpliva, ki za vsako vplivno spremenljivko določi delež vpliva tako, da je vsota faktorjev vpliva posameznih spremenljivk enaka 100.

Ne glede na obdobje, ki ga v analizi upoštevamo, na kinetično energijo dežnih kapljic na vseh treh lokacijah najbolj vpliva količina padavin na prostem oziroma količina prepuščenih padavin pod drevesom (slike 5-7). V celotnem obdobju meritev vplivni faktor te spremenljivke znaša med 50 % (pod brezo) in 66 % (pod borom), v obdobju vegetacije pa se vpliv količine padavin pod drevesi zmanjša, saj na odprtem znaša 59 %, po drevesoma pa 48 % (breza) oziroma 37 % (bor). Tudi v obdobju mirovanja količina padavin najbolj vpliva na kinetično energijo dežnih kapljic na odprtem (85 %), manj pa na kinetično energijo prepuščenih dežnih kapljic (62 % in 60 % pod brezo in pod borom).


Količina padavin je tudi sicer spremenljivka, ki najbolj vpliva na prerazporeditev padavin z vegetacijo. Analiza vpliva meteoroloških spremenljivk na delež prepuščenih padavin pod brezo in borom z uporabo ojačanih regresijskih dreves je namreč prav tako pokazala, da je količina padavin najvplivnejša spremenljivka (Zabret et al., 2018). Podobno so ugotovili tudi raziskovalci v številnih drugih študijah vplivov na komponente prestrezanja padavin (Staelens et al., 2008; Šraj et al., 2008; Siegert and Levia, 2014).

V celotnem obdobju meritev na kinetično energijo dežnih kapljic na odprtem poleg količine padavin ( $P_a$ ) z vplivnim faktorjem večjim od 8 % vplivajo še največja hitrost vetra izmerjena tekom dogodka ( $W_{S\_max}$ ), največja minutna intenziteta padavin ( $P_{i\_max}$ ) in največje število dežnih kapljic, zabeleženih v intervalu ene minute ( $Drop_{Nr\_max}$ ) (slika 5). Slednja spremenljivka je povezana s količino padavin in maksimalno minutno intenziteto in s tem še potrjuje vpliv že omenjenih spremenljivk. V primeru prepuščenih padavin pa je tako pod brezo kot tudi pod borom spremenljivka z drugim največjim vplivom in z vplivnim faktorjem enakim 13,5 %, število prepuščenih dežnih kapljic tekom dogodka ( $Drop_{Nr}$ ).



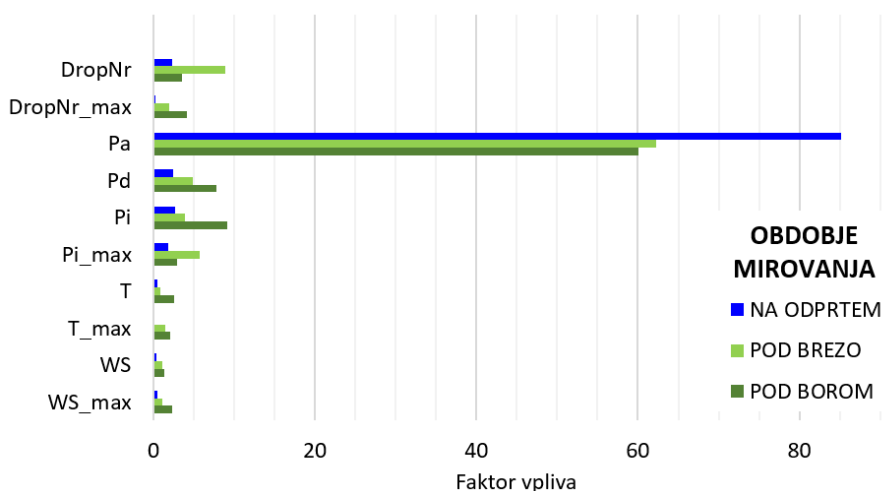
Slika 5 – Faktor vpliva posamezne vplivne spremenljivke na kinetično energijo na odprtem, pod brezo in pod borom v celotnem analiziranem obdobju

V obdobju vegetacije kinetično energijo dežnih kapljic na odprtem določajo predvsem spremenljivke, ki so neposredno povezane z lastnostmi padavinskega dogodka, to so povprečna intenziteta padavin ( $P_i$ ), maksimalna minutna intenziteta padavin ( $P_{i\_max}$ ) in trajanje padavinskega dogodka ( $P_d$ ) (Slika 6). Trajanje padavinskega dogodka je v tem obdobju tudi druga najbolj vplivna spremenljivka na KE pod obema drevesoma, kar je verjetno povezano predvsem s časom, ki je potreben, da se drevesna krošnja zasiči, kar vodi v pričetek bolj intenzivnega prepuščanja padavin. Poleg tega na KE prepuščenih padavin pod brezo in pod borom pomembneje vplivata še celotno število dežnih kapljic dogodka ( $DropNr$ ) ter maksimalna hitrost vetra ( $W_{s\_max}$ ) (Slika 6).



Slika 6 – Faktor vpliva posamezne vplivne spremenljivke na kinetično energijo na odprtem, pod brezo in pod borom v obdobju vegetacije

Vpliv količine padavin ( $P_a$ ) na kinetično energijo dežnih kapljic na odprtem je največji v obdobju mirovanja, ko faktor vpliva za to spremenljivko znaša kar 85 % (slika 7). Ostale tri spremenljivke, ki imajo na odprtem faktor vpliva večji od 2 %, pa so intenziteta ( $P_i$ ), trajanje ( $P_d$ ) in skupno število dežnih kapljic ( $DropNr$ ) padavinskega dogodka. Pod drevesoma pa so poleg splošnih lastnosti padavinskega dogodka ( $P_i$  in  $P_d$ ) tudi v obdobju mirovanja pomembne lastnosti prepuščenih dežnih kapljic, pod brezo predvsem vsota števila kapljic ( $DropNr$ ), pod borom pa maksimalno število dežnih kapljic na minuto ( $DropNr\_max$ ).



Slika 7 – Faktor vpliva posamezne vplivne spremenljivke na kinetično energijo na odprtem, pod brezo in pod borom v obdobju mirovanja

Ne glede na vegetacijsko obdobje in lokacijo meritve, je najbolj vplivna spremenljivka, ki določa kinetično energijo dežnih kapljic, količina padavin dogodka. Tudi Geißler in sodelavci (2013), ki so se sicer osredotočili na vpliv vegetacijskih spremenljivk na kinetično energijo prepuščenih dežnih kapljic, so tekom analize potrdili pomemben vpliv količine padavin, kar velja tudi za študijo, ki so jo izvedli Brasil in sodelavci (2022). Poleg tega je bil dokaj velik vpliv prepoznani tudi za število dežnih kapljic, kar pa je povezano s količino padavin (Zabret et al., 2018). Večja količina padavin namreč pomeni večje število dežnih kapljic, s tem pa tudi bolj raznolik spekter njihovih velikosti in hitrosti. Mao in sodelavci (2023) na primer navajajo, da koncentracija števila in velikosti dežnih kapljic naraščata s količino in intenziteto dežja, zato spekter kapljic postaja vse širši, torej je možnost pojava večjih in hitrejših dežnih kapljic, ki dosežejo večjo kinetično energijo, večja. To je lahko povezano tudi z večjim premerom dežnih kapljic, ki so bile izmerjene pod brezo (Slika 4) in zabeleženim velikim vplivom števila dežnih kapljic na KE pod brezo (slike 5-7).

Izmed ostalih analiziranih lastnosti dogodka je bil za celotno obdobje meritev izpostavljen tudi vpliv maksimalne minutne intenzitete padavin na KE prepuščenih padavin pod drevesi. Podobno so tudi Li in sodelavci (2019) v analizi rezultatov meritev kinetične energije dežnih kapljic v gozdu rdečega kitajskega bora izpostavili vpliv intenzitete padavin. Marzen in sodelavci (2015) pa so se v svoji raziskavi osredotočili na vpliv vetra in ugotovili potencialno zelo velik vpliv dežja, ki pada z vetrom, na erozijo tal. Vpliv vetra na KE prepuščenih dežnih kapljic je bil z uporabljenim modelom pod drevesi prepoznani kot zanemarljiv, je bila pa maksimalna hitrost vetra, zabeležena tekom dogodka, druga najbolj vplivna spremenljivka na KE dežnih kapljic na odprtem v celotnem analiziranem obdobju. Takšen rezultat kaže na to, da drevje zmanjšuje vpliv vetra na erozivnost dežnih kapljic.

## **Zaključki**

Kinetična energija dežnih kapljic pomembno vpliva na erozivnost padavin, zaradi katere prihaja do degradacije visokokakovostnih tal ali drugih okoljskih težav. Vegetacija zaradi prestrezanja padavin vpliva na količino dežja, ki doseže tla, pa tudi na kinetično energijo prepuščenih dežnih kapljic. Z modelom ojačanih regresijskih dreves smo pokazali, da na kinetično energijo dežnih kapljic na prostem in pod drevesi ne glede na vegetacijsko obdobje najbolj vpliva količina padavin. Ta je povezana s številom dežnih kapljic, ki pri večjih koncentracijah vplivajo na vse širši spekter kapljic in s tem na večjo možnost pojava večjih in hitrejših dežnih kapljic z večjo kinetično energijo. Poleg tega smo z analizo rezultatov uporabljenega modela pokazali tudi, da je vpliv števila dežnih kapljic bolj izrazit v primeru prepuščenih padavin pod drevesi kot padavin na odprtem. Bistvena razlika med vplivi na kinetično energijo prepuščenih padavin po posameznih vegetacijskih obdobjih pa se kaže v tem, da je v obdobju olistanosti izredno pomemben tudi čas trajanja padavin, ki vpliva na zasičenost drevesnih krošenj in s tem na pričetek obilnejšega prepuščanja padavin.

## **Zahvala**

Raziskava, predstavljena v prispevku, je bila finančno podprta s strani Javne agencije za raziskovalno in inovacijsko dejavnost Republike Slovenije iz državnega proračuna v okviru raziskovalnih projektov J2-4489, N2-0313, J6-4628 in raziskovalnega programa P2-0180. Raziskava je finančno podprta tudi s strani programa Evropske unije za raziskave in inovacije Horizon Europe preko projekta SpongeScapes (Grant agreement ID 101112738).

Dodatno je bila raziskava sofinancirana s strani Ministrstva za izobraževanje, znanost in šport, Medvladnega hidrološkega programa UNESCO IHP.

## Reference

- Alivio, M.B., Bezak, N., Mikoš, M. (2023). The size distribution metrics and kinetic energy of raindrops above and below an isolated tree canopy in urban environment. *Urban Forestry & Urban Greening* 85, 127971.
- Angulo-Martínez, M., Beguería, S., Navas, A., Machín, J. (2012). Splash erosion under natural rainfall on three soil types in NE Spain. *Geomorphology* 175-176, 38-44.
- Beczek, M., Mazur, R., Ryżak, M., Sochan, A., Polakowski, C., Beczek, T., Bieganski, A. (2022). How much raindrop energy is used for transportation of the two-phase splashed material? *Geoderma* 425, 116034.
- Bezak, N., Petan, S., Mikoš, M. (2021). Spatial and Temporal Variability in Rainfall Erosivity Under Alpine Climate: A Slovenian Case Study Using Optical Disdrometer Data. *Frontiers in Environmental Science* 9.
- Brasil, J.B., Andrade, E.M., Araújo de Queiroz Palácio, H., Fernández-Raga, M., Carvalho Ribeiro Filho, J., Medeiros, P.H.A., Guerreiro, M.S. (2022). Canopy Effects on Rainfall Partition and Throughfall Drop Size Distribution in a Tropical Dry Forest. *Atmosphere* 13, 1126.
- Fernández-Raga, M., Palencia, C., Keesstra, S., Jordán, A., Fraile, R., Angulo-Martínez, M., Cerdà, A. (2017). Splash erosion: A review with unanswered questions. *Earth-Science Reviews* 171, 463-477.
- Ghahramani, A., Ishikawa, Y., Gomi, T., Shiraki, K., Miyata, S. (2011). Effect of ground cover on splash and sheetwash erosion over a steep forested hillslope: A plot-scale study. *CATENA* 85, 34-47.
- Geißler, C., Nadrowski, K., Kühn, P., Baruffol, M., Bruelheide, H., Schmid, B., Scholten, T. (2013). Kinetic energy of throughfall in subtropical forests of SE China - effects of tree canopy structure, functional traits, and biodiversity. *PloS One* 8, e49618.
- Goebes, P., Seitz, S., Geißler, C., Lassu, T., Peters, P., Seeger, M., Nadrowski, K., Scholten, T. (2014). Momentum or kinetic energy – How do substrate properties influence the calculation of rainfall erosivity? *Journal of Hydrology* 517, 310-316.
- Greenwell, B., Boehmke, B., Cunningham, J. (2022). Package 'gbm'. Dostopno na: <https://cran.r-project.org/web/packages/gbm/gbm.pdf>
- Jomaa, S., Barry, D.A., Brovelli, A., Heng, B.C.P., Sander, G.C., Parlange, J.Y., Rose, C.W. (2012). Rain splash soil erosion estimation in the presence of rock fragments. *CATENA* 92, 38-48.
- Komac, B., Zorn, M. (2005). Soil erosion on agricultural land in Slovenia – measurements of rill erosion in the Besnica valley. *Acta geographica Slovenica* 45, 53-86.
- Lazarević, R. (1981). Erozija zemljišta u Jugoslaviji. *Geographica Iugoslavica* 3, 7-17.
- Li, G, Wan, L., Cui, M., Wu, B., Zhou, J. (2019). Influence of Canopy Interception and Rainfall Kinetic Energy on Soil Erosion under Forests. *Forests* 10, 509.
- Lüpke, M., Leuchner, M., Levia, D., Nanko, K., Iida, S., Menzel, A. (2019). Characterization of differential throughfall drop size distributions beneath European beech and Norway spruce. *Hydrological Processes* 33, 3391-3406.
- Lv, L., Li, Y., Zhou, C. (2023). Mechanistic analysis of splash erosion on loess by single raindrop impact: Interaction of soil compaction, water content, and raindrop energy. *Biosystems Engineering* 236, 238-247.

- Mao, W., Zhang, W., Kou, M. (2023). Statistical characteristics of raindrop size distribution during rainy seasons in complicated mountain terrain. *Hydrology and Earth System Sciences* 27, 3895-3910.
- Marzen, M., Iserloh, T., Casper, M.C., Ries, J.B. (2015). Quantification of particle detachment by rain splash and wind-driven rain splash. *CATENA* 127, 135-141.
- Petan, S., Rusjan, S., Vidmar, A., Mikoš, M. (2010). The rainfall kinetic energy–intensity relationship for rainfall erosivity estimation in the mediterranean part of Slovenia. *Journal of Hydrology* 391, 314-321.
- Radulović, L. (2023): Vpliv prestrezanja padavin na mikrostrukturo padavin. Diplomska naloga. Univerza v Ljubljani, FGG, 56 pp.
- Ryżak, M., Beczek, M., Mazur, R., Sochan, A., Gibała, K., Polakowski, C., Bieganski, A. (2023). The splash of a single water drop on selected coniferous plants. *Forest Ecology and Management* 541, 121065.
- Siegert, C.M., Levina, D.F. (2014). Seasonal and meteorological effects on differential stemflow funneling ratios for two deciduous tree species. *Journal of Hydrology* 519, 446-454.
- Staelens, J., De Schrijver, A., Verheyen, K., Verhoest, N.E.C. (2008). Rainfall partitioning into throughfall, stemflow, and interception within a single beech (*Fagus sylvatica* L.) canopy: influence of foliation, rain event characteristics, and meteorology. *Hydrological Processes* 22, 33-45.
- Šraj, M., Brilly, M., Mikoš, M. (2008). Rainfall interception by two deciduous Mediterranean forests of contrasting stature in Slovenia. *Agricultural Forest Meteorology* 148, 121-134.
- Zabret, K., Rakovec, J., Mikoš, M., Šraj, M. (2017). Influence of Raindrop Size Distribution on Throughfall Dynamics under Pine and Birch Trees at the Rainfall Event Level. *Atmosphere* 8, 240.
- Zabret, K., Rakovec, J., Šraj, M. (2018). Influence of meteorological variables on rainfall partitioning for deciduous and coniferous tree species in urban area. *Journal of Hydrology* 558, 29-41.
- Zabret K., Šraj M. (2021). Relation of influencing variables and weather conditions on rainfall partitioning by birch and pine trees. *Journal of Hydrology and Hydromechanics* 69, 456-466.
- Zambon, N., Lolk Johannsen, L., Strauss, P., Dostal, T., Zumr, D., Cochrane, T.A., Klik, A. (2021). Splash erosion affected by initial soil moisture and surface conditions under simulated rainfall. *CATENA* 196, 104827.
- Zore, A., Bezak, N., Šraj, M. (2022). The influence of rainfall interception on the erosive power of raindrops under the birch tree. *Journal of Hydrology* 613, 128478.



# Geomagnetna nevihta in polarni sij v Sloveniji v letu 2023

Rudi Čop<sup>1</sup>, Jure Atanackov<sup>2</sup>

## Povzetek

V letu 2023 je sedanji 25. Sončev cikel dosegel prvo polovico svoje druge tretjine. Nam najbližja zvezda se približuje svojemu maksimumu aktivnosti in temu primeren je tudi njen vpliv na Zemljo. Geomagnetno polje je zelo pogosto razburkano, kar najbolj zaznamo v spremljajočih svetlobnih učinkih. Med njimi je najbolj poznan polarni sij, ki se pojavlja v vsakokrat drugačni obliki na višjih geografskih širinah. V članku je narejen pregled polarnih sijej, opaženih v Sloveniji v prvih enajstih mesecih leta 2023. Slovenija namreč leži na srednjih geografskih širinah, torej zunaj območja, kjer se polarni siji običajno pojavljajo. Predstavljena je geomagnetna nevihta, ki se je začela 4.11.2023 in naslednji dan dosegla stopnjo G3 (Strong). Ta nevihta je povzročila polarni sij, ki je bil viden skoraj po vsej Evropi. Pojavil se je tudi SAR (Stable Auroral Red), ki spremlja močne geomagnetne nevihte in ni značilen za območja znotraj polarnega kroga. Vse rezultate opazovanj na slovenskem podežlju sva primerjala z rezultati meritev spremembe lokalnega magnetnega polja na geomagnetnem observatoriju PIA (Piran, Slovenia).

**Ključne besede:** geomagnetne nevihte, polarni siji, SAR, Slovenija

**Keywords:** geomagnetic storms, northern lights, SAR, Slovenia

## Pojavi polarnih sijej v Sloveniji


Ker je Slovenija od severnega pola precej oddaljena (subauroral latitudes), so pri nas videni pojavi polarnih sijej precej redki. Običajno se pojavljajo ob vrhuncih Sončeve aktivnosti, ki se ciklično ponavljajo približno vsakih 11 let (Slika 1). V tem obdobju so namreč pogostejši močni izbruhi na Soncu. Zato lahko še v naslednjih dveh do petih letih zagotovo pričakujemo polarne sije tudi pri nas.

Od 1.1.2023 do 1.12.2023 je bilo v Sloveniji vidnih 17 polarnih sijej. Do tega podatka sva prišla na podlagi opazovanj na podežlju ali na podlagi posnetkov spletnih kamer v Sloveniji. Kadar vremenske razmere niso bile ugodne za opazovanje, sva podatke dobila iz spletnih kamer sosednjih držav, ki so na istih geografskih širinah kot Slovenija. Od teh 17 polarnih sijej bi lahko bilo v Sloveniji vidnih od 12 do 14. Vsaj trije od njih najverjetneje ne bi dosegli zadostne svetilnosti, da bi jih lahko opazovali s prostim očesom.

V preglednici (Preglednica 1) so zbrani podatki o tistih polarnih sijih, ki so jih v letu 2023 dobro dokumentirali opazovalci, ki pri nas ljubiteljsko sledijo tem naravnim pojavom. Polarni siji so se vsakokrat pojavili ob geomagnetnih nevihtah. Te so razporejene v kategorije od G1 do G5 (Minor, Moderate, Strong, Severe, Extreme) (NOAA, 2011). Kategorije, opisane v razpredelnici, so določene na podlagi geomagnetnih indeksov  $K_{PIA}$ , ki veljajo za ozemlje Slovenije. Izračunani so iz merilnih podatkov, pridobljenih na geomagnetnem observatoriju z mednarodno kodo PIA (Piran, Slovenia) (v nadaljevanju: Observatorij).

<sup>1</sup> Zavod Terra Viva, Sv. Peter 115, 6333 Sečovlje

<sup>2</sup> Geološki zavod Slovenije, Dimičeva ulica 14, 1000 Ljubljana



Slika 1 – Število Sončevih peg v predhodnem 24. in sedanjem 25. Sončevem ciklu: modre barve so srednje mesečne vrednosti, vijolične izravnane mesečne vrednosti in rdeče barve napovedane mesečne vrednosti (Solar Cycle, 2023).

Preglednica 1 - Leta 2023 v Sloveniji opazovani polarni siji in/ali SAR-i

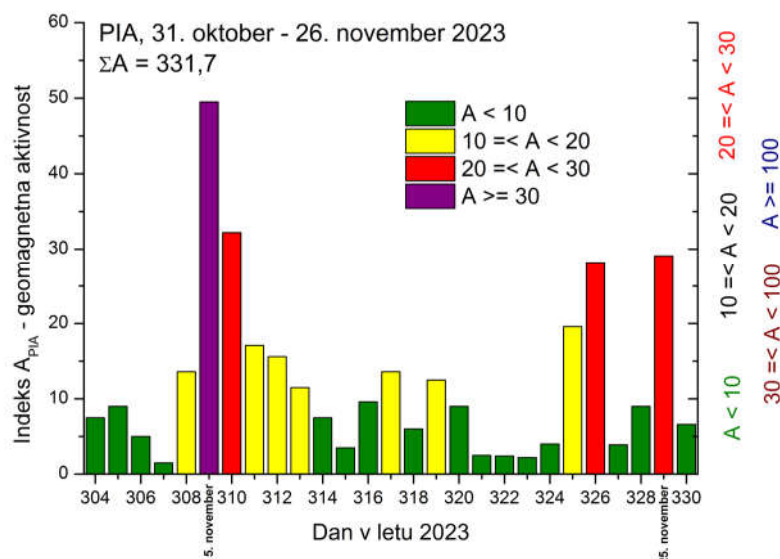
Datum [yyyy-mm-dd]	$K_{PIA}$ interval	Vrednost	NEVIHTA (Kategorija)	Aktivnost <b>A</b>	Opazovan in fotografiran
2023-03-23	8	7	G3 (Strong)	42,9	Polarni sij
2023-04-23	7	7	G3 (Strong)	37,8	Polarni sij - SAR
2023-06-25	1	5	G1 (Minor)	16,1	Polarni sij
2023-09-12	5	5	G1 (Minor)	21,4	Polarni sij
2023-09-25	1	5	G1 (Minor)	23,6	Polarni sij
2023-11-05	6	7	G3 (Strong)	49,5	Polarni sij - SAR
2023-11-25	7	6	G2 (Moderate)	29,1	Polarni sij
2023-12-01	4	6	G2 (Moderate)	46,5	Polarni sij

**Opomba:** Seznam opazovanj je narejen za obdobje od 1.1.2023 do 5.12.2023.

### Meritve sprememb lokalnega magnetnega polja

Meritve sprememb lokalnega magnetnega polja na geomagnetnih observatorijih na površini Zemlje so meritve aktivnosti električnih tokov v ionosferi in magnetosferi ter motenj, ki jih ti tokovi povzročajo. Iz teh meritev izhaja indeks geomagnetne aktivnosti  $K$ , primeren predvsem za opis geomagnetnih razmer v srednjih geografskih širinah. Za izračunavanje tega indeksa je izbran tri urni interval v času UTC (Universal Time Coordinated). V tem intervalu so zajete geomagnetne motnje, ki trajajo od ene do dveh ur. Interval je dovolj kratek, da se z njim lahko ločita dva zaporedna dogodka, nastala v času enega dneva (Čop et al, 2015). Z osmimi indeksi  $K$  se opiše geomagnetno dogajanje preko celega dneva. Iz teh indeksov se izračuna geomagnetna aktivnost posameznega dne, indeks  $A$  (Slika 2), ki je linearen in z vrednostmi od 0 do 400 (Mayaud, 1980).





