

# Definiranje odnosa zagrebačkih jezera i rijeke Save

---

Šegović, Filip

Master's thesis / Diplomski rad

2022

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Mining, Geology and Petroleum Engineering / Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:169:853663>

*Rights / Prava:* [In copyright](#) / [Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2024-04-20**



*Repository / Repozitorij:*

[Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU  
RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET  
Diplomski studij geološkog inženjerstva

**DEFINIRANJE ODNOSA ZAGREBAČKIH JEZERA I RIJEKE SAVE**

Diplomski rad

Filip Šegović

GI 443

Zagreb, 2022.



KLASA: 602-01/22-01/98  
URBROJ: 251-70-15-22-2  
U Zagrebu, 27. 6. 2022.

Filip Šegović, student

## RJEŠENJE O ODOBRENJU TEME

Na temelju vašeg zahtjeva primljenog pod KLASOM 602-01/22-01/98, URBROJ: 251-70-15-22-1 od 30. 4. 2022. priopćujemo vam temu diplomskog rada koja glasi:

### DEFINIRANJE ODNOSA ZAGREBAČKIH JEZERA I RIJEKE SAVE

Za mentoricu ovog diplomskog rada imenuje se u smislu Pravilnika o izradi i obrani diplomskog rada Izv. prof. dr. sc. Jelena Parlov nastavnik Rudarsko-geološko-naftnog-fakulteta Sveučilišta u Zagrebu.

Mentorica:

(potpis)

Izv. prof. dr. sc. Jelena Parlov

(titula, ime i prezime)

Predsjednik povjerenstva za  
završne i diplomske ispite:

(potpis)

Doc. dr. sc. Zoran Kovač

(titula, ime i prezime)



Prodekan za nastavu i studente:

(potpis)

Izv. prof. dr. sc. Borivoje  
Pašić

(titula, ime i prezime)

*Zahvaljujem...*

*Svojoj mentorici, izv. prof. dr. sc. Jeleni Parlov, na predloženoj temi, savjetima i pomoći tijekom izrade diplomskog rada.*

*Tehničarima Saši Šipeku i Hrvoju Čičeku na pomoći na terenu.*

*Obitelji i prijateljima na podršci tijekom studija i pisanja diplomskog rada.*

## DEFINIRANJE ODNOSA ZAGREBAČKIH JEZERA I RIJEKE SAVE

Filip Šegović

Rad izrađen: Sveučilište u Zagrebu  
Rudarsko-geološko-naftni fakultet  
Zavod za geologiju i geološko inženjerstvo  
Pierottijeva 6, 10 000 Zagreb

### Sažetak

U diplomskom radu prikazan je utjecaja rijeke Save na vodostaj jezera Jarun i Savica. U analizama su korišteni podatci vodostaja Save s dvije mjerne postaje na području Grada Zagreba kao i podaci o vodostajima jezera prikupljeni automatskim mjeracima. Podatci su prikupljeni u razdoblju od 07.04.2022. do 26.05.2022. godine. Za definiranje odnosa rijeke Save i jezera korištene su statističke metode korelacije, linearna regresija i kroskorelacija. Metode korelacije i linearne regresije ukazuju na slabu vezu Save i Jaruna i kao i slabu vezu Save i Savice. Metodom kroskorelacije dobiveni su kroskorelogrami iz kojih je vidljivo da rijeka Sava utječe na promjenu vodostaja Jaruna sa zaostatom od 85 sati. S druge strane, rijeka Sava nema utjecaj na vodostaj jezera na Savici.

Ključne riječi: meandrirajuća rijeka, meandri, jezero Jarun, jezera Savica, rijeka Sava, vodostaj, automatski mjerač, korelacija, regresija, kroskorelacija

Završni rad sadrži: 40 stranica, 3 tablice, 27 slika i 25 referenci.

Jezik izvornika: Hrvatski

Pohrana rada: Knjižnica Rudarsko-geološko-naftnog fakulteta, Pierottijeva 6, Zagreb

Mentorica: Dr. sc. Jelena Parlov, izvanredni profesor RGNF

Ocjenjivači: Dr. sc. Jelena Parlov, izvanredni profesor RGNF  
Dr. sc. Kristijan Posavec, redoviti profesor RGNF  
Dr. sc. Zoran Kovač, docent RGNF

DEFINING THE RELATIONSHIP BETWEEN ZAGREB CITY LAKES AND THE SAVA RIVER

Filip Šegović

Thesis completed at: University of Zagreb  
Faculty of mining, Geology and Petroleum Engineering  
Department of Geology and Geological engineering  
Pierottijeva 6, 10 000 Zagreb

Abstract

The thesis presents the impact of the Sava River on the water level of Lakes Jarun and Savica. The analyzes used data on the water level of the Sava with two measuring stations in the City of Zagreb, as well as data on the water levels of the lake collected by loggers. Data were collected in the period from 07.04.2022. to 05.26.2022. Statistical methods of correlation, linear regression and cross-correlation were used to define the relationship between the Sava River and the lakes. The methods of correlation and linear regression indicate a weak connection between the Sava and the Jarun, as well as a weak connection between the