Slika 2 – Geomagnetna aktivnost  $A$  v Sloveniji v času enega efektivnega obrata Sonca od 31. oktobra do 26. novembra 2023.

Indeks  $K$  je neimenovano število: od 0 za najbolj miren dan do 5, ko nastopa najmilejša oblika geomagnetne nevihte, pa vse do 9 za opis razmer, ko je zemeljsko magnetno polje najbolj razburkano. Jakost geomagnetnih neviht narašča od geomagnetnega ekvatorja proti področjema polarnih sijev. Zato ima vsak observatorij svojo skalo indeksa  $K$ . Ta skala je logaritemska, zato zadostuje, da ima posamezni observatorij določeno najmanjšo vrednost geomagnetne motnje pri največjem indeksu  $K = 9$  (ISGI, 2023). Tako je skala posameznega geomagnetnega observatorija primerljiva s skalo referenčnega geomagnetnega observatorija NGK (Niemegk, Germany).

Planetarni geomagnetni indeks  $K_p$  je danes izhodiščni indeks v geomagnetizmu in aeronomiji, znanosti o električnih tokih, ki tečejo v zgornjih plasteh atmosfere. Vrednost tega indeksa se napoveduje in nato tudi naknadno obdeluje (postprocesira) (Geomagnetic  $K_p$ , 2023). V ta namen se uporabljajo merilni podatki tistih geomagnetnih observatorijev, ki v popolnosti zadoščajo priporočilom mednarodnih organizacij IAGA (International Association of Geomagnetism and Aeronomy) in INTERMAGNET (International Real-time Magnetic Observatory Network).

Geomagnetne nevihte nastajajo ob izbruhih v koroni Sonca CME (angl. coronal mass ejections) ali zaradi prehodov Zemlje preko tokovnic sončnega vetra s povečano hitrostjo CIR (angl. corotating interaction regions), ki izhajajo iz lukenj v koroni Sonca. Vezane so na cikel sončnih peg. Leto največje geomagnetne aktivnosti običajno zaostaja za dve ali tri leta za letom z največjo sončevo aktivnostjo. Po obliki njihovega magnetograma se geomagnetne nevihte delijo v dve skupini: na geomagnetne nevihte z nenadnim začetkom (angl. sudden commencement storms) in geomagnetne nevihte s postopnim začetkom (angl. gradual commencement storms). Tako v ciklu sončnih peg kot v ciklu geomagnetnih neviht je zaznaven 27 dnevni efektivni obrat Sonca (Čop, 2020). Geomagnetne nevihte so torej zelo predvidljive. Napovedati jih je mogoče razmeroma točno na podlagi meritev na namenskih umetnih satelitih in to vsaj 2 dni vnaprej.

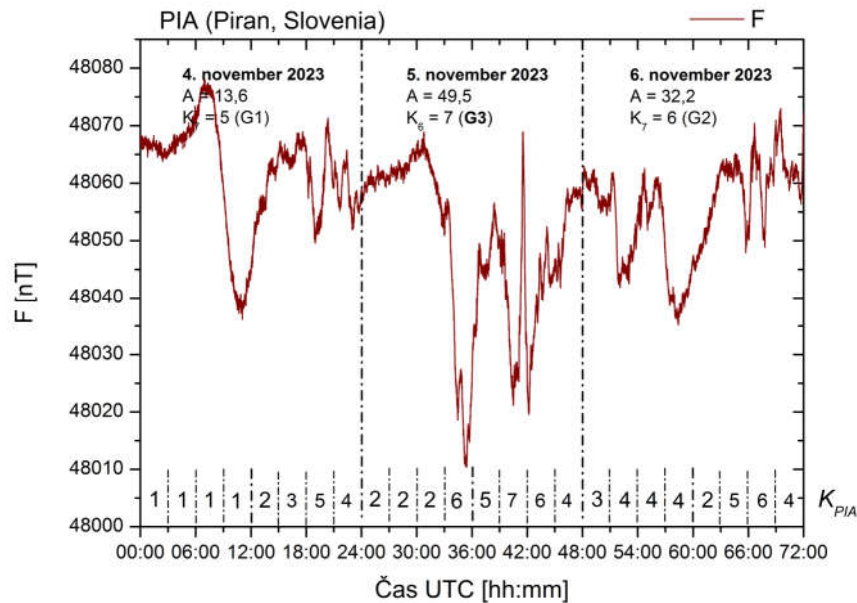
### Geomagnetna nevihta kategorije G3 z začetkom 4. novembra 2023

Zaradi precej zapletenega stanja magnetnega polja na Soncu (Geomagnetic storm, 2023) je 3. novembra 2023 nastal izbruh v njegovi koroni CME. Usmerjen je bil neposredno proti Zemlji. Posnetek tega izbruha je bil narejen s teleskopom, ki je nameščen na ameriškem geosinhronem satelitu SDO (Solar Dynamics Observatory), v ultravijoličnem delu spektra svetlobe EUV (Extreme ultraviolet radiation)  $\lambda = 304$  nm. NASA (National Aeronautics and Space Administration) je satelit SDO izstrelila v geocentrično orbito 11.02.2010. Tudi na satelitu SOHO (Solar and Heliospheric Observatory) je posnet ta izbruh na Soncu (LASCO Coronagraph, 2023) s pomočjo koronografa (LASCO, 1994). Vesoljski observatorij SOHO je bil izstreljen 2.12.1995 v sodelovanju ESA (European Space Agency) in NASA. Utirjen je v Lagrangevi točki  $L_1$  med Soncem in Zemljo, kjer se njuni gravitacijski sili izenačita. Satelit je zgradilo podjetje Matra Marconi Space (Toulouse, France), izstreljen pa je bil z ameriško nosilno raketo Atlas II in deluje že preko 25 let.



Slika 3 – Polarni sij fotografiran 5. novembra 2023 ob 17:16 UTC v vasi Gomila pri Mirni na Dolenjskem [45°56'2.19"N 15°2'48.49"E].

V nedeljo 5.11.2023, dva dni po izbruhu v koroni Sonca, je bil kot posledica viden severni sij v velikem delu Evrope. V zadnjih dveh desetletjih je bil v naših krajih to eden od najbolj izrazitih polarnih sijev (Slika 3). Meritve na Observatoriju so to tudi potrdile (Slika 4). V času pojava geomagnetne nevihte stopnje G3 (Strong), je bila srednja vrednost meritev gostote lokalnega magnetnega polja na Observatoriju  $F = 48049,07$  nT. Sprememba vrednosti te gostote je znašala  $\Delta F = 58,54$  nT = 58,54  $\gamma$  (Gamma) ali vsega 0,12 % od njene srednje vrednosti. Ta sprememba gostote lokalnega magnetnega polja pa je bila vzrok za nastanek v članku opisanih izrednih svetlobnih pojavov v Sloveniji.



Slika 4 – Meritev spremembe lokalnega magnetnega polja na Observatoriju in pripadajoči 3-urni geomagnetni indeksi  $K_{PIA}$  v času geomagnetne nevihte kategorije G3 (Strong) od 4. do 6. novembra 2023.

### SAR na srednjih geografskih širinah

Polarni siji (Aurora Polaris) nastajajo zaradi trkov naelektrenih atomov, protonov in elektronov iz vesolja ob atome plinov visoko v našem ozračju. Geomagnetno polje v polarnih območjih te naelektrene elementarne delce iz Sončevega vetra usmeri proti atmosferi Zemlje. Polarni siji se redno pojavljajo v pasu med  $59^\circ$  in  $71^\circ$  zemljepisne širine (Aurora Borealis, Aurora Australis). Njihova pojavnost je neposredno povezana s ciklom geomagnetnih neviht. So zelo različnih barv, različnih oblik in imajo svoj ritem. Njihova svetilnost je od komaj zaznavnega tlenja na zvezdnatem nebu pa do svetilnosti polne Lune. Najpogosteje se pojavljajo na višini od 95 km do 210 km, izjemoma pa tudi na višini več kot 600 km. Predvsem v času nizke in srednje aktivnosti Sonca je prevladujoča barva polarnih sijev zelena (557,7 nm), v času njegove največje aktivnosti pa se pogosteje pojavljajo polarni siji pretežno rdeče barve (630 nm). Obe barvi svetlobe sta barvi sevanja atomov kisika, ki pa so različno vzbujeni (Egeland & Burke, 2013).

SAR (Stable Auroral Red) tvori podobne svetlobne loke na nebu kot polarni sij (Slika 5). Pojavlja se samo na geografskih širinah, kjer se sicer polarni sij običajno ne pojavlja. Zanj je značilna samo rdeča barva svetlobe, ki pa jo prosto človeško oko slabo zazna. Zato je SAR viden le ob močnih geomagnetnih nevihtah. Je tlenje zaradi segrevanja zgornjih plasti atmosfere. Povzročajo ga električni toki, ki v obliki kolobarja obkrožajo Zemljo. Rdečemu siju na nebu SAR se lahko pridružil še STEVE (Strong Thermal Emission Velocity Enhancement) v obliki dodatnega pramena bele barve (Gillies et al, 2023). Nastanek tega svetlobnega pojava še ni docela razjasnjen (Nishimura et al, 2023).

V plazmosferi, v notranjem delu magnetosfere in nad ionosfero, se nahaja hladna plazma. Nagel skok v gostoti te plazme (plasmopause) določa zunanjo mejo tega območja. Zaradi turbulentne izgube energije električnih tokov, ki v obliki kolobarja obkrožajo Zemljo, nastane v tej zunanji meji svetlobni lok SAR. V drugem delu geomagnetne nevihte, ko slednja že pojenja (angl. recovery phase, substorm), se namreč to mejno

področje razširi v simetrični krožni električni tok okoli Zemlje (angl. terrestrial ring current) (Cornwall et al, 1970; Foster et al, 1994).



Slika 5 – SAR (Stable Auroral Red) fotografiran 5. novembra 2023 ob 18:32 UTC v vasi Gomila pri Mirni na Dolenjskem [45°56'2.19"N 15°2'48.49"E].

Laboratorijske raziskave nastanka polarnih sijev v zadnjem desetletju 19. stoletja so potrdile hipotezo, da polarni sij v polarnem krogu nastaja zaradi naelektrenih delcev, ki prihajajo iz Sonca in jih magnetno polje Zemlje usmerja proti magnetnim polom (Rypdal & Brundtland, 1997). V bližnjem vesolju je torej sončni veter, medplanetarno magnetno polje IMF (angl. interplanetary magnetic field) in stalen električni tok, ki obkroža Zemljo v ekvatorialni ravnini (angl. equatorial electrojet). V drugi polovici prejšnjega stoletja so njihov obstoj potrdile meritve z vesoljskimi sondami. V tem stoletju pa je bilo z njimi, po obsežnih predhodnih pripravah (Dungey, 1962) in večkratnih poizkusih, uspešno raziskano tudi področje magnetosfere in plazmosfere, ter ugotovljen vzrok za njeno dodatno polnjenje s hladno plazmo v času močnih geomagnetnih neviht (Xiao et al, 2007; Treumann et al, 2009). Ugotovljen in potrjen je bil torej vzrok za nastanek SAR-ov v srednjih geografskih širinah.

### Zaključki

Pri današnjem urbanem načinu življenja spremljajo svetlobne pojave na nočnem nebu le še posamezniki, ki jih to zanima. Na njem obstaja tudi stalen vir difuzne svetlobe, ki ni neposredno sevanje Sonca v vidnem delu spektra temveč tlenje v atmosferi (angl. airglow). Emisija žarkov UV iz Sonca povzroča v zgornjih plasteh atmosfere fotokemične procese. Vzburjeni atomi kisika sevajo svetlobo zelene barve (Richter et al, 2021). Zato noči niso popolnoma temne. Poleg intenzivnosti sevanja Sonca vpliva na to tlenje tudi planetarno valovanje v atmosferi na njenih velikih višinah (Dickinson, 1969). Mehanizem tlenja v atmosferi torej ni enostaven in tudi še ne docela raziskan. V izjemnih pogojih povzroči tudi svetle noči (lat. solis nocturnus, angl. bright nights) (Shepherd & Cho, 2017).

Svetlobni pojavi, nastali zaradi hitrih sprememb v magnetnem polju Zemlje, niso le zanimivost sama zase, temveč so tudi znanilci vplivov geomagnetnega polja tako na

življenje na Zemlji (Čop, 2022) kot tudi na našo civilizacijo (Čop & Jere Jakulin, 2022). Živimo v tem magnetnem polju in zato Sonce vpliva na naše življenje in na vse oblike naše dejavnosti (Jere Jakulin & Čop, 2017). Nekatere od teh dejavnosti so pod njegovim neposrednim vplivom, med njimi predvsem elektroenergetika (Kirkham et al, 2011), satelitski radionavigacijski sistemi (Zhang et al, 2020; Android Platform, 2023) in brezžični komunikacijski sistemi (Čop, 2015) ter praktično vsa človekova dejavnost.

## Literatura

- Android Platform. GeomagneticField. (2023). Android for Developers. <https://developer.android.com/reference/android/hardware/GeomagneticField#public-methods> (4.12.2023)
- Cornwall, J. M. Coroniti, F. V. Thorne, R. M. (1970). A unified theory of SAR Arc. Formation at the Plasmopause. Los Angeles (US): University of California; Department of Physics, 52p.
- Čop, R. (2015). Vpliv Sonca na prenos merilnih podatkov v realnem času po omrežju mobilne telefonije. *Geodetski vestnik*, 60 (2), 197–21.
- Čop, R. Deželjin, D. De Reggi, R. (2015). Določitev lokalnega geomagnetnega indeksa K. *Geodetski vestnik*, 59 (4), 697–708.
- Čop, R. (2020). Spremembe števila geomagnetnih neviht in števila sončnih peg: mesečni, desetletni in stoletni naravni cikli. Raziskave s področja geodezije in geofizike 2019. Zbornik del. Ljubljana: Slovensko združenje za geodezijo in geofiziko – SZGG, 21–28.
- Čop, R. (2022). Magnetna polja in kresnice. Raziskave s področja geodezije in geofizike 2021. Zbornik del. Ljubljana: Slovensko združenje za geodezijo in geofiziko, 121–126.
- Čop, R. Jere Jakulin, T. (2022). The Influence of the Sun on our Lives. *International Journal for Quality Research*, 16 (3), 703–716.
- Dickinson, E. R. (1969). Theory of Planetary Wave-Zonal Flow Interaction. *Journal of the Atmospheric Sciences*, 26 (1), 73–81.
- Dungey, J. W. (1962). The Interplanetary Magnetic Field and the Auroral Zones. AFCRL-62-423. Scientific Report No. 157. State College (PA, US): The Pennsylvania State University, 35 p.
- Egeland, A. Burke, J. W. (2013). Carl Störmer. Auroral Pioneer. Berlin; Heidelberg; Springer-Verlag, 195 p.
- Foster, J. C. Buonsanto, M. Mendillo, J. Nottingham, M. D. Rich, F. J. Denig, W. (1994). Coordinated stable auroral red arc observations: Relationship to plasma convection. *Journal of Geophysical Research*, 99 (A6), 429–439.
- Geomagnetic Kp index. (2023). Potsdam (Germany): Helmholtz-Zentrum Potsdam - Deutsches GeoForschungsZentrum GFZ. <https://kp.gfz-potsdam.de/en/> (3.12.2023)
- Geomagnetic storm watch (G2). (2023). SpaceWeather, 2019–2023. <https://www.spaceweather.com/archive.php?view=1&day=04&month=11&year=2023> (4.11.2023)
- Gillies, D. M. Liang, J. Gallardo-Lacourt, B. Donovan, E. (2023). New insight into the transition from a SAR arc to STEVE. *Geophysical Research Letters*, 50, e2022GL101205.
- ISGI - International Service of Geomagnetic Indices. (2023). Strasbourg (France): SIIG/ISGI. <https://isgi.unistra.fr/> (3.12.2023)
- Jere Jakulin, T. Čop, R. (2017). Sunspot Cycles Impacts on Tourism and Quality of Life. *International Journal for Quality Research*, 11 (3), 717–728.
- Kirkham, H. Makarov. Y. V. Dagle, J. E. Desteese, J. G. Elizondo, M. A. Diao, R. (2011). Geomagnetic Storms and Long-Term Impacts on Power Systems. PNNL-21033. Prepared for the U.S. Department of Energy under Contract DE-AC05-76RL01830. Richland (WA, US): Pacific Northwest National Laboratory, 37 p.
- LASCO, The Large Angle and Spectrometric Coronagraph Experiment. (1994). LASCO Handbook for Scientific Investigators, Version 1.0. Official U.S. Navy Web Site.
- LASCO Coronagraph. (2023). Boulder (CO, US): National Oceanic and Atmospheric Administration; Space Weather Prediction Center.

- <https://www.swpc.noaa.gov/products/lasco-coronagraph> (3.11.2023)
- Mayaud, P. N. (1980). Derivation, Meaning, and Use of Geomagnetic Indices. Gophysical monograph 22. Washington (DC, US): American Geophysical Union, 154 p.
- NOAA Space Weather Scales. (2011). Boulder (CO, US): National Oceanic and Atmospheric Administration; Space Weather Prediction Center.
- Nishimura, Y. Dyer, A. Kangas, L. Donovan, E. Angelopoulos, V. (2023). Unsolved problems in Strong Thermal Emission Velocity Enhancement (STEVE) and the picket fence. *Frontiers in Astronomy and Space Sciences*, 10.
- Richter, H. Buchbender, C. Güsten, R. Higgins, R. Klein, B. Stutzki, J. Wiesemeyer, H. Hübers, H.-W. (2021). Direct measurements of atomic oxygen in the mesosphere and lower thermosphere using terahertz heterodyne spectroscopy. *Communications Earth & Environment*, 2, 19.
- Rypdal, K. Brundtland, T. (1997). The Birkeland Terrella Experiments and their Importance for the Modern Synergy of Laboratory and Space Plasma Physics. *Journal de Physique IV*, 7 (C4), C4-113-C4-132.
- Shepherd, G. G. Cho, Y.-M. (2017). WINDII airglow observations of wave superposition and the possible association with historical “bright nights”. *Geophysical Research Letters*, 44, 7036–7043.
- Solar Cycle Progression. (2023). Boulder (CO, US): National Oceanic and Atmospheric Administration; Space Weather Prediction Center. <https://www.swpc.noaa.gov/products/solar-cycle-progression> (24.11.2023)
- Treumann, R. A. Jaroschek, C. H. Pottellette, R. (2009). Auroral evidence for multiple reconnection in the magnetospheric tail plasma sheet. *EPL*, 85, 49001.
- Xiao, C. J. Wang, X. G. Pu, Z. Y. Ma, Z. W. Zhao, H. Zhou, G. P. Wang, J. X. Kivelson, M. G. Fu, S. Y. Liu, Z. X. Zong, Q. G. Dunlop, M. W. Glassmeier, K.-H. Lucek, E. Reme, H. Dandouras, I. Escoubet, C. P. (2007). Satellite observations of separator-line geometry of three-dimensional magnetic reconnection. *Nature Physics*, 3, 609–613.
- Zhang, S. He, L. Wu, L. (2020). Statistical Study of Loss of GPS Signals Caused by Severe and Great Geomagnetic Storms. *Journal of Geophysical Research: Space Physics*, 125 (9), e2019JA027749.

# Snežišča okoli Prisojnika iz spletnih kamer

Mihaela Triglav Čekada<sup>\*,\*\*</sup>, Peter Lamovec<sup>\*</sup>

## Povzetek

Članek je nadaljevanje lani objavljenega članka o snežišču v Skednju pod Prisojnikom, ki smo ga nadgradili še z analizo snežišč, ki ležijo na severozahodni strani Prisojnika nad dolino Suhe Pišnice. Za podrobno letno analizo spreminjanja omenjenih snežišč v letu 2023 smo uporabili posnetke narejene s pomočjo spletnih kamer z jezera Jasna in Erjavčeve koč. Obdelali smo še nekaj posameznih fotografij starejšega stanja, ki prikazujejo vsa ta snežišča. Za leto 2023 smo ugotovili, da vsa tri snežišča nad dolino Suhe Pišnice izginejo v sredini avgusta, medtem ko snežišče v Skednju vztraja vsaj do konca prvega tedna septembra. Največje med snežišči nad dolino Suhe Pišnice pa maja ali junija vseeno pokriva le približno polovico takratne površine snežišča v Skednju. Podrobna analiza spreminjanja snežišča v Skednju skozi štiri poletja, to je v letih med 2020 in 2023, je pokazala še, da lahko pričakujemo v začetku julija njegovo površino med 5,5 in 1,5 ha, do začetka avgusta pa se zmanjša na 4 do 1 ha. Med obravnavanimi leti je bilo za njegovo ohranjanje najugodnejše leto 2021. To leto je imelo med obravnavanimi leti tudi najnižjo povprečno letno temperaturo na Kredarici.

**Ključne besede:** snežišče, Snežišče v Skednju pod Prisojnikom, snežišča nad dolino Suhe Pišnice, površina, interaktivna metoda fotogrametrične orientacije

**Key words:** snowfield, snowfield Skedenj under Prisojnik, snowfields above the valley of Suha Pišnica river, area, monoplottting

## Uvod

Pod Prisojnikom (ali po domače Prisankom) poleg njegovega največjega snežišča v Skednju, ki ga je nekdaj štel Badjura (1922, str. 43) med ledenike, najdemo na njegovi severozahodni strani, ki se nahaja nad dolino Suhe Pišnice, še več manjših snežišč, ki jih imenuje Gams (1961): ledišče v Suhi Pišnici, zgornje snežišče v Suhi Pišnici in snežišče nad slapom v Prisojniku. Prvi jih je na karto izrisal Gams (1961), medtem ko na kartah Badjure (1913, 1922) najdemo od snežišč pod Prisojnikom izrisano le snežišče v Skednju, ne pa tudi preostalih treh manjših snežišč nad dolino Suhe Pišnice. Žal nismo uspeli Gamsovega opisa posameznega snežišča in lokacije, ki jo je podal na karti, enoznačno povezati, zato smo se odločili, da bomo snežišča nad dolino Suhe Pišnice le oštevilčili (slika 1). Obravnavali bomo snežišča nad dolino Suhe Pišnice, ki se nahajajo na nadmorskih višinah med 1600 in 2000 m. Vsa se nahajajo ob današnji Hanzovi poti, ki vodi na Hudičev steber in Prisojnik.


Na ortofotu Cikličnega aerofotografiranja Slovenije (CAS) iz leta 2020 (slika 1), kjer snežišče v Skednju kaže še svojo značilno obliko z dokaj veliko površino 2,8 ha, največje snežišče nad dolino Suhe Pišnice, ki ga bomo oštevilčili s številko 2, leži v skupni krnici nekje na povprečni nadmorski višini 1700 m. Sestavljeno je vsaj iz dveh ločnih večjih snežišč in enega manjšega. Pogled iz Vršiča na snežišče 2 nam deloma zakriva skalna glava z nadmorsko višino 2045 m, ki je na karti Ledinska imena v občini Kranjska Gora imenovana Turn (Klinar in Škofic, 2015). Snežišča 2 na ortofotu CAS iz leta 2020 skupaj merijo 0,9 ha. Pod krnico na povprečni nadmorski višini 1600 m se nahaja snežišče 1, nad krnico na povprečni nadmorski višini okoli 2000 m se nahaja snežišče 3. Prvo ima na istem ortofotu površino 0,4 ha, slednje pa 0,2 ha. Snežišče št. 1 je najverjetneje snežišče, ki ga je Gams

\* Geodetski inštitut Slovenije, Jamova c. 2, 1000 Ljubljana,

\*\* Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Jamova c. 2, 1000 Ljubljana

(1961) poimenoval snežišče nad slapom v Prisojniku, Tuma (1907) pa snežišče nad vodopadom. Domačini temu snežišču pravijo tudi snežišče pod Hudičevim stebrom. Snežišču št. 2 pa snežišče za Turnom. Le ta naj bi bil nekoč celo povezan z najvišjeležečim snežiščem št. 3 (Polajnar, 2023).

Snežišča nad dolino Suhe Pišnice lepo vidimo tudi iz Erjavčeve kočice na Vršiču, kjer se nahaja spletna kamera, ki snema severozahodno ostenje Prisojnika (Erjavčeva kočica na Vršiču, 2023). Kamera nam omogoča, da skozi poletje spremljamo kako izginjajo ta snežišča. Na jezeru Jasna, na Jasna Chalet Resortu, se nahaja še ena spletna kamera, ki snema severno ostenje Prisojnika in na njej lahko spremljamo tudi spreminjanje snežišča v Skednju (Jasna Chalet Resort, 2023). Od maja do konca septembra 2023 smo približno enkrat na dva tedna zajeli zaslonske posnetke z obeh spletnih kamer, ki smo jih obdelali z interaktivno metodo orientacije, enako kot smo naredili lani s fotografijami snežišča v Skednju (Triglav Čekada, Adjova, 2023).



Slika 1: Obravnavana snežišča pod Prisojnikom (vir podlage: CAS, 2020).

Na osnovi fotografij narejenih v različnih letih, ki smo jih po javnem pozivu na lanskem posvetu Slovenskega združenja za geodezijo in geofiziko dobili od različnih avtorjev, smo zgoščili še letno časovno vrsto spreminjanja snežišča v Skednju ter pričeli sestavljati letno časovno vrsto za snežišča nad dolino Suhe Pišnice. Tudi tu smo za orientacijo fotografij in zajem obodov snežišč uporabili interaktivno metodo orientacije. Vendar smo tu potrebovali za orientacijo nekaj več časa, saj so bile fotografije narejene iz različnih stojišč okoli Kranjske gore in Vršiča.

Še nekaj besed o poimenovanju snežišča v Skednju pod Prisojnikom. Avtorja sva ime povzela enako kot snežišče imenuje Gams (1961). V starejši literaturi krnico imenujejo tudi V Škednju, tako je poimenovana še na planinski karti Jalovec in Mangart (PZS, 2016), domačini pa ji še danes večinoma pravijo U Skednjah (Polajnar, 2023), kar lahko razberemo tudi s karte Ledinska imena v občini Kranjska Gora (Klinar in Škofic, 2015).



## Spletne kamere in snežišča v Skednju ter nad dolino Suhe Pišnice

Po začetku maja 2023 smo približno na vsaka dva tedna zajeli zaslonske slike s spletne kamere na Jasna Chalet Resortu ob jezeru Jasna, ki prikazuje tudi snežišče v Skednju, ter spletne kamere z Erjavčeve koče na Vršiču, ki prikazuje nekatera snežišča nad dolino Suhe Pišnice. Medtem, ko je snežišče v Skednju z jezera Jasna vidno celo, pa so snežišča nad dolino Suhe Pišnice z Erjavčeve koče delno zakrita s kamnito glavo imenovano Turn, ki se nahaja pred njimi. Teoretično bi se na posnetkih narejenih s spletno kamero na jezeru Jasna morali deloma videti še snežišči 2 in 3, vednar je ta del velikokrat premočno osvetljen, zato ne moremo ločiti med snegom in skalami. Ko smo delali zaslonske slike s spletne kamere na jezeru Jasna, smo se večinoma osredotočali na to, da je bilo snežišče v Skednju lepo vidno, kar pomeni enakomerno osvetljeno, torej v jutranji senci, okolica pa je lahko bila medtem že močnejše osvetljena. Zato smo za izmero snežišča v Skednju uporabili samo spletno kamero z jezera Jasna, za izmero snežišč nad dolino Suhe Pišnice pa samo spletno kamero iz Erjavčeve koče.


Preglednica 1: Površina snežišč v poletju 2023 v Skednju pod Prisojnikom ter snežišč nad dolino Suhe Pišnice iz spletnih kamer na Jasna Chalet Resortu ob jezeru Jasna ter Erjavčeve koče na Vršiču.

Datum	Površina			
	Snežišče v Skednju	Snežišče 3	Snežišče 2	Snežišče 1
27. 5. 2023	14,9 ha	1,0 ha	3,1 ha	1,1 ha
1. 6. 2023	11,0 ha	0,9 ha	3,1 ha	0,9 ha
16. 6. 2023	6,8 ha	0,7 ha	2,4 ha	0,8 ha
29. 6. 2023	3,0 ha	0,4 ha	1,7 ha	0,4 ha
12. 7. 2023	2,8 ha	0,3 ha	1,0 ha	0,3 ha
6. 8. 2023	2,0 ha	0,2 ha	0,4 ha	0,1 ha
14. 8. 2023	0,9 ha	0,1 ha	0,2 ha	0 ha
31. 8. 2023	0,9 ha	0,03 ha	0,01 ha	0 ha
7. 9. 2023	0,4 ha	0 ha	0 ha	0 ha
12. 9. 2023	0,4 ha	0 ha	0 ha	0 ha


Z Erjavčeve koče se vidi celotno najvišje ležeče snežišče 3, del snežišča 2 za Turnom in del snežišča 1 (slika 2). Iz posnetkov narejenih s spletno kamero smo izmerili samo dele, ki se na posnetku vidijo, zato so površine slednjih dveh podcenjene, kar bomo videli v nadaljevanju, ko jih bomo primerjali z rezultati površin pridobljenimi iz ortofotov Cikličnega aerofotografiranja Slovenije.

Površine snežišča v Skednju so na posnetkih spletne kamere zaradi slabe ločljivosti precenjene, saj snežišče predstavlja le majhen del celotnega posnetka. To ugotovimo s primerjavo površin, ki smo jih izmerili na fotografijah narejenih s klasičnim fotoaparatom iz Kranjske Gore, to je 7. 8. 2023 in 9. 9. 2023 (slika 3). Ti fotografiji imata veliko boljšo ločljivost kot spletna kamera, zato je na njiju veliko lažje določiti pravi rob snega. Za 7. 8. 2023 smo izmerili površino 1,0 ha, 9. 9. 2023 pa 0,1 ha, kar je občutno manj kot smo lahko izmerili iz posnetkov narejenih s pomočjo spletne kamere za približno iste datume. Iz te primerjave lahko ocenimo, da je po 1. 8. lahko površina pridobljena iz posnetkov spletne kamere precenjena za tudi do 1 ha (razlika med 6. 8. narejenim s spletno kamero in 7. 8. 2023 narejenim s fotoaparatom).

Generalno nam preglednica 1 pove, katera snežišča so v poletju 2023 izginila najprej: snežišče 1 začetek avgusta, snežišča 2 in 3 pa konec avgusta. Snežišče v Skednju pa se je ohranilo vsaj do sredine septembra.



Slika 2: Zmanjševanje snežišč nad dolino Suhe Pišnice v poletju 2023 (foto: spletna kamera na Erjavčevi koči na Vršiču, <https://www.erjavcevakoca.com/live-camera-and-videos/>).



Slika 3: Primerjava posnetkov narejnih s pomočjo spletne kamere ob jezeru Jasna – levo (foto: Jasna Chalet Resort, [https://www.hribi.net/spletna\\_kamera/jezero\\_jasna/3352](https://www.hribi.net/spletna_kamera/jezero_jasna/3352)) in fotografij narejnih s klasičnim fotoaparatom iz Kranjske gore – desno (foto: M. Triglav Čekada).

### Snežišče v Skednju iz fotografij

Preglednica 2: Spremljanje površine snežišča v Skednju pod Prisojnikom od 1906 do 2023.


Datum	Vir ali avtor	Površina
1906 (r)	Ravnihar et al. (2009), str. 49	10,6 ha
7. 1912 (r)	Ravnihar et al. (2009), str. 48	8,3 ha
1915 (r)	Gorenjski muzej Jesenice	11,6 ha
16. 9. 1959	Gams (1961), str. 255, sl. 6	3,3 ha
pred 1970*	Jaka Čop (Banovec et al., 1970)	5,0 ha
31. 7. 1999	Zvone Kosovelj	1,3 ha
29. 7. 2003	Dušan Polajner	1,0 ha
5. 8. 2006	Dušan Polajner	3,3 ha
7. 2007	Miha Pavšek	2,0 ha
11. 8. 2008	Krunoslav Indir	2,3 ha
22. 8. 2015	Anže Gregorič, Bogomir Košir	0,1 ha
30. 8. 2016	Breda Vrenčur	2,9 ha
6. 8. 2017	Anže Gregorič	0,5 ha
26. 6. 2018**	M. Triglav Čekada	4,8 ha
31. 7. 2020	Špela Intihar	2,8 ha
18. 9. 2021	M. Triglav Čekada	2,7 ha
5. 9. 2022	M. Triglav Čekada	0,5 ha
9. 9. 2023	M. Triglav Čekada	0,1 ha

\*v Triglav Čekada in Adjova (2022) je fotografija napačno datirana kot 7. 1972. Planinska založba Slovenije.

\*\* fotografija je posneta iz poti v Krnico, kjer je velik del snežišča zakrit in površina temelji tudi na sklepanju glede na delno viden zgornji rob, ki prikazuje samo vzhodni del snežišča.

Preglednica 2 prikazuje spremljanje površine snežišča v Skednju sredi ali konec določenega poletja. V bistvu je to preglednica 3 iz Triglav Čekada in Adjova (2023), ki smo jo dopolnili z novimi površinami, ki smo jih izmerili iz fotografij, ki so nam jih poslali različni avtorji, ki jih navajamo v stolpcu avtor. Dodali smo leta 1999, 2003, 2006 in 2023.


Obdelali smo še fotografiji z dne 27. 6. 2020 M. Triglav Čekade in 10. 7. 2022 Aleša Robiča, ki sta nam pomagala zgotoviti poletne časovne vrste spreminjanja Snežišča v Skednju za posamezno leto, ki smo jih prav tako prikazali že v tabelah v lanskem članku (Triglav Čekada in Adjova, 2023). Letos jih ponovno podajamo v grafični obliki (slika 4). Za 26. 6. 2020 smo izmerili površino snežišča na 4,8 ha, za 10. 7. 2022 pa na 1,9 ha. Na grafu na sliki 4 vidimo, da je bilo med primerjanimi leti 2020, 2021, 2022 in 2023 najugodnejše leto za ohranjanje snežišča leto 2021. Tako obnašanje se ujema s povprečnimi letnimi temperaturami na Kredarici (slika 5), kjer vidimo, da je bila ta v letih 2020, 2022 in 2023 pozitivna, v letu 2021 pa je bila negativna. Za lažjo predstavbo smo letom z več kot štirimi meritvami dodali trendne linije, uporabili smo osnovno potenčno funkcijo.



Slika 4: Podrobno zmanjševanje površine snežišča v Skednju v poletjih: 2020, 2021, 2022 in 2023. Ker smo imeli za leto 2020 le dve fotografiji, za to leto nismo izrisali trendne linije.

Iz grafa 4 lahko razberemo še, da lahko pričakujemo v začetku julija površino Snežišča v Skednju med 5,5 in 1,5 ha, do začetka avgusta pa se ta zmanjša na 4 do 1 ha. Ta ugotovitev nam lahko pomaga tudi pri ugotavljanju, kako se je snežišče verjetno zmanjševalo v letih, za katera v preglednici 2 nimamo fotografij za snežišče ob koncu posamezne talilne dobe (začetek septembra). Na osnovi tega lahko sklepamo, da so bila za snežišče slaba leta 1999, 2003, 2015, 2017 ter zadnji dve leti.

Na grafu 5 so prikazane površine snežišča iz Skednja iz preglednice 2 skupaj z letnimi povprečnimi temperaturami na Kredarici. Izrisali smo samo površine, ki prikazujejo snežišče konec julija, v avgustu ali septembru, zato površin, ki smo jih izmerili iz ortofotov cikličnega aerofotografiranja Slovenije, za katere še nismo pridobili točnih datumov snemanj, nismo dodali. Ker smo za posamezno leto površino izmerili iz fotografij, ki ne prikazujejo snežišča ravno konec talilne dobe, so površine med sabo dokaj neprimerljive.



Slika 5: Površine snežišča v Skednju od leta 1999 do 2023 ter povprečne letne temperature na Kredarici (vir: Arhiv ARSO, 2024).


### Snežišča nad dolino Suhe Pišnice iz fotografij in državnih ortofotov

Orientirali smo tudi fotografije, ki prikazujejo samo snežišča nad dolino Suhe Pišnice, to sta primera iz ceste na Vršič ter iz Kumlehove glave (slika 6), ki nam jih je poslal Zvone Kosovelj. Občasno se del snežišč nad Suho Pišnico vidi tudi na fotografijah, ki so bile posnete iz Kranjske gore. Večinoma na njih prepoznamo le snežišče 3 ter del snežišča 2. Za razliko od letne časovne vrste za Snežišče v Sednju, imamo tu večino fotografij iz junija in julija. Tako na primer 10. 6. 2008 in 11. 8. 2008 nista direktno primerljiva.

Preglednica 3: Spremljanje površine snežišč nad dolino Suhe Pišnice pod Prisojnikom od 2003 do 2023.

Datum	Vir ali avtor	Površina		
		Snežišče 3	Snežišče 2	Snežišče 1
29. 7. 2003	Dušan Polajner	0,1 ha	ni videti	ni videti
5. 8. 2006	Dušan Polajner	ni videti	0,2 ha	ni videti
10. 6. 2008	Zvone Kosovelj	1,1 ha	3,6 ha	ni videti
27. 6. 2020	M. Triglav Čekada	0,6 ha	0,6 ha	ni videti
17. 7. 2021	M. Triglav Čekada	0,5 ha	1,3 ha	ni videti
2. 7. 2022	Zvone Kosovelj	0,3 ha	1,0 ha	0,6 ha
12. 7. 2023*	Erjavčeva koča	0,3 ha	1,0 ha	0,3 ha

\*Ker imamo večino fotografij starejšega datuma iz začetka ali najkasneje srede julija smo tudi za leto 2023 dodali površino iz sredine julija.



Slika 6: Fotografija z lepo vidnimi snežišči na SZ strani Prisojnika. Na fotografiji se vidi snežišče 1 – Snežišče nad slapom v Prisojniku (na sliki obkroženo spodaj) ter snežišči 2 in 3 (obkroženo skupaj). Del snežišča 2 je skrit za Turnom (foto: Zvone Kosovelj, 2. 7. 2022).

Na ortofotih CAS in na podobi analitičnega senčenja laserskega skeniranja Slovenije (LSS) je snežišče 2 vedno sestavljeno iz vsaj dveh delov, katerih skupno površino podajamo v preglednici 4. Zavedati se moramo dejstva, da so stereofotografije za izdelavo ortofotov CAS ponavadi posnete nekje od konca junija do konca julija, zato teh površin nikakor ne smemo obravnavati kot posnetih konec talilne dobe. S pomočjo preglednice 2 lahko naredimo direktno primerjavo za Snežišče v Skednju za leta 2006, 2015, 2017 in 2020 ter s tem ugotovimo, kdaj je bilo verjetno izvedeno snemanje CAS. V letu 2006 je površina podobna tisti iz fotografije posnete začetek avgusta. V letu 2015 je bilo snemanje CAS izvedeno veliko pred koncem avgusta, saj v preglednici 2 dobimo za konec avgusta površino 0,1 ha. Zaradi podobnih površin v 2017 je moralo biti snemanje CAS takrat izvedeno nekje začetek avgusta. Za leto 2020 smo določili podobne površine, zato je moralo biti snemanje CAS izvedeno konec julija.

Preglednica 4: Površina snežišč v Skednju in nad dolino Suhe Pišnice iz ortofotov Cikličnega aerofotografiranja Slovenije (ortofoto CAS) in lidarske podobe analitičnega senčenja (LSS).

Leto	državno snemanje	Površina			
		Snežišče v Skednju	Snežišče 3	Snežišče 2	Snežišče 1
2006	ortofoto CAS	3,4 ha	0,3 ha	1,5 ha	0,6 ha
2011	ortofoto CAS	3,0 ha	0,2 ha	1,0 ha	0,4 ha
15. 6. 2014	LSS	4,2 ha	0,3 ha	2,5 ha	1,0 ha
2015	ortofoto CAS	3,4 ha	0,2 ha	1,3 ha	0,4 ha
2017	ortofoto CAS	0,4 ha	0,0 ha	0,0 ha	0,0 ha
2020	ortofoto CAS	2,8 ha	0,2 ha	0,9 ha	0,4 ha

## Sklep

Sodelovanje javnosti pri iskanju starejših fotografij snežišč pod Prisojnikom se je izkazalo za zelo uporabno, saj smo lahko zgotovili časovno vrsto spreminjanja Snežišča v Skednju pod Prisojnikom tako, da imamo sedaj obdobje od 1999 do danes dokaj enakomerno pokrito s površinami, ki smo jih izmerili na osnovi arhivskih fotografij. Uporabljena metoda nam omogočila začetek preučevanja manjših snežišč na Prisojniku, ki se nahajajo na njegovi severozahodni strani nad dolino Suhe Pišnice in so predvsem vidna iz ceste na Vršič in okolice. Hkrati smo s pomočjo fotografij lahko ocenili uporabnost zaslonskih posnetkov, narejenih s pomočjo spletnih kamer na Chalet Resortu Jasna in Erjavčevi koči, ki nam prav tako omogočata preverbo, kaj se s snežišči dogaja tekom posamezne talilne dobe oz. poletje. S preučevanjem časovne vrste površin, ki smo jih izmerili iz posnetkov spletnih kamer, smo lahko ugotovili, da so snežišča nad dolino Suhe Pišnice začetek poletja vsaj za polovico manjša od snežišča v Skednju ter da izginejo sredi avgusta, medtem ko snežišče v Skednju večinoma vztraja tudi še v sredo septembra. Primerjava površin dobljenih s pomočjo spletnih kamer in iz navadnih fotografij je pokazala še, da pri majhnih površinah snežišč ločljivost spletnih kamer postane omejujoč faktor, saj lahko izmerimo prevelike površine. Zato bomo morali v prihodnosti kombinirati oba vira podatkov, tako spletne kamere kot tudi navadne fotografije narejene s fotoaparati višje ločljivosti.

Na koncu bomo ponovili našo lansko prošnjo, ki jo bomo letos razširili na snežišča Martuljkove skupine. Bralce vljudno naprošamo, če imajo doma shranjene arhivske fotografije snežišč okoli Prisojnika ali pa snežišč v Martuljski skupini, naj nam jih pošljejo, da bomo lahko drugo leto našo raziskavo časovno in prostorsko razširili.

## Zahvala

Najprej bi se posebej zahvalila Dušanu Polajnarju za podrobno zgodovinsko preverbo poimenovanj krnice v Skednju ter snežišč nad dolino Suhe Pišnice. Potem bi se najlepše zahvalili še vsem avtorjem arhivskih fotografij, ki so se odzvali na naš lanski poziv, da zbiramo fotografije snežišč okoli Prisojnika: Dušanu Polajnarju, Alešu Robiču, Zvonetu Kosovelju in Blažu Kogovšku. Zahvalili bi se še Jasna Chalet Resortu na jezeru Jasna ter Erjavčevi koči na Vršiču, da sta nam dovolila uporabo njihovih spletnih kamer.

Delo je delno nastalo v okviru temeljnih raziskovalnih projektov J6-4634 in J7-50095, ki ju financira Javna agencija za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije (ARIS).

## Literatura

- Arhiv ARSO (2023). Arhiv – opazovani in merjeni meteorološki podatki po Sloveniji, <https://meteo.arso.gov.si/met/sl/archive/> (dostopano 5. 1. 2024)
- Badjura, R. (1913). Na Triglav, v kraljestvo Zlatorogovo. Ljubljana.
- Badjura, R. (1922). Jugoslovenske Alpe. Praktični vodič. Ljubljana.
- Banovec, T., Klinar, M., Munda, J., Savenc, F. (1970). Plezalni vzponi Vhodne Julijske Alpe. Planinska založba Slovenije.
- Gams, I. (1961). Snežišča v Julijskih Alpah. Geografski zbornik, 6, 243–269.
- Klinar, K., Škofic, J. (2015). Ledninska imena v občini Kranjska Gora merilo 1 : 25 000. Razvojna agencija Zgornje Gorenjske. <https://ragor.si/wp-content/uploads/2021/07/ragor-ledinska-imena-zemljevid-Kranjska-Gora.pdf>
- Polajnar, D. (2023). Osebna komunikacija.
- PZS (2016). Planinska karta Jalovec in Mangart v merilu 1:25 000. Planinska zveza Slovenije.

- Ravnihar, M., Dolar, N., Dolar, M. (2009). Pozdrav z vrhov: planinstvo na starih razglednicah. Žirovnica: Medium.
- Erjavčeva koča na Vršiču (2023). Spletna kamera: <https://erjavcevakoca.si/posnetki/>, [https://www.hribi.net/spletna\\_kamera/erjavceva\\_koca\\_na\\_vrsicu/4354](https://www.hribi.net/spletna_kamera/erjavceva_koca_na_vrsicu/4354)
- Jasna Chalet Resort (2023). Spletna kamera: [https://www.hribi.net/spletna\\_kamera/jezero\\_jasna/3352](https://www.hribi.net/spletna_kamera/jezero_jasna/3352)
- Triglav Čekda, M., Adjova, L. (2023). Površina snežišča v Skednju pod Prisojnikom iz fotografij. V: Kuhar, M. (ur.), et al. Raziskave s področja geodezije in geofizike 2022 : zbornik del : 28. srečanje Slovenskega združenja za geodezijo in geofiziko, Ljubljana, 26. januar 2023. Ljubljana: Slovensko združenje za geodezijo in geofiziko, str. 95-103.
- Tuma, H. (1907). Prisojnik (2559 m). Planinski vestnik, XIII, št. 10, 153-156.



# Analiza odstopanj izkopa in primarnih površin predora iz fotogrametričnih oblakov točk

Tilen Urbančič\*, Jure Česnik\*\*

## Povzetek

Med izkopavanjem predorov po novi avstrijski metodi je potrebno za vse izkopne faze in faze izvedbe primerne podgradnje izvesti analizo skladnosti dejanskih površin s teoretičnimi linijami, predpisanimi v podpornih tipih. V članku predstavljamo inovativen pristop, kjer smo z lastnimi programskimi rešitvami v prvi fazi avtomatizirali postopek obdelave podatkov fotogrametričnega zajema in izdelavo oblakov točk površine izkopa in brizganega betona primarne podgradnje predora. Georeferencirane in filtrirane oblake točk smo skupaj z osjo predora in profili teoretičnih linij uporabili v drugi fazi. Le-ta vključuje analizo odstopanj od teoretičnih linij izkopa in brizganega betona primarne podgradnje ter debeline nanešenega betona. S predstavljenim postopkom smo razvili rešitev, ki omogoča neodvisne analize z izrisi različnih profilov in razvitih pogledov odstopanj z numeričnimi izsledki.

**Ključne besede:** fotogrametrija, oblak točk, analiza odstopanj, izkop predora, brizgan beton  
**Keywords:** photogrammetry, point cloud, deviation analysis, tunnel excavation, shotcrete

## Uvod

Razvoj sodobnih tehnologij za masovni prostorski zajem podatkov je med drugim privedel tudi do posodobljenega pristopa za ocenjevanje kakovosti geometrije izkopa in izdelave primarne obloge v predorogradnji. Tovrstne kontrole so potrebne v primeru gradnje predorov po novi avstrijski metodi (NATM) (Wittke et al., 2006). Poleg geometrijskih analiz oblaki točk omogočajo določanje dejanskih pomikov primarne obloge, saj analize oblakov točk omogočajo celovitejšo določitev oblike površine, ki omogoča določitev neizvršenih deformacij. Pomembna prednost metod obdelave oblakov točk v predorogradnji omogoča celovit vpogled v geometrijo celotnega oboda predora in poznavanje podrobne geometrije. Tovrstni rezultati se po natančnosti in uporabnosti močno razlikujejo od rezultatov običajnih tahimetričnih izmer točk merskih profilov.

Vsa pravila in geometrijske količine, ki jih je v primeru gradnje z NATM potrebno upoštevati pri analizi izkopavanja predora ali odklonov primarnih oblog, so opredeljene v avstrijskem standardu ÖNORM B 2203-1 (ÖNORM B 2203-1, 2001) (Slika 1). Vse količine povezane z geometrijo izkopa, prekomernim izkopavanjem, izvršenimi deformacijami in podobno so kasneje določene kot pričakovane vrednosti v fazi projektiranja, natančno pa se jih iz nabora možnih variant iz faze projektiranja določa v času gradnje predora na osnovi spremljanja geološke sestave hribine in izvršenih deformacij.


Kar zadeva metode zajema prostorskih podatkov, sta se za zajem oblike geometrije izkopane površine in površine brizganega betona dodobra uveljavili tako metoda terestričnega laserskega skeniranja (TLS) (Sun et al., 2020) kot fotogrametrija (Attard et al.,

---

\* Geotočka d.o.o, Tehnološki park 24, 1000 Ljubljana in UL FGG, Jamova 2, 1000 Ljubljana

\*\* ELEA iC d.o.o., Dunajska cesta 21, 1000 Ljubljana

2018). Obe metodi sta v predorogradnji primerni predvsem zaradi brezkontaktnega merjenja, hitrosti terenske izmere, zanesljivosti, popolnosti oblakov točk, geometrijske natančnosti in nenazadnje možnosti poznavanja barvnih vrednosti (RGB) posameznih izmerjenih točk.



Slika 1: Računske sheme: a) izkopna dela in b) betonska dela (ÖNORM B 2203-1, 2001)


V zadnjem času se v praksi pogosteje uporablja fotogrametrična metoda, zato je intenzivnost razvoja tovrstnih sistemov za zajem podatkov in postopkov obdelave podatkov v zadnjem obdobju v primerjavi s TLS večja. Predvsem s ciljem prihranka časa pri terenskem in pisarniškem delu, je glavna motivacija pri razvoju fotogrametričnega zajemanja tudi maksimalna avtomatizacija postopkov. Vsi koraki avtomatizacije so zasnovani tako, da končni izdelek ali rezultati zagotavljajo vsaj enako kakovost, če ne celo boljšo, kot ročno obdelani podatki.

Pravi pomen prostorski podatki velike gostote, ki so rezultat množičnih zajemov, dobijo šele ob pravilni interpretaciji ter izvedbi smiselnih analiz ter včasih celo grafičnih prikazov. Vzporedno z uvajanjem sodobnih sistemov zajema prostorskih podatkov v predorih je torej pomembno, da se je prilagodila oz. izdelala tudi ustrezna programska oprema. Prilagoditi je bilo potrebno programe za obdelave podatkov, izdelati orodja za izrisovanje prečnih profilov in ostalih grafičnih prikazov iz oblakov točk. Geometrično analizo površin iz oblakov točk s primerjano med različnimi projektiranimi in izvedenimi površinami sodobne programske rešitve izvajajo z izrisovanjem razvitega plašča predora ter prečnimi prerezi na izbranih stacionažah. V tem članku predstavljamo pristop za izvedbo tovrstnih analiz v lastno razviti rešitvi OTIS.

V prvem delu članka predstavljamo študijo primera nadgradnje ali delne avtomatizacije postopka obdelave zajetih fotografij za generiranje oblakov točk v programskem okolju Agisoft Metashape. V drugem delu članka predstavljamo geometrijsko analizo površin iz fotogrametričnih oblakov točk. Proces obdelave izvede primerjave teoretičnih projektiranih profilov z realno izvedenimi površinami z namenom izdelave grafičnih predstavitev razvite predorske obloge in prečnih prerezov na izbranih stacionažah. V tem članku predstavljamo naš pristop k izvajanju tovrstnih analiz z lastno programsko rešitvijo OTIS.

## Fotogrametrični zajem

S tehničnega vidika je pogoj za zajem fotografij zadovoljive prostorske ločljivosti in ostrine uporaba ustrezne kamere in osvetlitve. Za izdelavo oblaka točk potrebujemo fotografije z ustreznim vzdolžnim in prečnim preklopom. V trenutnih predorskih projektih v Sloveniji se za zajeme površine izkopa in betonskih oblog uporabljajo kamere kot je npr. dicit FSC 5100-SRsF1x (Urbančič et al., 2021) in dodatna umetna svetloba na ločenem nosilcu. Sistem za zajem ima vgrajen kalibriran fotoaparati, za upravljanje pa vgrajeni ločeni funkciji za fotografiranje med rotacijo in za običajno fotografiranje. S serijo fotografij s treh ali štirih stojišč zagotovimo zadosten preklop za izvedenotenje oblaka točk. Z izravnavo bloka fotografij določimo elemente zunanje orientacije fotografij. Najbolj uveljavljena metoda je zaradi svoje učinkovitosti grajenje strukture iz gibanja oz. SfM fotogrametrija (angl. Structure from Motion) (Schönberger in Frahm, 2016). Končni rezultat obdelave fotografij je modeliranje gostega oblaka točk (Slika 2).




a) b) c)  
Slika 2: Postopek obdelave podatkov: a) fotografije, b) redki oblak točk in c) gost oblak točk in oslonilne točke.

Merilo in lego oblaka točk v izbranem koordinatnem sistemu zagotovimo z oslonilnimi točkami. Na geometrijsko pravilnost oz. notranjo kakovost oblaka točk imajo velik vpliv število in razporeditev danih točk ter način signalizacije (Śledź in Ewertowski, 2022). Kakovost končnega rezultata in samega postopka obdelave lahko v nekaterih programskih paketih izboljšamo z uporabo kodiranih tarč.

Stopnjo avtomatizacije procesa obdelav je možno dvigniti z izdelavo dodatnih orodij in skript, vendar je popolno avtomatizacijo zelo težko doseči. V preteklosti je bil dosežen znaten napredek pri učinkovitosti algoritmov za prepoznavanje umetnih ali naravnih tarč (Remondino, 2006). Kljub tem napredkom imajo umetno signalizirane točke jasne prednosti, saj imajo nedvoumno določeno središče in na splošno dosegajo boljšo natančnost 3D položaja (Fraser, 1997; Fryer et al., 2007). Prav zaradi tega je večina proizvajalcev programske opreme namenila veliko časa razvoju in testiranju kodiranih tarč za zmanjšanje porabljenega časa in uporabo v visoko natančnih aplikacijah. Različne primere kodiranih tarč prikazujemo na Slika 3.

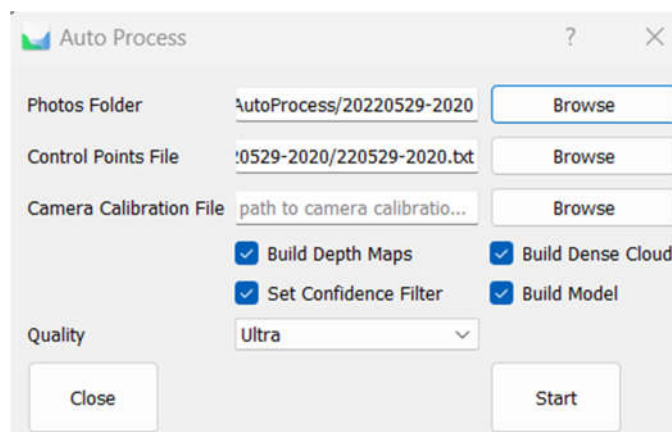
Enako velja za program Agisoft Metashape, kjer so procesi prepoznavanja središča optimizirani z umetnimi kodiranimi cilji. Običajno gre za črno-bele vzorce in s pomočjo ustreznih algoritmov ali rešitev računalniškega vida lahko v koordinatnem sistemu slike določimo značilne točke. Z ustreznim poimenovanjem kontrolne točke program samodejno dodeli koordinate v izbranem koordinatnem sistemu projekta vsaki kontrolni točki (Slika 2). Rešitve, ki vključujejo kodirane cilje, so na voljo tudi v drugi programski opremi za

obdelavo podatkov o fotogrametriji, kot so 3Dsurvey, PIX4D, ReCap Photo, PhotoModeler itd.



Slika 3: Primeri kodiranih tarč: a) okrogla črno-bela tarča, b) kodirana tarča 3DSurvey, c) kodirana tarča Agisoft Metashape.

Drugi korak pri optimizaciji obdelave fotogrametričnih podatkov vključuje uporabo ustreznih in po meri razvitih vtičnikov in skript. V programski opremi, kot je npr. Agisoft Metashape, so avtorji in številni uporabniki programa že ustvarili najrazličnejše skripte, ki so prosto dostopne (<https://github.com/agisoft-llc/metashape-scripts>). Primarni pristopi pri obdelavi terenskih podatkov, ki jih uporabljajo naprednejši uporabniki, so paketna obdelava in ustvarjanje skript v programskem jeziku Python (Slika 4).



Slika 4: Primer izdelanega vtičnika Auto Process.

Z ustrezno polavtomatsko obdelavo lahko uporabnik dokaj hitro ustvari oblak točk območja, ki ga je bil predhodno pravilno fotografiral in opremil s kodiranimi tarčami. Tudi, če je korake modeliranja georeferenciranega oblaka točk mogoče popolnoma avtomatizirati, je za kasnejše korake potrebno še vedno nekaj ročnega dela. Gre predvsem za postopek segmentacije oblaka točk na območja, ki pripadajo posameznim površinam – izkopni površini, prvemu sloju betona, končnemu sloju betona itd.

### **Analiza odstopanj izvedenih površin**

Zagotovitev geometrijsko popolnega in pravilnega oblaka točk, ki predstavlja dejansko izkopano površina ali površino brizganega betona, je le prvi korak v celotni analizi. Za izvedbo analiz iz oblakov točk so potrebna posebna programska orodja, ki omogočajo primerjavo s teoretičnimi profili, opredeljenimi v projektni dokumentaciji predora. Na trgu obstaja več programskih rešitev, kot sta TMS Tunnelscan ali Cyclone 3DR, vendar so te

rešitve drage in naprednejše uporabnike odvrtaajo zaradi tako imenovanega problema "črne skrinjice". Uporabljeni algoritmi in metode niso znane in programov zato ni mogoče pravilno preskusiti in nadzorovati. Razvili smo lastno rešitev, ki nam omogoča izdelavo neodvisnih analiz, ki jih lahko spreminjamo glede na potrebe posameznega projekta.

Izdelali smo programski dodatek OTIS, ki je izdelan s programskim jezikom Grasshopper in kot vtičnik deluje znotraj programa Rhino. Vtičnik omogoča analiziranje in primerjave oblakov točk izkopov ter oblakov točk brizganega betona reta s teoretičnimi profili predora. OTIS-ov proces lahko razdelimo na naslednje korake (Slika 5):

1. Vnos in izbor podatkov (oblak točk, os predora, geometrija profila, stacionaža, dolžina odseka analize)
2. Segmentacija oblakov točk in izbor točk, ki so potrebne za analizo.
3. Projekcija izbranih oblakov točk na teoretične profile, ekstrudirane vzdolž osi.
4. Izdelava mreže nepravilnih trikotnikov in določitev prečnih profilov.
5. Analiza odstopanj na prečnih profilov in mreži nepravilnih trikotnikov.
6. Analiza debeline betona na podlagi izkopa in mreže trikotnikov.
7. Risba končnih rezultatov (profili in razviti pogledi) v pdf formatu.

Slika 5: Uporabniški vmesnik za vnos numeričnih podatkov in izbiro parametrov predora.

Vse te glavne korake je mogoče nadalje segmentirati na postopoma manjše korake do posameznih matematičnih, logičnih ali pretočnih operacij. Te operacije bi se lahko izvajale tudi v kakšni drugi programski opremi ki uporabniku omogoča ustvarjanje in zagon lastnih

skriptov. Razlog za izbor programa Rhino je veliko število predhodno že izdelanih dodatnih knjižnic za kompleksne geometrijske operacije znotraj Grasshopperja. Skupno se med celotno analizo znotraj OTIS-a izvede približno 2500 operacij.

## Rezultati

Fotogrametrični oblaki točk vključujejo vse točke, ki jih je bilo iz preklapov fotografij možno zmodelirati. Gre torej tudi za točke, ki predstavljajo šum in ostale površine, ki niso pomembne za potrebe kontrole kakovosti izkopa oboka oz. izvedbe brizganih betonov – čelo predora, tla predora, nedokončani izkopi oz. brizganje ipd. Iz surovih oblakov točk tako najprej ročno odstranimo vse neželene točke, oblak točk razdelimo na ločene sloje, npr. izkopna površina in površina betona (Slika 6) in jih ločeno po slojih zložimo iz zaporednih odsekov v celovit predor (Slika 7).



Slika 6: Segmentacija oblaka točk na območje, ki pripada izkopni površini in površini brizganega betona.



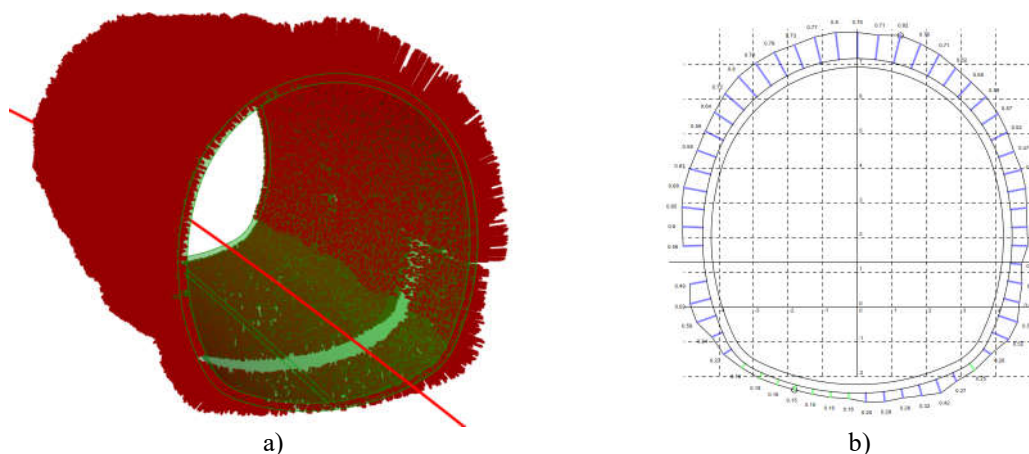
Slika 7: Združen oblak točk izkopne površine.

Tako urejeni prostorski podatki so vhodni podatek za izvedbo geometrijskih analiz in izračun odstopanj od projektiranih linij.

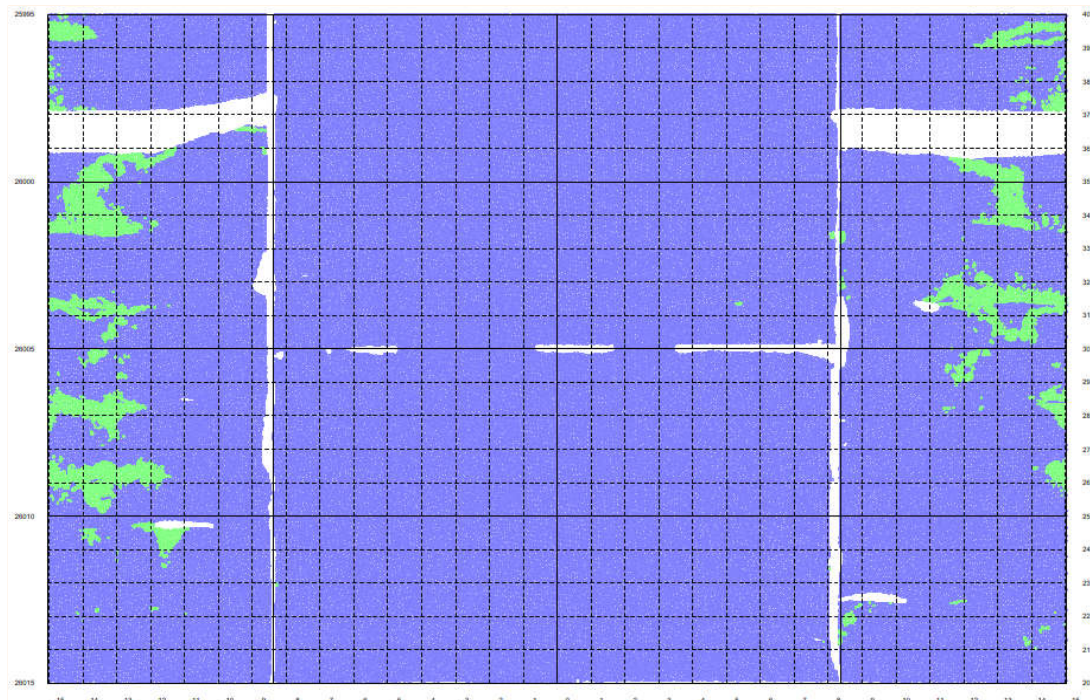
Končni rezultati obdelav so prikazani v dveh oblikah, ki sta pomembni za nadzor del predora: prečni profili z enakomernim korakom vzdolž osi (0,5 m ali 1,0 m) in razviti pogled plašča predora od zgoraj navzdol (Slika 8 in Slika 9). Obe obliki rezultatov prikazujeta naslednje tri vrste analiz:

- barvno označene razdalje od izmerjene površine izkopa do teoretične črte izkopa.
- barvno označene razdalje od merjenja končne površine posnetka do teoretične črte brizganega betona,
- barvno označene debeline od izmerjene površine izkopa do izmerjene končne površine.

Te rezultate uporabi izvajalec ali nadzornik, da oceni kakovost in natančnost postopkov izkopavanja in izvedbe primarnega podporja predora ter jasno pokaže, kje je prišlo do prekomernega ali premajhnega izkopavanja ali kje je treba nabrizgati dodaten beton.



Slika 8: Grafični prikaz izračuna odstopanj: a) 3D pogled na izračunana odstopanja med teoretično in dejansko izkopno linijo in b) izrisan prečni profil odstopanj.



Slika 9: Razviti pogled na plašč predora z obarvanimi vrednostmi odstopanj od teoretične linije.

## Zaključek

Pomemben dejavnik pri različnih gradbeno inženirskih projektih je izvajanje kontrol in spremljanje kakovosti izvedbe del. V predorogradnji se temeljito preverja vse izvedene izkope in betonerska dela, saj je potrebno zagotoviti s projektom določene tolerance posameznih gradbenih faz. V članku predstavljamo razvit postopek oz. celotno metodologijo od zajema terenskih podatkov do izdelave končnih grafičnih prikazov.

Celoten proces obdelave fotografij in analiz iz oblakov točk smo skušali čim bolj avtomatizirati. Kljub avtomatizaciji posameznih korakov je še vedno kar nekaj možnosti za prisotnost napak, predvsem zaradi možnosti človeške napake:

- Na končne rezultate imajo lahko vpliv napaka pri geodetskem merjenju in določanju koordinat kontrolnih točk zaradi netočne in nenatančne geodetske mreže - nepravilno georeferenciranje oblakov točk posameznih izkopnih korakov. Večji problem se lahko pojavi v predorih z manjšimi premiki po izkopavanju in obratno. Potreben je stalen nadzor kakovosti geodetskih referenčnih točk oz. ustrezna transformacija oblakov točk.
- Neustrezni preklopi fotografij povzročajo luknje v oblaku točk, torej lahko dobimo nepopolne in manj zanesljive končne rezultate. Težave zmanjšamo z izkušenim operaterjem in pravilna izbira položajev kamere.
- V oblakih točk se lahko pojavijo sence, čemur se na aktivnem gradbišču zelo težko izognemo. Ker so na nekaterih območjih oblaki zaradi tega brez točk, tam ni mogoče opraviti analiz (glej Slika 8 in Slika 9).
- Slabo prekrivanje oblakov točk med zaporednimi koraki zajemov po izkopavanju ali po vgradnji primarne podpore.
- Nekatero druge težave izhajajo iz različnih človeških napak med obdelavo slik ali izvajanjem analize, vendar jih je mogoče zmanjšati z ustreznim usposabljanjem in več izkušnjami uporabnikov programske opreme. Zato se te napake večinoma pojavijo le v začetni fazi.

Razvili smo skripte in vtičnike za polavtomatsko izdelavo fotogrametričnih oblakov točk izkopne površine in površine primarnih oblog v predoru ter za analizo oblaka točk glede na teoretične linije. To smo naredili z dodatnim skriptiranjem v dveh obstoječih programskih rešitvah (Agisoft Metashape in Rhino), s katerimi smo nadgradili njune prvotne funkcionalnosti. Velika prednost tovrstnega pristopa je, da je postopek možno nadzorovati in ga prilagajati ter nadgrajevati tudi v prihodnje.

## Literatura in viri

- Attard, L., Debanò, C. J., Valentino, G., Di Castro, M. (2018). Tunnel inspection using photogrammetric techniques and image processing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144, 180-188.
- Fraser, C. S. (1997). Innovations in automation for vision metrology systems, *The Photogrammetric Record*, 15, 90: 901-911.
- Fryer, J. G., Mitchell, H. L., Chandler, J. H. (2007). *Applications of 3D Measurements from Images*, Whittles Publishing, Dunbeath, Scotland, 304 p.
- ÖNORM B 2203-1. (2001). Underground works - Works contract - Part 1: Cyclic driving (conventional tunnelling). [https://shop.austrian-standards.at/action/en/public/details/93793/OENORM\\_B\\_2203-1\\_2001\\_12\\_01](https://shop.austrian-standards.at/action/en/public/details/93793/OENORM_B_2203-1_2001_12_01). Pridobljeno 20. 10. 2023.
- Remondino, F. (2006). Detectors and descriptors for photogrammetric applications, *International Archives of Photogrammetry and Remote Sensing*, 36, 3: 49-54.
- Schönberger, J. L., Frahm, J. M. (2016). Structure-from-Motion Revisited, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, 4104-4113.



- Śledź, S., Ewertowski, M. W. (2022). Evaluation of the Influence of Processing Parameters in Structure-from-Motion Software on the Quality of Digital Elevation Models and Orthomosaics in the Context of Studies on Earth Surface Dynamics, *Remote Sensing*, 14, 1312.
- Sun, H., Xu, Z., Yao, L., Zhong, R., Du, L., Wu, H. (2020). Tunnel Monitoring and Measuring System Using Mobile Laser Scanning: Design and Deployment, *Remote Sensing*, 12, 730.
- Urbančič, T., Čuk, T., Burja, T., Dolenc, R., Pajnič, M. (2021). Vpliv glavnih dejavnikov za kakovosten fotogrametrični zajem v predorih. Zbornik referatov, 13. mednarodna konferenca o predorih in podzemnih objektih, Ljubljana, 17.-19. 11. 2021. [https://www.ita-slovenia.si/wp-content/uploads/2021/11/13\\_mkppo\\_zbornik.pdf](https://www.ita-slovenia.si/wp-content/uploads/2021/11/13_mkppo_zbornik.pdf). (20.10.2023)
- Wittke, W., Pierau, B., Erichsen, C. (2006). New Austrian tunneling method (NATM)-stability analysis and design. Essen, Germany, WBI, 419 p.



# Transformacija višin med starim in novim višinskim sistemom

Božo Koler\*, Tomaž Ambrožič\*, Klemen Kregar\*, Dušan Kogoj\*, Aleš Marjetič\*, Simona Savšek\*, Gašper Štebe\*, Jernej Tekavec\*, Tilen Urbančič\*\*

## Povzetek

V prispevku smo predstavili prve rezultate in analizirali kakovost transformacije višin med starim višinskim sistemom SVS2000 (višinski datum Trst) in novim višinskim sistemom SVS2010 (višinski datum Koper) na osnovi višinske transformacijske ploskve za območje Slovenije. Predstavljeni so postopki za pridobitev vhodnih podatkov za določitev višinske transformacijske ploskve. Na osnovi razlik višin reperjev v starem in novem višinskem sistemu, ki so stabilizirani na območju Slovenije, smo določili višinsko transformacijsko ploskev za dva različna niza podatkov in analizirali vpliv različnih interpolacijskih metod na kakovost določitve transformacijske ploskve. Kakovost transformacije višin med SVS2000/Trst in SVS2010/Koper smo analizirali na nizu kontrolnih reperjev, ki so vključeni v bazo geodetskih točk Geodetske uprave Republike Slovenije in imajo višine določene v SVS2000/Trst in preračunane višine v SVS2010/Koper.

**Ključne besede:** višinska transformacijska ploskev, višinski sistem, višinski datum, interpolacija, povprečna višina

**Key words:** height transformation surface, height system, vertical datum, interpolation, average height

## Uvod

Z Uredbo o določitvi parametrov višinskega dela vertikalne sestavine državnega prostorskega koordinatnega sistema (Koler in sod., 2019; Uredba, 2018), ki jo je sprejela Vlada Republike Slovenije, smo konec leta 2018 uvedli novi višinski sistem z oznako SVS2010, ki temelji na višinskem datumu Koper (Sterle in Koler, 2019). Novi višinski sistem je nadomestil star višinski sistem z oznako SVS2000/Trst, ki je temeljil na višinskem datumu Trst. Na območju Slovenije razlika višin med višinskima sistemoma SVS2010/Koper in SVS2000/Trst ni konstantna, ampak so spremembe višin v razponu od 1,4 cm do 30,8 cm (Medved in sod., 2020), kar onemogoča enostavno transformacijo med SVS2000/Trst in SVS2010/Koper.

Geodetska uprava RS (GURS) in številni drugi upravljavci ter državni organi vodijo različne zbirke prostorskih podatkov, ki vsebujejo georeferencirane podatke vključno z višino, ki je določena v starem višinskem sistemu. Ko obstoječe podatkovne zbirke, ki vsebujejo tudi podatek o nadmorski višini, dopolnjujemo z novimi podatki, kjer so višine določene v novem višinskem sistemu (SVS2010/Koper), pride do razlik v višinah. Podobni problemi so prisotni pri dopolnjevanju starih grafičnih prikazov, ki jih potrebujemo za prostorsko načrtovanje, projektiranje in umeščanje novih objektov v prostoru in ne nazadnje za evidentiranje nepremičnin, ki so jih izdelala različna geodetska podjetja pred letom 2019. Razliko v podatkih lahko odpravimo s transformacijo podatkovnih nizov z višinami iz starega višinskega sistema v nov višinski sistem. Velik problem predstavlja preračun višin na večjih območjih in preračun višin v podatkovnih nizih. S problemom transformacije višin iz SVS2000/Trst v SVS2010/Koper se tako vsak upravljavec podatkovnih nizov ukvarja sam. Tako so višine v podatkovnih nizih transformirane na različne načine in z različnimi

---

\*Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Jamova 2, Ljubljana

\*\* Geotočka d.o.o. in Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo

lokalnimi transformacijskimi modeli. Kakovost tako pridobljenih lokalnih transformacijskih modelov je odvisna od kakovosti določitve višin danih reperjev v obeh višinskih sistemih, njihovega števila in prostorske razporeditve. Problem predstavlja tudi sledljivost transformacije višin, saj uporabljeni postopki za transformacijo višin običajno niso dokumentirani, kar lahko vodi v nove razlike med transformiranimi višinami v podatkovnih nizih.

Zgoraj navedene probleme lahko rešimo in uredimo s kreiranjem enotnega državnega višinskega transformacijskega modela za območje Slovenije, ki bo različnim upravljavcem prostorskih podatkov omogočal enostaven prehod iz starega v nov višinski sistem. Konec leta 2022 je Javna agencija za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije (ARIS) razpisala ciljni raziskovalni projekt V2-2294: Razvoj državnega višinskega transformacijskega modela med SVS2000/Trst in SVS2010/Koper, ki ga sofinancira GURS. Osnovni namen predlaganega projekta je razvoj višinske transformacijske ploskve za območje Slovenije in programa za interpolacijo, ki bo zainteresiranim uporabnikom omogočil enostavno transformacijo prostorskih podatkov v nov državni višinski sistem SVS2010/Koper.

### **Pregled podatkovnih zbirk Geodetske uprave Republike Slovenije s podatkom o višinah**

Zapis in kakovost višin za posamezno podatkovno zbirko GURS je opredeljena v področni zakonodaji. Analiza zapisov o višinah v podatkovnih zbirkah GURS (Preglednica 1) je pokazala, da razen podatkov o evidenci slovensko-italijanske in slovensko-madžarske meje, kjer so višine prikazane na centimeter, so podatki o ostalih višinah vodeni na decimeter ali nekaj decimetrov, na nekaterih območjih tudi na meter. Višine točk državne meje z Italijo in Madžarsko so določene z GNSS-višinomerstvom, ki jih lahko transformiramo v novi višinski sistem s programom SiVis, preko geoidnih višin (Kozmus Trajkovski in Stopar, 2019). Glede na kakovost vodenja podatkov o višinah v ostalih podatkovnih zbirkah bi transformacijo v novi višinski sistem lahko izvedli z višinsko transformacijsko ploskvijo za območje Slovenije.

Preglednica 1: Zapis in kakovost višin v podatkovnih zbirkah GURS.

Podatkovna zbirka	Zapis/kakovost višin	Opomba
Zemljiški kataster	Koordinate zemljiško-katastrskih točk so zaokrožene na cm. Višina ni obvezen podatek.	<a href="https://www.gov.si/drzavni-organi/organi-v-sestavi/geodetska-uprava/zakonodaja-geodetske-uprave/">https://www.gov.si/drzavni-organi/organi-v-sestavi/geodetska-uprava/zakonodaja-geodetske-uprave/</a> Višinska koordinata zemljiškokatastrske točke je višina, ki se določi z meritvami, če metoda izmere to omogoča, ali se izračuna na podlagi digitalnega modela višin.
Kataster stavb	Višine stavbe so zapisane v metrih na eno decimalno mesto.	<a href="https://www.gov.si/drzavni-organi/organi-v-sestavi/geodetska-uprava/zakonodaja-geodetske-uprave/">https://www.gov.si/drzavni-organi/organi-v-sestavi/geodetska-uprava/zakonodaja-geodetske-uprave/</a>

Zbirni kataster gospodarske javne infrastrukture	Določeni so razredi natančnosti: $\sigma_H \leq 0,1 \text{ m}$ $0,1 \text{ m} < \sigma_H < 0,5 \text{ m}$ $0,5 \text{ m} < \sigma_H \leq 1,0 \text{ m}$	<a href="https://www.gov.si/drzavni-organi/organi-v-sestavi/geodetska-uprava/zakonodaja-geodetske-uprave/">https://www.gov.si/drzavni-organi/organi-v-sestavi/geodetska-uprava/zakonodaja-geodetske-uprave/</a>  <a href="https://www.e-prostor.gov.si/zbirke-prostorskih-podatkov/zbirni-kataster-gospodarske-javne-infrastrukture/">https://www.e-prostor.gov.si/zbirke-prostorskih-podatkov/zbirni-kataster-gospodarske-javne-infrastrukture/</a>
Evidenca državne meje	Višina se vodi na cm oz. m natančno.	V zdaj veljavnih mejnih dokumentih: <ul style="list-style-type: none"> <li>• za slovensko-italijansko državno mejo so višine prikazane z ločljivostjo 1 cm,</li> <li>• za slovensko-avstrijsko državno mejo so višine prikazane z ločljivostjo 1 m,</li> <li>• za slovensko-madžarsko državno mejo so višine prikazane z ločljivostjo 1 cm,</li> <li>• za slovensko-hrvaško državno mejo ni podatka o višini.</li> </ul>
Državni koordinatni sistem	Nivelirane višine so zaokrožene na mm, ostale na cm.	Natančnost višin državnih geodetskih točk je odvisna od metode geodetske izmere. Vsi nivelmanski poligoni so preračunani v novi višinski sistem, zato jih ni potrebno transformirati.
Digitalni model višin	Višine v modelu so zaokrožene na cm.	Srednje odstopanje DMR je odvisno od resolucije in je manjše od 0,40 m na odprtem in deloma poraščenem zemljišču, ter 1,20 m na poraščenem zemljišču.
Zbirka topografskih podatkov	Točnost pridobljenih višin je $\pm 1 \text{ m}$ (RMSE).	Točnost je odvisna od vira za pridobivanje topografskih podatkov.
Državna topografska karta 1 : 50 000	Ekvidistanca ( $E$ ) plastnic je 20 m.	Če so na karti prikazane pomožne plastnice, si sledijo na 10 ( $E/2$ ) ali 5 ( $E/4$ ) metrov.
Državna pregledna karta 1 : 250 000	Ekvidistanca ( $E$ ) plastnic je 100 m.	Če so na karti prikazane pomožne plastnice, si sledijo na 50 ( $E/2$ ) ali 25 ( $E/4$ ) metrov.
Druge državne pregledne karte	/	Relief je prikazan s senčenjem.

Podatek o višini se pričakovano ne vodi v zbirki vrednotenja nepremičnin, evidenci trga nepremičnin, registru nepremičnin, registru prostorskih enot in registru zemljepisnih imen.

### Pregled obstoječih podatkov o višinah reperjev

GURS v bazi geodetskih točk vodi podatke o višinah vseh reperjev, ki so stabilizirani v nivelmanskih mrežah in poligonih. Višine reperjev so določene v starem (SVS2000/Trst) in novem višinskem sistemu (SVS2010/Koper). V preglednici 2 so zbrani podatki o številu reperjev, ki so razdeljeni v različne redove.

Preglednica 2: Podatki o višinah reperjev v bazi geodetskih točk GURS.

Red nivelmanskega poligona	Reperji		Reperji z višino v obeh višinskih sistemih	
	<i>n</i>	%	<i>n</i>	%
1	2871	23,9	2135	74,4
2	662	5,5	568	85,8
3	955	7,9	936	98,0
4	2985	24,8	2973	99,6
Mestni	4548	37,8	4477	98,4
Skupaj	12021	100	11089	92,2

Iz preglednice 2 vidimo, da je v bazi geodetskih točk vodenih 12021 reperjev. Pričakovano je največ reperjev mestnih nivelmanskih mrež (37,8 %), 4. reda (24,8 %) in 1. reda (23,9 %). V bazi je zajetih 5,5 % reperjev 2. reda in 7,9 % reperjev 3. reda. Največ reperjev, ki imajo višine določene v starem in novem višinskem sistemu, pripada 4. redu (99,6 %) in najmanj 1. redu (74,4 %). Rezultati so pričakovani, saj je bila nivelmanska mreža 1. reda v celoti sanirana (Slika 2), zato so bili stabilizirani tudi novi reperji, ki višine nimajo določene v starem višinskem sistemu. Reperji nižjih redov so bili preračunani iz starega v novi višinski sistem na osnovi podatkov o starih merjenih višinskih razlikah. Reperji, kjer je bilo odstopanje med dano (navezava) in merjeno višinsko razliko preveliko, za katerikoli red nivelmanske mreže, niso bili preračunani in zato v bazi niso zajeti. Zato pri nižjih redih iz starega v novi višinski sistem nimamo preračunanih vseh reperjev.

#### **Določitev razlik višin reperjev med novim in starim višinskim sistemom za določitev višinske transformacijske ploskve in ocena natančnosti**

Razliko nadmorskih višin reperjev, ki jo potrebujemo za določitev višinske transformacijske ploskve na območju Slovenije, izračunamo po naslednji enačbi:

$$\Delta H_{ViTraP} = H_{SVS2010} - H_{SVS2000} \quad (1)$$

V enačbi (1) so:

$\Delta H_{ViTraP}$  . . . razlika nadmorskih višin reperjev za določitev višinske transformacijske ploskve,

$H_{SVS2010}$  . . . nadmorska višina reperja v novem višinskem sistemu SVS2010/Koper,

$H_{SVS2000}$  . . . nadmorska višina reperja v starem višinskem sistemu SVS2000/Trst.

Natančnost določitve višin reperjev v novem in starem višinskem sistemu potrebujemo za oceno natančnosti razlik nadmorskih višin med novim in starim višinskim sistemom. Na osnovi ocene natančnosti določitve razlike višin reperjev bomo določili model za oceno kakovosti transformacijskega modela. Oceno natančnosti razlik višin reperjev si izračunamo po enačbi:

$$\sigma_{\Delta H_{ViTraP}} = \sqrt{\sigma_{H_{SVS2010}}^2 + \sigma_{H_{SVS2000}}^2} \quad (2)$$

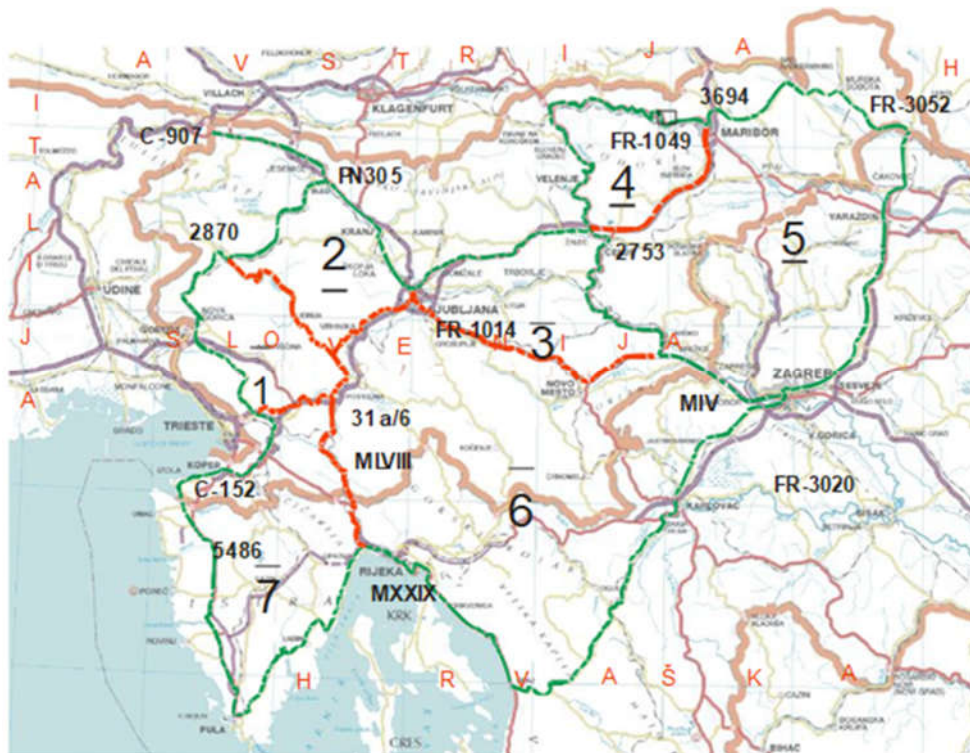
V enačbi (2) so:

$\sigma_{\Delta H_{ViTraP}}$  . . . natančnost razlike višin, ki je vhodni podatek za določitev modela natančnosti višinske transformacijske ploskve,

$\sigma_{H_{SVS2010}}$  . . . natančnost določitve nadmorske višine reperjev v SVS2010/Koper,


$\sigma_{H_{SVS2000}}$  . . . natančnost določitve nadmorske višine reperjev v SVS2000/Trst.

Stara in nova nivelmanska mreža sta bili izravnani s programom VimWin (Ambrožič, 2016). Referenčni standardni odklon po izravnavi stare nivelmanske mreže 1. reda (Slika 1, SVS2000/Trst) znaša 0,86 mm/km in natančnost določitve nadmorskih višin reperjev od 0,12 mm do 11,46 mm.



Slika 1: Stara nivelmanska mreža Slovenije.

Reperji, ki so bili vključeni v izmero in izračun nove nivelmanske mreže 1. reda Slovenije (Slika 2), imajo v bazi geodetskih točk GURS zapisano tudi natančnost določitve nadmorskih višin. Referenčni standardi odklon po izravnavi znaša 0,50 mm/km in natančnost določitve nadmorskih višin reperjev od 0,06 mm do 6,08 mm (Koler in sod., 2019). Izmera nove nivelmanske mreže 1. reda Slovenije (Slika 2) je rezultat sistematične sanacije nivelmanske mreže na območju Slovenije (Koler in sod., 2019). Izmera nove nivelmanske mreže 1. reda je bila uspešno zaključena leta 2015 v okviru projekta »Posodobitev prostorske podatkovne infrastrukture za zmanjšanje tveganj in posledic poplav«, podprojekta »Geodetski referenčni sistem«, ki se je izvajal med leti 2013 in 2016 v okviru Finančnega mehanizma Evropskega gospodarskega prostora (Projekt EGP, 2013; Režek, 2017).



Slika 2: Nova nivelmanska mreža 1. reda z oznako nivelmanskih poligonov in zank.

Iz preglednice 2 vidimo, da imamo v bazi geodetskih točk 11089 reperjev, ki imajo višino določeno v obeh višinskih sistemih. Reperje za izdelavo višinskega transformacijskega modela smo izbrali v več korakih, ki so opisani v naslednjem poglavju.

### Izbira reperjev za izdelavo višinskega transformacijskega modela

Reperje za izdelavo višinskega transformacijskega modela smo določili v sledečih korakih:

- a) Podatki za transformacijsko ploskev na osnovi merjenih višin identičnih reperjev 1. reda v SVS2000/Trst in SVS2010/Koper

Analiza baze geodetskih točk je pokazala, da je bilo v novo izmero nivelmanske mreže 1. reda Slovenije (Slika 2) vključeno 1231 starih reperjev, ki so bili predhodno vključeni tudi v izmero v starem višinskem sistemu SVS2000/Trst. Na osnovi navzkrižnega preverjanja oziroma analize razlik višin smo izločili 186 reperjev, kjer je razlika med novim in starim višinskim sistemom med sosednjimi reperji presegala 10 mm in ni posledica različne velikosti posedanaj med sosednjimi območji (Preglednica 3). Predvidevamo namreč, da je le ta posledica lokalnih premikov posameznih objektov, v katerih so stabilizirani reperji.


Preglednica 3: Primer razlike med SVS2010/Koper in SVS2000/Trst med sosednjimi reperji, ki presegala 10 mm (rdeče v besedilu).

Reper	Vgrajen v objekt	$H_{SVS2010}$ [m]	$H_{SVS2000}$ [m]	$\Delta H_{Tran}$ [m]
FR-1033	Solkan, ob parkirišču pri žičnici za Sv. Goro	79,3334	79,4447	-0,111
5352	Upravna zgradba Goriških vodovodov	106,6234	106,7357	-0,112
5349	Propust Kobarid – Nova Gorica pri km 106+593	80,8363	80,9640	-0,109
<b>5351</b>	<b>Propust Kobarid – Nova Gorica pri km 109+058</b>	<b>79,5649</b>	<b>79,6735</b>	<b>-0,128</b>
5350a	Steni Kobarid – Nova Gorica pri km 109+290	81,0391	81,1539	-0,115
5349a	Propust Kobarid – Nova Gorica pri km 107+580	82,2320	82,3473	-0,115



5349	Propust Kobarid – Nova Gorica pri km 106+593	80,8363	80,9640	-0,128
5348a	Močnejši robnik ob glavni cesti pri km 105+685	82,0822	82,1925	-0,110
O-41	Propust Kobarid – Nova Gorica pri km 105+034	89,8892	89,9997	-0,111

Tako smo dobili 1045 reperjev nove nivelmanske mreže 1. reda,, ki so bili že predhodno vključeni v izmero SVS2000/Trst ter naknadno še v SVS2010/Koper in predstavljajo osnovo za določitev višinske transformacijske ploskve (Slika 3).



Slika 3: Skica identičnih reperjev, ki so bili vključeni v izmeri SVS2000/Trst in SVS2010/Koper, (Vir slikovne podlage: GoogleMaps).

V preglednici 4 so zbrane statistične cenilke o razlikah višin med novim in starim višinskim sistemom in natančnosti razlike višin, ki jo izračunamo po enačbi (2).

Preglednica 4: Statistične cenilke za reperje, ki so bili vključeni v SVS2000/Trst in SVS2010/Koper.

	Reper	Niv. pol./Kraj	$\Delta H_{ViTraP}$ [m]	Reper	Niv. pol./Kraj	$\sigma_{\Delta H_{ViTraP}}$ [mm]
Maks.	5244b	N1-12B/Podplat	-0,014	12	N3-51/Breg	13,8
Min.	46	N-3/Trenta	-0,240	C-2	N1-11B/Smolnik pri Rušah	0,1
Sred.			-0,129	Sred.		9,2

Iz preglednice 4 vidimo, da znašajo razlike višin med novim in starim višinskim sistemom na 1045 reperjih od -0,014 m do -0,240 m in srednja razlika višin -0,129 m. Natančnost

določitve razlike višin znaša od 0,1 mm do 13,8 mm in srednja vrednost natančnosti je 9,2 mm. Navedeni reperji iz preglednice 4 so tudi prikazani na sliki 3.

- b) Dopolnjeni podatki za izračun transformacijske ploskve na osnovi preračunanih višin reperjev nižjih redov v SVS2000/Trst in SVS2010/Koper


Iz slike 3 vidimo, da so podatki za izdelavo transformacijske ploskve neenakomerno porazdeljeni na območju Slovenije, zato smo se odločili, da osnovne podatke dopolnimo z dodatnimi podatki, ki bodo omogočili izdelavo bolj kakovostne transformacijske ploskve. V izravnavo stare nivelmanske mreže 1. reda (Slika 1) smo vključili dodatne nivelmanske poligone nižjih redov. Iz slike 4 vidimo, da so bili v izravnavo vključeni nivelmanski poligoni do posameznih mejnih prehodov, stari nivelmanski poligoni in novo izmerjeni nivelmanski poligoni 2. reda (N2-59: Nova Gorica – Kalce in N2-45: Šoštanj – Šempeter) in 3. reda (N3-51: Zidani most – Brežice).

Da bi dosegli čim bolj enakomerno porazdelitev reperjev, smo med stare reperje dodali tudi nove reperje, ki so bili zajeti v izmero nove nivelmanske mreže 1. reda Slovenije. Ker ti reperji nimajo znane nadmorske višine v SVS2000/Trst, smo novo merjene višinske razlike nivelmanskih linij vključili v izravnavo stare nivelmanske mreže (Slika 1). Izravnane nadmorske višine v starem višinskem sistemu SVS2000/Trst smo uporabili za izračun razlik nadmorskih višin. Pri tem smo pazili, da so bile razlike skladne z razlikami višin, ki so bile določene za posamezna območja na starih reperjih (Preglednica 5), ki so imeli višino določeno v SVS2000/Trst in SVS2010/Koper.

Preglednica 5: Razlike nadmorskih višin reperjev na starih reperjih in novih reperjih (zeleno), ki so bili vključeni v izravnavo stare nivelmanske mreže.

Reper	$H_{SVS2010}$ [m]	$\sigma_H^{SVS2010}$ [mm]	$H_{SVS2000}$ [m]	$\sigma_H^{SVS2000}$ [mm]	$\Delta H_{ViTraP}$ [m]	$\sigma_{\Delta H_{ViTraP}}$ [mm]
5407a	485,5064	4,9	485,6278	9,4	-0,121	10,6
5408	483,4450	4,9	483,5644	9,4	-0,119	10,6
N215	482,1861	4,9	482,3090	9,4	-0,123	10,5
N214	485,2734	4,9	485,3968	9,4	-0,123	10,5
N213	481,5141	4,9	481,6379	9,4	-0,124	10,5
C-83	480,2874	4,9	480,4106	9,4	-0,123	10,6
CP-539	502,0420	4,9	502,1651	9,4	-0,123	10,6

Iz preglednice 5 vidimo, da so razlike med nadmorskimi višinami med sosednjimi starimi in novimi reperji manjše od 5 mm, kar je bil pogoj za izbor dodatnih reperjev za izračun transformacijske ploskve in se lepo vključujejo v podatke o razlikah višin na starih reperjih. Za izdelavo višinske transformacijske ploskve je bilo tako izbranih 2126 reperjev (Slika 4).



Slika 4: Skica razporeditve reperjev za izdelavo višinske transformacijske ploskve v dopolnjeni nivelmanski mreži (Vir slikovne podlage: GoogleMaps).

V preglednici 6 so zbrane statistične cenilke o reperjih, ki so bili izbrani za izdelavo višinske transformacijske ploskve.

Preglednica 6: Statistične cenilke za reperje, ki so bili vključeni v dopolnjeno nivelmansko mrežo in izbrani za izdelavo višinske transformacijske ploskve.

	Reper	Niv. pol./Kraj	$\Delta H_{ViTraP}$ [m]	Reper	Niv. pol./Kraj	$\sigma_{\Delta H_{ViTraP}}$ [mm]
Maks.	5244b	N1-12B/Podplat	-0,014	N1168	N3-51/Sevnica	15,2
Min.	46	N-3/Trenta	-0,240	C-2	N1-11B/Smolnik pri Rušah	0,1
Sred.			-0,130			9,3

Iz preglednice 6 vidimo, da znašajo razlike višin med novim in starim višinskim sistemom na 2126 reperjih od  $-0,014$  m do  $-0,240$  m, kot je predstavljeno v preglednici 6, in srednja razlika  $-0,130$  m, ki se je minimalno spremenila glede na vrednost v preglednici 5 ( $-0,129$  m). Natančnost določitve razlike višin znaša od 0,1 mm do 15,2 mm in srednja vrednost natančnosti je 9,3 mm. Tudi v tem primeru so razlike majhne glede na vrednosti v preglednici 5. Reperji navedeni v preglednici 6 so tudi prikazani na sliki 4.

Z dopolnjevanjem osnovnih podatkov za izračun višinske transformacijske ploskve (Slika 3), smo zgostili podatke med starimi reperji in dosegli, da je srednja dolžina med reperji, ki so služili za izdelavo višinske transformacijske ploskve, okoli 1 km (Preglednica 7).

Preglednica 7: Statistični kazalci za dolžine med sosednjimi reperji, ki smo jih izbrali za izračun višinske transformacijske ploskve.

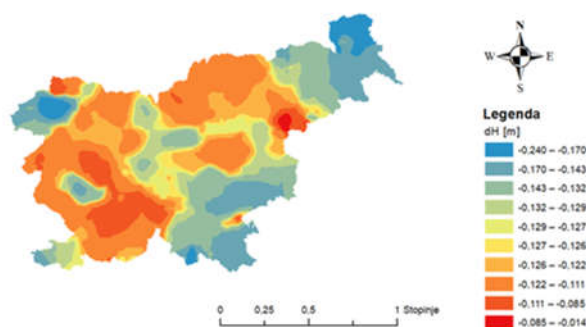
Statistični kazalci	Nivelmanski poligon	$d$ [m]
Maksimalna	N3-P21	2331,6
Minimalna	MP201	123,0
Srednja		952,9

### Izdelava višinske transformacijske ploskve

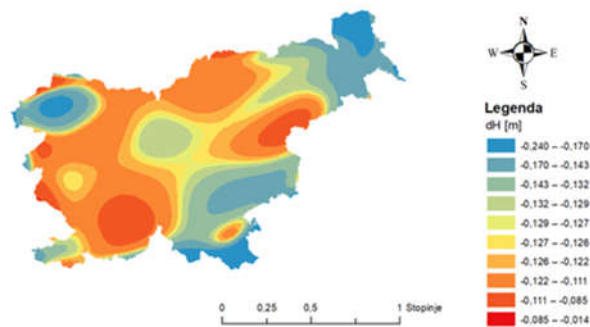
Ploskev, ki jo dobimo z različnimi interpolacijskimi metodami, je tridimenzionalna in jo sestavlja zvezno polje vrednosti po celotnem območju izdelane ploskve. Podatki interpolacije predstavljajo površino ploskve kot mrežo celic enakih velikosti. Glede na horizontalne koordinate  $e$ ,  $n$  je določen podatek za tretjo koordinato ( $\Delta H$ ). Funkcija površinske interpolacije je, da ustvari neprekinjeno ploskev iz vrednosti, ki predstavljajo vhodni podatek. Za izdelavo ploskve obstaja več različnih interpolacijskih metod. Metode interpolacij lahko razvrstimo v dve skupini, in sicer na interpolacije na osnovi determinističnih metod ter na osnovi geostatističnih metod. Deterministične metode določajo vrednosti na podlagi vhodnih podatkov in določenih matematičnih enačb, medtem ko geostatistične metode temeljijo na statističnih modelih, ki vključujejo avtokorelacijo (Ayeni in Samuel, 2014).

Obdelava podatkov je potekala v okolju ArcGIS z orodjem Geostatistical Wizard, kjer so zbrane vse uveljavljene metode prostorske interpolacije podatkov. Višinski transformacijski model smo izdelali na osnovi razlik višin točk na 1045 reperjih (sloj 1045, Slika 3) in 2126 reperjev (sloj 2126, Slika 4). Višinska transformacijska ploskev je bila izdelana s štirimi determinističnimi metodami interpolacije (metoda inverzne razdalje – angl. Inverse distance weighting, globalna polinomska interpolacija – angl. Global polynomial interpolation, lokalna polinomska interpolacija – angl. Local polynomial interpolation in radialne bazne funkcije – angl. Radial basis functions), ter metodo kriging in kriging z dodanim vplivom smeri na variogramu, ki sta geostatistični metodi (Slika 5).

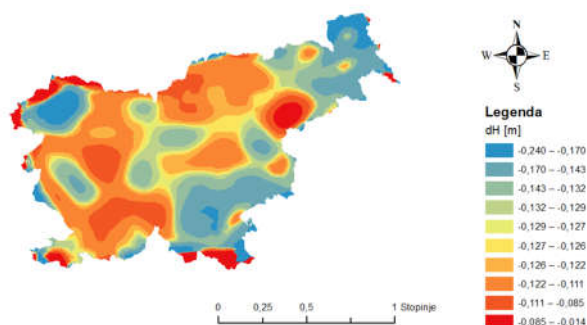
Metoda inverzne razdalje



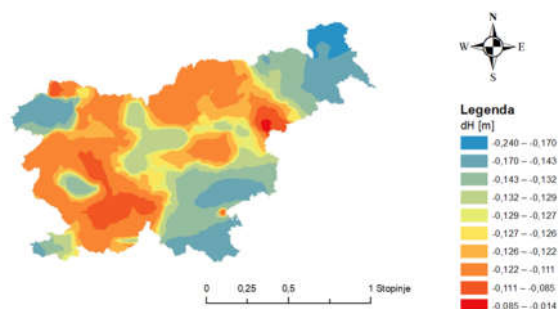
Globalna polinomska interpolacija



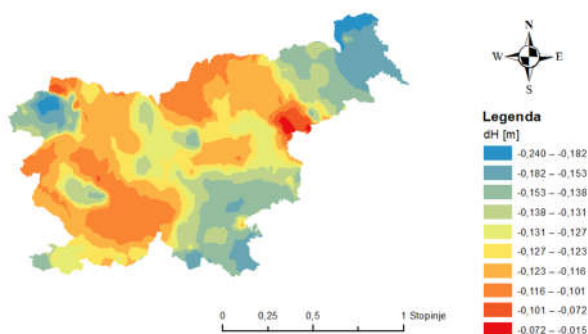
Lokalna polinomska interpolacija



Radialne bazne funkcije



Kriging z dodanim vplivom smeri na variogramu



Slika 5: Višinski transformacijski modeli na osnovi uporabljenih interpolacijskih metod.

Iz slike 5 vidimo, da se višinske transformacijske ploskve, izdelane z različnimi interpolacijskimi metodami, nekoliko razlikujejo. Kakovost višinskega transformacijskega modela, ki je določen z različnimi interpolacijskimi metodami, lahko ocenimo na osnovi analize kakovosti.

### Analiza kakovosti višinske transformacijske ploskve

Na osnovi analize kakovosti različnih višinskih transformacijskih ploskev je bila izbrana tudi končna metoda interpolacije. Analizo kakovosti smo izvedli v več korakih.

- a) Analiza kakovosti interpolacijskih metod na osnovi sloja razlik višin na 1045 oziroma 2126 reperjih

Analizo kakovosti različnih višinskih transformacijskih ploskev, smo izvedli z navzkrižnim preverjanjem, ki v vsaki iteraciji odstrani eno točko iz določitve ploskve in nato primerja vrednost ploskve z merjeno vrednostjo. Iz razlik se izračunajo statistične cenilke, ki jih uporabimo za oceno kakovosti interpolirane ploskve (Preglednica 8).

Preglednica 8: Statistične cenilke za sloja podatkov z 1045 in 2126 razlik višin in uporabljene interpolacijske metode.


Interpolacijska metoda	Statistične cenilke	Sloj 1045 reperjev	Sloj 2126 reperjev
Metoda inverzne razdalje	Srednje odstopanje [mm]	0,0336	-0,0112
	RMSE [mm]	6,64	6,94
Globalna polinomska interpolacija	Srednje odstopanje [mm]	-0,0358	-0,0082
	RMSE [mm]	11,75	11,70

Lokalna polinomska interpolacija	Srednje odstopanje [mm]	-0,0876	0,0166
	RMSE [mm]	9,29	8,73
Radialne bazne funkcije	Srednje odstopanje [mm]	-0,0260	-0,0086
	RMSE [mm]	6,88	6,96
Kriging	Srednje odstopanje [mm]	0,0157	0,0168
	RMSE [mm]	6,63	6,24
Kriging z dodanim vplivom smeri na variogramu	Srednje odstopanje [mm]	-0,0171	-0,0050
	RMSE [mm]	6,36	6,17

Iz preglednice 8 vidimo, da so razlike med srednjimi odstopanji majhne in da so vse statistične cenilke za sloj 2126 reperjev boljše, razen za metodo inverzne razdalje, kjer je RMSE za sloj 2126 reperjev večji, kot za sloj 1045 reperjev. Vendar tudi v tem primeru razlika ni bistvena. Iz preglednice 8 tudi vidimo, da pri metodi kriging z dodanim vplivom smeri na variogramu dobimo najmanjše srednje odstopanje (-0,0050 mm) in najmanjši RMSE (6,17 mm). Na osnovi opravljene analize kakovosti lahko zaključimo, da je višinski transformacijski model, ki je izračunan z metodo kriging z dodanim vplivom smeri na variogramu in sloj 2126 reperjev, ki vsebuje dodatne podatke o razliki višin reperjev, najboljši.

b) Analiza kakovosti višinske transformacijske ploskve na osnovi razlik višin na kontrolnih reperjih

Kakovost izbrane višinske transformacijske ploskve smo kontrolirali tudi na 8700 kontrolnih reperjih, ki imajo višino določeno tako v SVS2000/Trst kot v SVS2010/Koper. Izračunali smo razliko višin med SVS2010/Koper in SVS2000/Trst (Enačba (1)) in jo primerjali z razliko višin, ki smo jo dobili iz višinske transformacijske ploskve. Na osnovi razlike med izračunano in interpolirano razliko višin na kontrolnih reperjih, smo ocenili kakovost višinskega transformacijskega modela (Slika 6 in Preglednica 9).



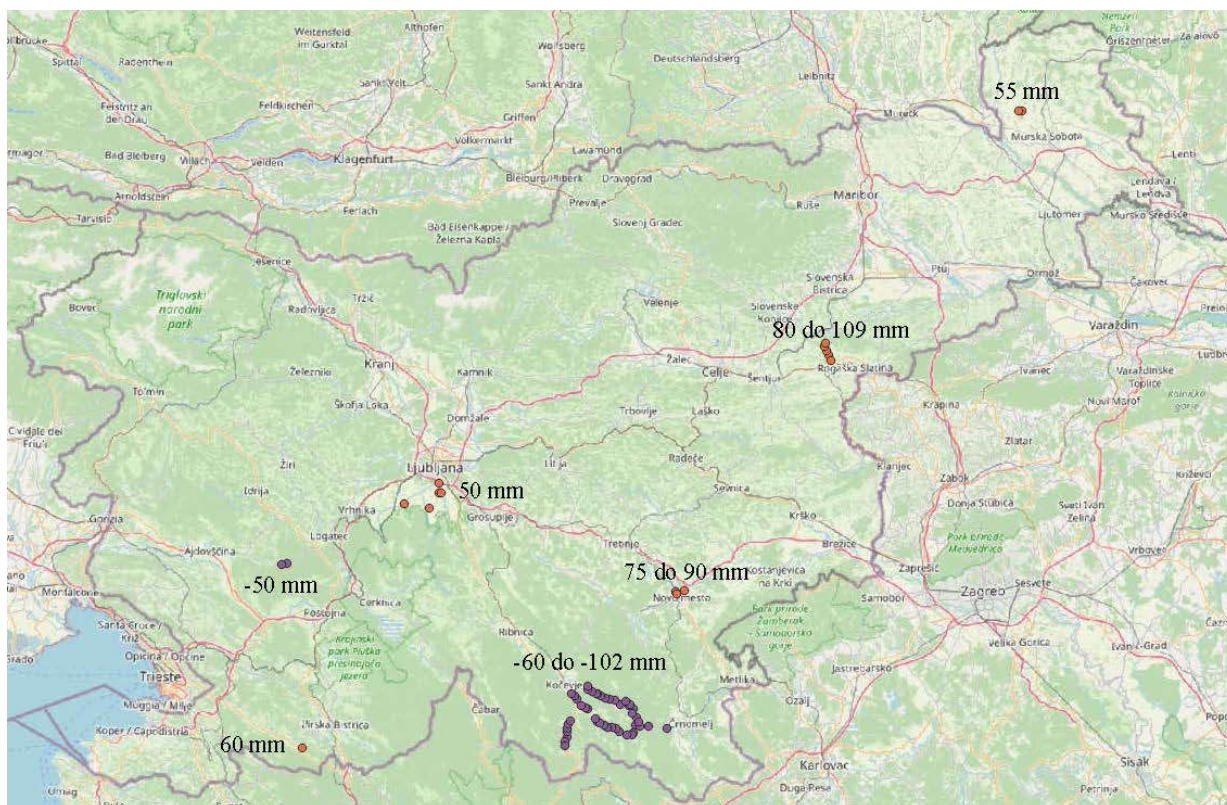
Slika 6: Histogram porazdelitve razlik višin na kontrolnih reperjih.

Iz slike 6 vidimo, da razlika višin na kontrolnih reperjih sledi normalni porazdelitvi in da je večina razlik višin na kontrolnih reperjih med -10 mm in 10 mm (84,2 %).

Preglednica 9: Statistične cenilke za oceno kakovosti višinskega transformacijskega modela.

Interpolacijska metoda	Statistične cenilke	Sloj 2126 reperjev
Kriging z dodanim vplivom smeri na variogramu	Minimalno odstopanje [mm]	-102
	Štev. reperjev z odst. od -50 mm do -102 mm	47 (0,5 %)
	Maksimalno odstopanje [mm]	109
	Štev. reperjev z odst. od 50 mm do 109 mm	16 (0,2 %)
	Srednje odstopanje [mm]	14
	RMSE [mm]	11,7

Iz preglednice 9 vidimo, da znaša minimalno odstopanje -102 mm, podobne velikosti je tudi maksimalno odstopanje, 109 mm. Na 47 kontrolnih reperjih (0,5 %) je odstopanje med -50 mm do -102 mm in na 16 kontrolnih reperjih (0,2 %) od 50 mm do 109 mm. V obeh primerih je odstotek kontrolnih reperjev zanemarljiv vendar, če jih prikažemo na kartografski podlagi (Slika 7) lahko ugotovimo, da je večina reperjev z negativno razliko na območju Kočevskega Roga in s pozitivno razliko na območju med Poljčanami in Rogaško Slatino.



Slika 7: Prikaz večjih razlik višin na osnovi razlik višin med SVS2010/Koper in SVS2000/Trst in višin reperjev iz višinskega transformacijskega modela (Vir slikovne podlage: GoogleMaps).

## Zaključek

V prispevku je prikazan način izbora reperjev z razlikami višin med SVS2000/Trst in SVS2010/Koper. Z dopolnjevanjem podatkov osnovnih reperjev (sloj 1045 reperjev), ki so bili vključeni v izmero stare in nove nivelmanske mreže, smo dobili niz podatkov (sloj 2126 reperjev), ki so enakomerno porazdeljeni na območju Slovenije, saj povprečna dolžina med reperji znaša okoli 1 km. Ocenjujemo, da je to zadostna gostota reperjev za določitev transformacijske ploskve.

Iz obeh slojev podatkov smo z različnimi interpolacijskimi metodami določili višinske transformacijske ploskve, ki se nekoliko razlikujejo med seboj. Na osnovi analize kakovosti določitve višinske transformacijske ploskve, ki je bila izvedena na obeh slojih podatkov, smo prišli do zaključka, da je najboljša višinska transformacijska ploskev za sloj 2126 reperjev, ki je določena z interpolacijsko metodo kriging z dodanim vplivom smeri na variogramu.

Kakovost izbrane višinske transformacijske ploskve smo testirali na 8700 kontrolnih reperjih, ki imajo višine določene v SVS2000/Trst in SVS2010/Koper. Primerjali smo razlike višin na kontrolnih reperjih z razlikami višin, ki jih dobimo iz višinske transformacijske ploskve. Analiza je pokazala, da je 84,2 % razlik višin v območju od -10 mm do 10 mm, srednja razlika znaša 14 mm in RMSE 11,7 mm. Največ reperjev z negativno razliko (-60 mm do -102 mm) dobimo na območju Kočevskega Roga in s pozitivno razliko (80 mm do 109 mm) na območju med Poljčanami in Rogaško Slatino. Nadaljnje analize bodo pokazale, ali so te razlike posledica slabih vhodnih podatkov za določitev višinske transformacijske ploskve na teh območjih.

Zaključimo lahko, da so prvi rezultati in analize kakovosti transformacije višin med SVS2000 (višinski datum Trst) in SVS2010 (višinski datum Koper) na osnovi višinske transformacijske ploskve za območje Slovenije vzpodbudni.

## Zahvala

Raziskava je nastala v okviru ciljnega raziskovalnega projekta V2-2294: Razvoj državnega višinskega transformacijskega modela med SVS2000/Trst in SVS2010/Koper, ki sta ga sofinancirali Javna agencija za raziskovalno dejavnost Republike Slovenije in Ministrstvo za naravne vire in prostor, Geodetska uprava Republike Slovenije.

## Literatura in viri

- Ambrožič, T. (2016). Navodila za uporabo programa VimWin ver. 5.1, mar. 16.
- Ayeni, B., Samuel, K. J. 2014. An evaluation of digital elevation modeling in GIS and Cartography. *Geo-spatial Information Science* 17, 2: 139-144. <https://www.tandfonline.com/doi/pdf/10.1080/10095020.2013.772808?needAccess=true>
- Koler, B., Stopar, B., Sterle, O., Urbančič, T., Medved, K. (2019). Nov slovenski višinski sistem SVS2010. *Geodetski vestnik* 63, 1: 27-40. [http://www.geodetski-vestnik.com/63/1/gv63-1\\_koler.pdf](http://www.geodetski-vestnik.com/63/1/gv63-1_koler.pdf)
- Kozmus Trajkovski, K., Stopar, B. (2019). Navodila za uporabo programa za pretvorbo višin med višinskimi sistemi RS – SiVis-v2.0, maj 2019. <http://sitranet.si/sivis.html>
- Medved, K., Kozmus Trajkovski, K., Berk, S., Stopar, B., Koler, B. (2020). Uvedba novega slovenskega višinskega sistema (SVS2010). *Geodetski vestnik* 64, 1: 33-42. [http://www.geodetski-vestnik.com/64/1/gv64-1\\_medved.pdf](http://www.geodetski-vestnik.com/64/1/gv64-1_medved.pdf)
- Projekt EGP (2013). Posodobitev prostorske podatkovne infrastrukture za zmanjšanje tveganj in posledic poplav. <http://www.gurs-egp.si/>.



- Režek, J. (2017). Ob zaključku projekta »Posodobitev prostorske podatkovne infrastrukture za zmanjšanje tveganj in posledic poplav«. Geodetski vestnik 61, 1: 115-124. [http://www.geodetski-vestnik.com/61/1/gv61-1\\_rezek.pdf](http://www.geodetski-vestnik.com/61/1/gv61-1_rezek.pdf).
- Sterle, O., Koler, B. (2019). Določitev novega višinskega datuma Slovenije. Geodetski vestnik 63 1: 13-26. [http://www.geodetski-vestnik.com/63/1/gv63-1\\_sterle.pdf](http://www.geodetski-vestnik.com/63/1/gv63-1_sterle.pdf).
- Uredba o določitvi parametrov višinskega dela vertikalne sestavine državnega prostorskega koordinatnega sistema. (2018). Uradni list Republike Slovenije, štev. 80/2018. <https://www.uradni-list.si/glasilo-uradni-list-rs/vsebina/2018-01-3854?sop=2018-01-3854>



# Več kot 30 let uporabe umetne inteligence na področju meteorologije v Sloveniji

Marija Zlata Božnar\*, Primož Mlakar\*, Boštjan Grašič\*

## Povzetek

V članku opisujemo več kot 30 let uporabe umetne inteligence na področju meteorologije v Sloveniji.

**Ključne besede:** umetne nevronske mreže, strojno učenje, umetna inteligenca, meteorologija, razširjanje onesnaževanja ozračja

**Key words:** artificial neural networks, machine learning, artificial intelligence, meteorology, air pollution dispersion

## Predgovor

10. januarja 2024 je ECMWF izdal sporočilo za javnost o uporabi in načrtih za uporabo strojnega učenja v procesu napovedovanja vremena: »Na zadnjih dveh zasedanjih Sveta ECMWF, junija in decembra 2023, so države članice ECMWF odobrile dve pomembni pobudi, namenjeni intenzivnejšemu razvoju, testiranju in izvajanju strojnega učenja v njihovih procesih za napovedovanje vremena.« (European Centre for Medium-Range Weather Forecasts, 2024)

Norveška in Švica sta prevzeli skupno enega od teh projektov in bosta usklajevali njegov razvoj: »Roar Skålin, generalni direktor Met Norway, in Christof Appenzeller, direktor MeteoSwiss, sta v skupni izjavi povedala: »Medtem ko se številne države članice ECMWF že ukvarjajo s strojnimi učenjem v okviru svojih meteoroloških služb, je pomembno nadaljevati in krepiti skupni pristop. To bo ključnega pomena za vodilno vlogo Evrope na področju napovedovanja vremena. Strojno učenje ima velik potencial za izboljšanje napovedi in storitev ter nam bo omogočilo boljše zaščito vseh državljanov pred posledicami nevarnih vremenskih pojavov. Iz nedavnih in zelo obetavnih rezultatov je jasno, da moramo v razvoj odločno vlagati.«« (prevod mag. Tanja Cegnar).

## Uvod

Iz predgovora je razvidno, da so si orodja **strojnega učenja** iz podatkov kot ena od orodij **popularno poimenovanega področja umetne inteligence** končno zanesljivo utrla pot tudi na področje atmosfere znanosti.

V tem članku bomo kratko predstavili kako smo Slovenci orali ledino na tem področju in nadaljevali razvoj v zadnjih več kot 30 letih.

---

\* MEIS storitve za okolje, d.o.o., Mali Vrh pri Šmarju 78, SI-1293 Šmarje-Sap, Slovenija

## Orodja za strojno učenje, kratek vpogled v delovanje

O **strojnem učenju** govorimo takrat, ko iz množice podatkov o obravnavanem sistemu, naprimer iz meritev v atmosferi, s posebnimi orodji **izvlečemo informacijo, za katero morda še ne vemo vseh zakonitosti povezav med spremenljivkami v eksplicitni obliki**. Lahko pa so nam povezave poznane, a so tako kompleksne, da onemogočajo hitre izračune, v teh primerih pa metode strojnega učenja pomagajo izračune izdelati **mного hitreje**.

Eno od prvih orodij strojnega učenja so bile umetne nevronske mreže, naprimer **večnivojska perceptronska nevronska mreža VPNM**. Če je v njene nevronske mreže vgrajena nelinearna prenosna funkcija, potem ima VPNM lastnost, da je univerzalni aproksimator. To pomeni, da z njo lahko poljubno dobro ponazorimo katerokoli nesingularno funkcijo. **V praksi to pomeni, da lahko z njo ponazorimo zapletene nelinearne odvisnosti** naprimer med spremenljivkami v ozračju, če le imamo na voljo dovolj pomejenih primerov »parov« odvisne spremenljivke (ali večih spremenljivk), ki jo želimo ponazoriti, in neodvisnih spremenljivk, ki jo pogojujejo. Posamezne pomejene primere imenujemo **vzorci** (ali tudi vektorji, patterns), odvisne in neodvisne spremenljivke pa imenujemo **značilke** (ali tudi regresorji, features). Neuron, ki je ključni element strukture nevronske mreže, pa je zgolj skupek enostavnih matematičnih operacij: z različnimi utežmi sešteje vrednosti s svojih vhodov in zatem vsoto podvrže prenosni funkciji. Izhod prenosne funkcije pa je izhod iz nevrona, ki se naprej povezuje na mrežo sestavljeno iz množice drugih nevronov. Od te konfiguracije je tudi nastalo poimenovanje umetne nevronske mreže, saj to posnema delovanje bioloških nevronskih mrež. Mrežo konfiguriramo tako, da nevronske mreže razporedimo v več slojev. Nevroni iz vsakega sloja so povezani z vsemi nevroni iz prejšnjega in iz naslednjega sloja. Možne pa so tudi druge kombinacije povezav, vključno s povratnimi zankami, kar pa niso več VPNM ampak druge vrste umetnih nevronskih mrež.

Proces izdelave **modela na osnovi VPNM** poteka v več korakih. Najprej oblikujemo količino nevronov in število slojev kar z izkušnjami prilagodimo razsežnosti problema, količini značilk in količini vzorcev. Potem nadaljujemo oblikovanje modela tako, da množico poznanih vzorcev, ki so ponazorjeni s posamičnimi realizacijami značilk, razdelimo na **učno, optimizacijsko in testno množico**. V procesu učenja **parametre modela na osnovi VPNM** z ustreznim učnim algoritmom spreminjamo tako, da se rezultati čim bolj prilagodijo učni množici. Hkrati pa testiramo vmesni izdelani model na optimizacijski množici. Končni model je tisti, ki najboljše ponazori optimizacijske vzorce. S tem zagotovimo, da ima nevronska mreža posploševalne sposobnosti. To je pomembno zato, ker se ustrezno konfigurirana VPNM lahko popolnoma nauči učne vzorce, vendar takrat nima dobrih posploševalnih sposobnosti. Dejansko učinkovitost modela na osnovi VPNM pa potem pretestiramo na neodvisni testni množici, ki je nismo uporabili v procesu učenja.

**Kohonenova nevronska mreža** pa ima drugačne sposobnosti. V množici vzorcev zna poiskati skupine podobnih vzorcev na zelo učinkovit in pronicljiv način.

Razvoj je prinesel celo množico podobnih orodij, od številnih drugih vrst umetnih nevronskih mrež do Gaussovih procesov (ki nimajo nobene zveze z Gaussovimi disperzijskimi modeli!), odločitvenih dreves (ti so primer »razložljive inteligence«) i.t.d..

## **Prva celovita metoda za uporabo umetne nevronske mreže za napovedovanje onesnaženja ozračja**

**Prvo celovito metodo v svetu za uporabo umetnih nevronske mreže za napovedovanje onesnaženja ozračja smo postavili že leta 1991 in jo objavili v letu 1993** (Božnar et al., 1993). Metodo smo razvili za kratkoročne napovedi zelo spremenljivih koncentracij žveplovega dioksida SO<sub>2</sub> na postajah v okolici Termoelektrarne Šoštanj, ki je takrat delovala še brez mokre odžvepljevalne naprave in je bil zato SO<sub>2</sub> v ozračju zelo pomemben in dobro pomeřen problem.

## **Predstavitve, razvoj in nova področja, od modelov za točke do krajevno prenosljivih modelov**

Metodo smo v naslednjih letih izpopolnili in predstavili na številnih konferencah in v člankih (Mlakar et al., 1994, Mlakar & Božnar, 1994, Božnar & Mlakar, 1995, Mlakar & Božnar, 1996, Mlakar, 1997, M. Božnar, 1997, Mlakar & Božnar, 1997, Božnar & Mlakar, 2002, Mlakar, 2004, Mlakar & Božnar, 2011).

Leta **2004** smo metodo s kolegi iz Sao Paula v Braziliji uspešno uporabili za točkovne napovedi **difuznega sončnega sevanja**, leta **2006** pa za korekcijo vpliva kupole na točkovne meritve dolgovalovnega sevanja s **pirgeometrom** (Soares et al., 2004, Oliveira et al., 2006, Mlakar et al., 2015; Mlakar, Božnar, Grašič, Oliviera, Soares, Gradišar, 2015).

Leta **2007** smo metodo razširili na uporabo še drugega orodja za strojno učenje, uporabili smo **Gaussove procese za točkovno napoved ozona** (Grašič et al., 2006). Razvoj na področju ozona smo nadaljevali v naslednjih letih (Kocijan et al., 2015, Petelin et al., 2015, Gradišar et al., 2016, Kocijan et al., 2016, Kocijan et al., 2018).

V **letu 2008** smo orodja uporabili za pohitritve simulacij disperzije onesnaževal v ozračju z uporabo Lagrangevega modela delcev (Grašič, 2008).

V **letu 2017** smo prešli iz napovedi za posamezne točke na napovedi, ki veljajo za različne kraje. Postavili smo **krajevno prenosljiv model za difuzno sončno sevanje in krajevno prenosljiv model za asimilacijo ozonskih meritev** za regionalni model maksimalnih koncentracij ozona (Božnar, Grašič, Mlakar, et al., 2017, Božnar, Grašič, Oliveira, et al., 2017).

Nadaljevali smo z modeli za izboljšanje točkovnih napovedi temperatur zraka, relativne vlage v zraku in vetra (Kocijan et al., 2019, Kocijan et al., 2020, Perne et al., 2021, Krivec et al., 2021).

## **Najnovejši nadomestni (»surogat«) modeli za ploskovne napovedi**

V **2023** smo objavili razvoj dveh različnih nadomestnih (»surogat«) modelov, ki omogočajo hkratno ponazoritev širjenja onesnaženja ozračja za celotno obravnavano prizemno ploskev izbranega krajevnega področja. Modele smo izdelali za relativne koncentracije in za relativne doze (Perne et al., 2023, Kocijan et al., 2023, Hvala et al., 2023).

## **Kohonenova nevronska mreža za klasificiranje podatkov**

S Kohonenovo nevronska mrežo smo zelo uspešno klasificirali podatke o vetrovnem polju v okolici Šoštanja, ki je bilo predstavljeno s hkratnimi meritvami smeri in hitrosti vetra na 10 m nad tlemi na številnih talnih merilnih postajah okoli Termoelektrarne Šoštanj (Mlakar, 2004).

### **Delo ostalih slovenskih skupin**

Med prvimi so metodo poprijeli v 2004 Rahela in Jure Žabkar ter Danijel Čemas za napovedi ozona, tudi v sodelovanju z Vladušič Danielom, Šuc Dorianom in Bratko Ivanom (Fakulteta za matematiko in fiziko Univerze v Ljubljani, Agencija Republike Slovenije za okolje (ARSO) in Fakulteta za računalništvo in informatiko Univerze v Ljubljani) (Žabkar et al., 2004, Žabkar et al., 2006).

V zadnjem času je več zanimanja na katedri za Meteorologijo, pri Gregorju Skoku in sodelavcih ter študentih s Katedre za meteorologijo, Fakultete za matematiko in fiziko Univerze v Ljubljani (Skok et al., 2021). Predvidoma bo na tem srečanju predstavil magistrsko delo Uroš Perkan (Perkan, 2023).

Skupaj s sodelavci z ARSO, Petrom Mlakarjem in Jankom Meršetom pa se s tem področjem ukvarja tudi Jana Faganeli Pucer s Fakultete za računalništvo in informatiko Univerze v Ljubljani, predstavitev bo predvidoma tudi na tem srečanju (Mlakar et al., 2024, Faganeli Pucer et al., 2018, Mlakar et al., 2023, Demaeyer et al., 2023).

Če smo še koga izpustili, se opravičujemo.

### **Zaključek**

Različne metode strojnega učenja se končno bolj množično uporabljajo na področju atmosfere znanosti.

### **Zahvala**

Projekt (Modeliranje dinamike kratkoročne izpostavljenosti radiološkemu sevanju, L2-2615) je sofinancirala Javna agencija za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije iz državnega proračuna.

### **Literatura**

Božnar, M., Lesjak, M., & Mlakar, P. (1993). A neural network-based method for short-term predictions of ambient SO<sub>2</sub> concentrations in highly polluted industrial areas of complex terrain. *Atmospheric Environment. Part B. Urban Atmosphere*, 27(2), 221–230. [https://doi.org/10.1016/0957-1272\(93\)90007-S](https://doi.org/10.1016/0957-1272(93)90007-S), (“Received 24 September 1991, Accepted 21 November 1992”)

- Božnar, M. Z., & Mlakar, P. (1995). Neural Networks - A New Mathematical Tool For Air Pollution Modelling. *WIT Transactions on Ecology and the Environment*. <https://doi.org/10.2495/AIR950301>
- Božnar, M. (1997). Pattern selection strategies for a neural network-based short term air pollution prediction model. *Intelligent Information Systems, 1997. IIS '97. Proceedings*, 340–344. <https://doi.org/10.1109/IIS.1997.645285>
- Božnar Marija Zlata, & Mlakar, P. (2002). Use of Neural Networks in the Field of Air Pollution Modelling. In G. Borrego Carlos and Schayes (Ed.), *Air Pollution Modeling and Its Application XV* (pp. 375–383). Springer US. [https://doi.org/10.1007/0-306-47813-7\\_38](https://doi.org/10.1007/0-306-47813-7_38)
- Božnar, M. Z., Grašič, B., Mlakar, P., Gradišar, D., & Kocijan, J. (2017). Nonlinear data assimilation for the regional modeling of maximum ozone values. *Environmental Science and Pollution Research*, 24(31), 24666–24680. <https://doi.org/10.1007/s11356-017-0059-2>
- Božnar, M. Z., Grašič, B., Oliveira, A. P. de, Soares, J., & Mlakar, P. (2017). Spatially transferable regional model for half-hourly values of diffuse solar radiation for general sky conditions based on perceptron artificial neural networks. *Renewable Energy*, 103, 794–810. <https://doi.org/10.1016/j.renene.2016.11.013>
- Demaeyer, J., Bhend, J., Lerch, S., Primo, C., Van Schaeybroeck, B., Atencia, A., Ben Bouallègue, Z., Chen, J., Dabernig, M., Evans, G., Faganeli Pucer, J., Hooper, B., Horat, N., Jobst, D., Merše, J., Mlakar, P., Möller, A., Mestre, O., Taillardat, M., & Vannitsem, S. (2023). The EUPPBench postprocessing benchmark dataset v1.0. *Earth System Science Data*, 15(6), 2635–2653. <https://doi.org/10.5194/essd-15-2635-2023>
- European Centre for Medium-Range Weather Forecasts. (2024). European met services pool resources to intensify use of AI in weather prediction. <https://www.ecmwf.int/en/about/media-centre/news/2024/european-met-services-pool-resources-intensify-use-ai-weather>, 10.01.2024
- Faganeli Pucer, J., Pirš, G., & Štrumbelj, E. (2018). A Bayesian approach to forecasting daily air-pollutant levels. *Knowledge and Information Systems*, 57(3), 635–654. <https://doi.org/10.1007/s10115-018-1177-y>
- Gradišar, D., Grašič, B., Božnar, M. Z., Mlakar, P., & Kocijan, J. (2016). Improving of local ozone forecasting by integrated models. *Environmental Science and Pollution Research*, 23(18), 18439–18450. <https://doi.org/10.1007/s11356-016-6989-2>
- Grašič, B., Mlakar, P., & Božnar, M. Z. (2006). Ozone prediction based on neural networks and Gaussian processes. *Nuovo Cimento C Geophysics Space Physics C*, 29, 651–661. <https://doi.org/10.1393/ncc/i2006-10011-5>
- Grašič, B. (2008). Improvement of the performance of an air-pollution dispersion model for use over complex terrain [Doctoral dissertation, University of Nova Gorica]. <http://www.ung.si/~library/doktorati/okolje/9Grasic.pdf>
- Hvala, N., Mlakar, P., Grašič, B., Božnar, M. Z., Perne, M., & Kocijan, J. (2023). Surrogate tree ensemble model representing 2D population doses over complex terrain in the event of a radiological release into the air. *Progress in Nuclear Energy*, 158, 104594. <https://doi.org/10.1016/j.pnucene.2023.104594>
- Kocijan, J., Hančič, M., Petelin, D., Božnar, M. Z., & Mlakar, P. (2015). Regressor selection for ozone prediction. *Simulation Modelling Practice and Theory*, 54, 101–115. <https://doi.org/10.1016/j.simpat.2015.03.004>
- Kocijan, J., Gradišar, D., Božnar, M. Z., Grašič, B., & Mlakar, P. (2016). On-line algorithm for ground-level ozone prediction with a mobile station. *Atmospheric Environment*, 131, 326–333. <https://doi.org/10.1016/j.atmosenv.2016.02.012>
- Kocijan, J., Gradišar, D., Štepančič, M., Božnar, M. Z., Grašič, B., & Mlakar, P. (2018). Selection of the data time interval for the prediction of maximum ozone concentrations. *Stochastic Environmental Research and Risk Assessment*, 32(6), 1759–1770. <https://doi.org/10.1007/s00477-017-1468-y>
- Kocijan, J., Perne, M., Mlakar, P., Grašič, B., & Božnar, M. Z. (2019). Hybrid model of the near-ground temperature profile. *Stochastic Environmental Research and Risk Assessment*, 33(11–12), 2019–2032. <https://doi.org/10.1007/s00477-019-01736-5>

- Kocijan, J., Perne, M., Grašič, B., Božnar, M. Z., & Mlakar, P. (2020). Sparse and hybrid modelling of relative humidity: the Krško basin case study. *CAAI Transactions on Intelligence Technology*, 5(1), 42–48. <https://doi.org/10.1049/trit.2019.0054>
- Kocijan, J., Hvala, N., Perne, M., Mlakar, P., Grašič, B., & Božnar, M. Z. (2023). Surrogate modelling for the forecast of Seveso-type atmospheric pollutant dispersion. *Stochastic Environmental Research and Risk Assessment*, 37(1), 275–290. <https://doi.org/10.1007/s00477-022-02288-x>
- Krivec, T., Kocijan, J., Perne, M., Grašič, B., Božnar, M. Z., & Mlakar, P. (2021). Data-driven method for the improving forecasts of local weather dynamics. *Engineering Applications of Artificial Intelligence*, 105, 104423. <https://doi.org/10.1016/j.engappai.2021.104423>
- Mlakar, P., Božnar, M., & Lesjak, M. (1994). Neural Networks Predict Pollution. In M. M. Gryning Sven-Erik and Millán (Ed.), *Air Pollution Modeling and Its Application X* (pp. 659–660). Springer US. [https://doi.org/10.1007/978-1-4615-1817-4\\_93](https://doi.org/10.1007/978-1-4615-1817-4_93)
- Mlakar, P., & Božnar, M. Z. (1994). Short-term Air Pollution Prediction On The Basis Of Artificial Neural Networks. *WIT Transactions on Ecology and the Environment*, 3, 4. <https://doi.org/10.2495/AIR940611>
- Mlakar, P. (1997). Determination of features for air pollution forecasting models. *Intelligent Information Systems, 1997. IIS '97. Proceedings*, 350–354. <https://doi.org/10.1109/IIS.1997.645291>
- Mlakar, P., & Božnar, M. Z. (1996). Analysis Of Winds And SO<sub>2</sub> Concentrations In Complex Terrain. *WIT Transactions on Ecology and the Environment*, 10, 10. <https://doi.org/10.2495/AIR960461>
- Mlakar, P., & Božnar, M. (1997). Perceptron neural network-based model predicts air pollution. In *Intelligent Information Systems, 1997. IIS '97. Proceedings* (pp. 345–349). <https://doi.org/10.1109/IIS.1997.645288>
- Mlakar, P. (2004). Analysis of ambient SO<sub>2</sub> concentrations and winds in the complex surroundings of a thermal power plant. *Nuovo Cimento- Societa Italiana Di Fisica Sezione C*, 6(6), 595–609. <https://doi.org/10.1393/ncc/i2004-10023-1>
- Mlakar, P., & Božnar, M. (2011). Artificial Neural Networks - a Useful Tool in Air Pollution and Meteorological Modelling. In *Advanced Air Pollution. InTech*. <https://doi.org/10.5772/20824>
- Mlakar, P., Božnar, M., Grašič, B., Oliveira, A. P. de, Soares, J. R., Gradišar, D., & Kocijan, J. (2015). Modeliranje difuznega sončnega obseva. *Raziskave s Področja Geodezije in Geofizike 2014 : Zbornik Del. 20. Srečanje Slovenskega Združenja Za Geodezijo in Geofiziko, Ljubljana, 29. Januar 2015. Ljubljana: Fakulteta Za Gradbeništvo in Geodezijo*, 45.
- Mlakar, P., Merše, J., & Faganelli Pucer, J. (2023). Ensemble weather forecast post-processing with a flexible probabilistic neural network approach. *ArXiv Preprint ArXiv:2303.17610*.
- Mlakar, P., Merše, J., & Faganelli Pucer, J. (2024). ANet: metoda za poprosiranje vremenskih napovedi s pomočjo strojnega učenja. *Raziskave s Področja Geodezije in Geofizike 2023 : Zbornik Del. 29. Srečanje Slovenskega Združenja Za Geodezijo in Geofiziko, Ljubljana, 1. Februar 2024. Ljubljana: Fakulteta Za Gradbeništvo in Geodezijo*.
- Oliveira, A. P., Soares, J., Božnar, M. Z., Mlakar, P., & Escobedo, J. F. (2006). An Application of Neural Network Technique to Correct the Dome Temperature Effects on Pyrgeometer Measurements. *Journal of Atmospheric and Oceanic Technology*, 23(1), 80–89. <https://doi.org/10.1175/JTECH1829.1>
- Perkan, U. (2023). Napovedovanje vremena s konvolucijskimi nevronskimi mrežami [Magistrsko delo, Univerza v Ljubljani, FMF - Fakulteta za matematiko in fiziko]. <https://repozitorij.uni-lj.si/IzpisGradiva.php?id=150234>
- Perne, M., Božnar, M. Z., Grašič, B., Mlakar, P., & Kocijan, J. (2021). Improving wind vector predictions for modelling of atmospheric dispersion during Seveso-type accidents. *Atmospheric Pollution Research*, 12(2), 76–83. <https://doi.org/10.1016/j.apr.2020.10.010>
- Perne, M., Kocijan, J., Božnar, M. Z., Grašič, B., & Mlakar, P. (2023). Hybrid Forecasting of Wind for Air Pollution Dispersion over Complex Terrain. *Journal of Environmental Informatics*. <https://doi.org/10.3808/jei.202300489>
- Petelin, D., Mlakar, P., Božnar, M. Z., Grašič, B., & Kocijan, J. (2015). Ozone forecasting using an online updating Gaussian-process model. *International Journal of Environment and Pollution*, 57(3–4). <https://doi.org/10.1504/IJEP.2015.074494>



- Skok, G., Hoxha, D., & Zaplotnik, Ž. (2021). Forecasting the Daily Maximal and Minimal Temperatures from Radiosonde Measurements Using Neural Networks. *Applied Sciences*, 11(22), 10852. <https://doi.org/10.3390/app112210852>
- Soares, J., Oliveira, A. P., Božnar, M. Z., Mlakar, P., Escobedo, J. F., & Machado, A. J. (2004). Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. *Applied Energy*, 79(2), 201–214. <https://doi.org/10.1016/j.apenergy.2003.11.004>
- Žabkar, R., Žabkar, J., & Čemas, D. (2004). Ground-level Ozone Forecast Based On Machine Learning. *WIT Transactions on Ecology and the Environment*, 74, 8. <https://doi.org/10.2495/AIR040051>
- Žabkar, J., Žabkar, R., Vladušič, D., Čemas, D., Šuc, D., & Bratko, I. (2006). Prediction of ozone concentrations. *Ecological Modelling*, 191(1), 68–82. <https://doi.org/10.1016/j.ecolmodel.2005.08.013>



Drugi del: razširjeni povzetki



# Verifikacija operativnih napovedi univerzalnega toplotnega klimatskega indeksa v Sloveniji

Danijela Kuzmanović\*, Jana Banko\*\*, Gregor Skok\*

## Povzetek

Univerzalni toplotni klimatski indeks (UTCI) je indeks toplotne obremenitve, ki opisuje, kako človeško telo občuti stanje okolice. Ima enote temperature in upošteva učinek temperature zraka, vlažnosti, vetra, sevanja in oblakov. V vse več državah se uporablja kot merilo toplotnega ugodja na prostem, njegova vrednost pa se izračunava v okviru operativne meteorološke napovedi. Hkrati pa napovedi UTCIja pogosto vsebujejo relativno veliko napako, ki jo povzroča napaka meteoroloških napovedi. V Sloveniji obstaja relativno gosta mreža meteoroloških postaj, na katerih se izvajajo tudi meritve globalnega sončnega sevanja, kar omogoča bolj natančno oceno dejanske vrednosti UTCIja, kot če meritev sevanja ni na voljo. V analizi smo uporabili sedem let meritev iz 42 postaj v urni ločljivosti. Najprej smo določili napako operativne napovedi UTCIja za prvi dan napovedi in nato poskušali izboljšati napovedi s pomočjo dveh metod strojnega učenja, linearno regresijo in nevronske mreže. Obe metodi sta uspešno zmanjšali napako operativnih napovedih UTCIja. Pri obeh se je povprečna napaka zmanjšala iz približno 2,6 °C na skoraj nič, medtem ko se je povprečna absolutna napaka zmanjšala s 5 °C na 3 °C v primeru nevronske mreže oziroma na 3,5 °C v primeru linearne regresije. Obe metodi, zlasti nevronska mreža, sta tudi znatno zmanjšali odvisnost napake od ure v dnevu.

**Ključne besede:** UTCI, ALADIN, BioKlima, verifikacija, termalni indeks, toplotni stres

**Keywords:** UTCI, ALADIN, BioKlima, verification, thermal indices, thermal stress

---

\* Univerza v Ljubljani, Fakulteta za Matematiko in Fiziko, Jadranska ul. 19, Ljubljana

\*\* Agencija Republike Slovenije za okolje, Vojkova 1b, Ljubljana



# Detekcija intenzivnih neviht na območju Slovenije

Matevž Osolnik<sup>1</sup>, Gregor Skok<sup>1</sup>, Matic Šavli<sup>2</sup>

## Povzetek

Nevihte veljajo za enega izmed nevarnejših meteoroloških pojavov, saj lahko proizvajajo močne sunke vetra in s tem povzročajo vetrolome, intenzivne nalive, ki so lahko povezani s poplavami meteorne vode, najbolj intenzivne nevihte pa lahko vsebujejo tudi debelo točo. Posledice intenzivnih neviht se lahko odražajo v poškodbah na objektih, kmetijskih pridelkih ter na ostali infrastrukturi, ogrožajo pa lahko tudi varnost ljudi in prometa. Zgodnje prepoznavanje potencialno nevarnih neviht je tako zelo pomembno, saj je na takšen način vsaj deloma mogoče preprečiti oziroma omiliti škodo, ki jo lahko povzroči takšna nevihta.

V okviru magistrske naloge je bila razvita metoda za detekcijo intenzivnih neviht na območju Slovenije. Metoda detektira intenzivne konvektivne celice na podlagi meritev meteorološkega radarja in razelektritev. Uporabljena je bila Python knjižnica Pysteps, ki temelji na tem, da v polju radarske odbojnosti najprej išče zaključena območja nad določenim pragom radarske odbojnosti, nato pa preko dodatnih kriterijev izmed teh območij določi tiste, ki ustrezajo konvektivnim celicam. Optimizacija metode in verifikacija rezultatov sta bili izvedeni na konvektivnih sezonah od maja do septembra v letih od 2020 do 2022. Za to so bili uporabljeni podatki o meritvah toče na padavinskih in klimatoloških postajah Agencije Republike Slovenije za okolje (ARSO) in podatki o intervencijah Uprave Republike Slovenije za zaščito in reševanje (URSZR), ki vsebujejo intervencije, ki so se zgodile zaradi toče, vetroloma in poplav meteorne vode. V primeru podatkov o intervencijah sta bili optimizacija in verifikacija izvedeni le na izbranih 13 območjih, kjer je prišlo do zadostnega števila javljenih dogodkov. Iz rezultatov so bili izračunani verifikacijski indeksi, ki bazirajo na kontingenčni tabeli. Preko teh indeksov je bila nato ovrednotena uspešnost metode in so bili določeni njeni optimalni parametri. Posebej smo analizirali tudi nekaj nevihtnih dni, za katere je ARSO izdal poročilo o neurjih. Metoda se je pri verifikaciji izkazala za sorazmerno uspešno pri detektiranju nevihtnih celic, ki povzročajo neurja s točo, vetrolomom in poplavam meteorne vode, rezultati verifikacije pa so primerljivi z rezultati podobnih študij, narejenih v Sloveniji in tujini. Razvita metoda tako lahko služi kot dodatno orodje meteorologom prognostikom pri subjektivnem kratkoročnem napovedovanju neviht, saj dobi prognostik pri uporabi te metode vpogled v aktivnost posamezne konvektivne celice in lahko lažje določi, katerim celicam je potrebno pri izdajanju opozoril dati večjo pozornost.

**Ključne besede:** nevihta, toča, vetrolom, poplava, radar, razelektritev, pysteps, verifikacija, optimizacija

**Keywords:** storm, hail, severe wind, flood, radar, lightning, pysteps, verification, optimization

---

<sup>1</sup> Univerza v Ljubljani, Fakulteta za Matematiko in Fiziko, Jadranska ul. 19, Ljubljana

<sup>2</sup> Agencija Republike Slovenije za okolje, Vojkova 1b, Ljubljana





# Nalivi, obilne padavine in izjemne poplave v Sloveniji med 3. in 8. avgustom 2023

Sašo Petan<sup>1</sup>, Gregor Vertačnik<sup>1</sup>, Miha Šupek<sup>1</sup>, Neža Lokošek<sup>1</sup>, Maja Koprivšek<sup>1</sup>, Anže Medved<sup>1</sup>, Mojca Sušnik<sup>1</sup>, Matevž Piry<sup>1</sup>, Florjana Ulaga<sup>1</sup>

## Povzetek

Od 3. do 6. avgusta so Slovenijo in dežele onstran severne meje prizadele obilne padavine. V severnem Sredozemlju je nastal ciklon z vremensko fronto. Takšna vremenska situacija je značilna za jesensko-zimski čas, ko na našem območju pade večja količina padavin v nekaj dneh. Zaradi zelo toplega Sredozemskega morja, ki je bilo na začetku avgusta 2023 toplejše od dolgoletnega povprečja, so najprej nastale močne plohe in nevihte z močnejšimi nalivi, ki jih je v nadaljevanju zamenjal še enakomeren dež.

V noči s 3. na 4. avgust so zelo močne plohe z nevihtami zajele porečja na širšem območju Kamniško-Savinjskih Alp, Karavank, Škofjeloškega, Cerkljanskega ter Polhograjskega hribovja. Na že predhodno namočeno podlago, posledica julijskih neurij, je v samo 6 do 12 urah padlo od 150 do 200 mm dežja. Na več kot 20 meteoroloških postajah smo zabeležili nalive s povratnimi dobami, ki so desegle in celo presegle 100-letne povratne nivoje. Najmočnejši naliv smo zabeležili na meteorološki postaji Pasja ravan, kjer je v manj kot 10 urah padlo preko 200 mm padavin. Tako izdatne padavine so povzročile silovit porast številnih hudournikov, manjših vodotokov in rek. 4. avgusta dopoldne so izjemne pretoke dosegle zlasti Meža, Mislinja, Suhodolnica, Savinja, Lučnica, Dreta, Kamniška Bistrica, Nevljica, Pšata, Sora, Poljanska Sora, Gradaščica, Šujica in Sava na Ljubljanskem območju. Pri tem so nastopile obsežne in uničujoče poplave, poplavljeni so bila številna naselja s stanovanjskimi in gospodarskimi objekti. Sprožili so se tudi številni plazovi, reke so nosile obsežne količine plavja in odnašale mostove in ceste. Že 4. avgusta sta vsled silovitega dotoka iz sosednje Avstrije pričeli poplavljeni tudi Mura in Drava. Drava je bila močno okrepljena z lokalnimi dotoki v Sloveniji, Mura pa z večkratnimi porasti pritokov dolvodno od avstrijskega Gradca. Mura v Gornji Radgoni je tako 6. avgusta dosegla rekordni pretok preko 1450 m<sup>3</sup>/s, pretok Drave po sotočju z Dravinjo pa je presegel 1900 m<sup>3</sup>/s.

Poplavni dogodek je močno spominjal na vse pretekle izjemne dogodke, ki so Slovenijo prizadele v letih 1990, 1998, 2005, 2007, 2010, 2012 in 2014, a jih je tokratni dogodek presegel po obsegu, v najbolj prizadetih porečjih pa tudi po silovitosti. Povratne dobe največjih pretokov manjših rek in glavnih odvodnikov v povirnih delih porečij Meže, Savinje, Kamniške Bistrice in Sore kot tudi reke Save na odseku od Medvod do Hrastnika so bile ocenjene na 100 in več let. Mura in Savinja v spodnjem toku sta dosegli od 50- do 100-letno, Sava pod sotočjem s Krko 20-letno, Drava v spodnjem toku pa 10- do 20-letno povratno dobo. Posebnost tokratnega dogodka je bila tudi ta, da so največje tri slovenske reke, Sava, Drava in Mura, poplavljele hkrati.

**Ključne besede:** obsežne poplave, hudourniki, izjemni pretoki, nalivi, obilne padavine

**Keywords:** extensive floods, torrents, exceptional flows, downpours, heavy rainfall

---

<sup>1</sup> Agencija RS za okolje, Vojkova 1b, Ljubljana



# Metoda ANET2: statistično poprocesiranje vremenskih napovedi s pomočjo nevronske mreže in normalizacijskih tokov

Peter Mlakar<sup>1,2</sup>, Janko Merše<sup>2</sup>, Jana Faganeli Pucer<sup>1</sup>

## Uvod

Poprocesiranje vremenskih napovedi je pomemben korak v formiranju bolj natančnih vremenskih napovedi. Razlog, da potrebujemo metode poprocesiranja, stoji za tem, da numerične vremenske napovedi vsebujejo sistematične napake. Te so posledica računskih poenostavitev, omejene ločljivosti napovednega modela in negotovosti, ki je prisotna že v atmosferski analizi (Bauer idr., 2015; Vannitsem idr., 2021; Hakim, Patoux, 2017). Evropski center za srednjeročne vremenske napovedi (ECMWF) z namenom, da bi bolje zajel negotovost vremenske napovedi, izdaja ansambelske vremenske napovedi. Te vsebujejo 51 različnih vremenskih napovedi za isti časovni termin ter iste lokacije z namenom simuliranja potencialno različnih vremenskih scenarijev v prihodnosti.

Kljub temu ansambelske napovedi še vedno vsebujejo napake, ki z večanjem napovednega časa naraščajo ter zmanjšujejo zanesljivost same napovedi, prav tako ostajajo že prej omenjene sistematične napake izračuna. Z namenom, da bi te napake omilili, lahko uporabimo metode poprocesiranja vremenskih napovedi (Vannitsem idr., 2021). Te delujejo tako, da na podlagi vremenske napovedi tvorijo novo verjetnostno napoved za določeno vremensko spremenljivko (npr. temperatura, količina padavin, hitrost vetra). Ta verjetnostna napoved opisuje kako verjetna je pojava določene vrednosti vremenske spremenljivke na določeni lokaciji ter ob določenem času. Cilj metod poprocesiranja je tvorjenje dobro kalibriranih verjetnostnih napovedi (Gneiting idr., 2007). Pristopov za poprocesiranje je mnogo, razlikujejo pa se predvsem po predpostavkah, na katerih slonijo. Vsaka metoda ima svoje prednosti in slabosti, njena uporaba pa je odvisna od specifik problema.

Pred kratkim so se na področju poprocesiranja vremenskih napovedi izkazale tudi nevronske mreže (Bremnes idr., 2020, Rasp in Lerch, 2018). Žal pa so v mnogih primerih aplikacije le teh omejene na en napovedni čas ali pa na posamezno lokacijo. Prav tako je veliko pristopov omejenih glede na tip verjetnostne porazdelitve, ki jo modelirajo, saj vrsto porazdelitve predpostavijo vnaprej (Rasp in Lerch, 2018). To predpostavko lahko sicer omilimo z metodo kvantilne regresije s pomočjo Bernsteinovih polinomov (Bremnes, 2020), a ta ne tvori eksaktne verjetnostne porazdelitve.

## Metoda in evalvacija

V našem raziskovalnem delu smo predlagali novo metodo za poprocesiranje vremenskih napovedi, Atmosferska nevronska mreža 2 (angleško "Atmosphere NETwork" (ANET2), ki predstavlja nadgradnjo naše prvotne metode ANET1. Za razliko od mnogih konkurenčnih pristopov ANET1 in ANET2 tvorita napoved za celoten napovedni čas naenkrat. Dodatno, ANET1 in ANET2 tvorita en sam model za poprocesiranje vseh napovednih lokacij, za kar mnogi pristopi potrebujejo toliko napovednih modelov, kot je lokacij samih. Pristop ANET2 se razlikuje od ANET1 po uporabi normalizacijskih tokov za modeliranje napovedne porazdelitve (Durkan idr., 2019; Dinh idr., 2016). S pomočjo slednjih lahko ANET2 tvori

---

<sup>1</sup> Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Večna pot 113, Ljubljana

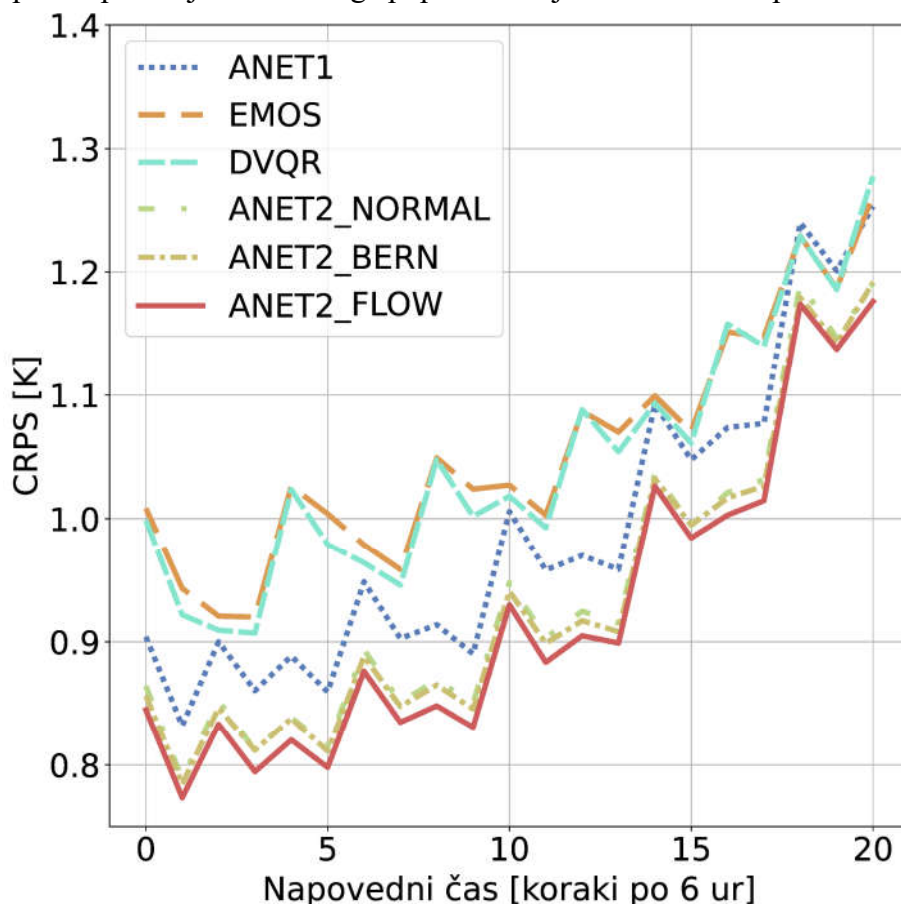
<sup>2</sup> Agencija Republike Slovenije za okolje, Vojkova 1b, Ljubljana

fleksibilne vremenske napovedi različno porazdeljenih spremenljivk, kot sta temperatura ali pa količina padavin, brez predhodnega poznavanja porazdelitve spremenljivke same. To omogoča ANET2 dodatno prilagodljivost ter zmožnost bogatejšega verjetnostnega opisovanja vremenskih realizacij.

Obe metodi smo evalvirali na podatkovni zbirki EUPPBench (Demaeyer idr., 2023) za poprocesiranje vremenskih napovedi. Natančneje, z metodama ANET1 in ANET2 smo poprocesirali napoved temperature za različne lokacije po srednji in zahodni Evropi in za napovedni čas petih dni. Prav tako smo normalizacijske tokove metode ANET2 primerjali z metodo Bernsteinovih polinomov, da bi bolje ocenili doprinos normalizacijskih tokov na področju poprocesiranja.

## Rezultati

Metoda ANET1 se je na podatkovni zbirki EUPPBench uvrstila med najboljše (Demaeyer idr., 2023). Posebej konkurenčna je bila na gorskih postajah v Švici, kjer je učinkovito odpravljala napake, ki so posledica razgibanega gorskega terena. Naš pristop modeliranja napovedi za celoten napovedni čas naenkrat pa je metodi ANET1 omogočil znatno zmanjšanje napake napovedi v prehodu dnevno nočnega cikla. Metoda ANET2 pa je še dodatno prekašala ANET1. V kombinaciji z novo arhitekturo nevronske mreže ter normalizacijskimi tokovi ANET2 uspe tvoriti bolj kalibrirane napovedi od referenčnih metod (Mlakar idr., 2023). ANET2 metoda z normalizacijskimi tokovi pa se je prav tako izkazala kot zelo konkurenčna napram metodi Bernsteinovih polinomov in tako predstavlja smiseln doprinos področju statističnega poprocesiranja vremenskih napovedi.



Slika 1 - Zvezna rangirana verjetnostna cenilka (angl. "continuous ranked probability score" CRPS) metod ANET1, ANET2 v primerjavi z dvema najboljšima metodama iz

EUPPBench podatkovne zbirke, metodo statistike ansambelskega modela (angl. "ensemble model output statistics" EMOS) ter kvantilne regresije s pomočjo D-vine kopul (angl. "D-vine copula quantile regression" DVQR).

Nižja vrednost CRPS (v Kelvinih) odraža boljšo napovedno moč. Cenilka CRPS je povprečena preko vseh napovednih lokacij ter zagonov napovednega modela. Iz slike lahko razberemo, da različica ANET2<sub>FLOW</sub>, ki temelji na nevronske mreži ANET2 in normalizacijskih tokovih, doseže najnižjo vrednost CRPS. Sledita ji preostala dva ANET2 pristopa, ki temeljita na Bernsteinovih polinomih ter normalni porazdelitvi.

## Literatura

- Bauer, P., Thorpe, A., & Brunet, G., 2015. The quiet revolution of numerical weather prediction. *Nature*, 525(7567), 47–55. doi:10.1038/nature14956
- Bremnes, J. B., 2020. Ensemble postprocessing using quantile function regression based on neural networks and Bernstein polynomials. *Monthly Weather Review*, 148(1), 403–414.
- Demaeyer, J., Bhend, J., Lerch, S., Primo, C., Van Schaeybroeck, B., Atencia, A., ... Vannitsem, S., 2023. The EUPPBench postprocessing benchmark dataset v1.0. *Earth System Science Data Discussions*, 2023, 1–25. doi:10.5194/essd-2022-465.
- Dinh, L., Sohl-Dickstein, J., & Bengio, S., 2016. Density estimation using real nvp. *arXiv Preprint arXiv:1605.08803*.
- Durkan, C., Bekasov, A., Murray, I., & Papamakarios, G., 2019. Neural spline flows. *Advances in Neural Information Processing Systems*, 32.
- Gneiting, T., Balabdaoui, F., & Raftery, A. E., 2007. Probabilistic forecasts, calibration and sharpness. *Journal of the Royal Statistical Society. Series B: Statistical Methodology*, 69(2). doi:10.1111/j.1467-9868.2007.00587.x.
- Hakim, G. J., & Patoux, J., 2017. *Weather: A Concise Introduction*. Retrieved from <https://books.google.si/books?id=pqXoAQAACAAJ>.
- Mlakar, P., Merše, J., & Pucer, J. F., 2023. Ensemble weather forecast post-processing with a flexible probabilistic neural network approach. *arXiv [Cs.LG]*. Retrieved from <http://arxiv.org/abs/2303.17610>.
- Rasp, S., & Lerch, S., 2018. Neural networks for postprocessing ensemble weather forecasts. *Monthly Weather Review*, 146(11), 3885–3900.
- Vannitsem, S., Bremnes, J. B., Demaeyer, J., Evans, G. R., Flowerdew, J., Hemri, S., ... Ylhaisi, J., 2021. Statistical postprocessing for weather forecasts review, challenges, and avenues in a big data world. *Bulletin of the American Meteorological Society*, 102(3). doi:10.1175/BAMS-D-19-0308.1.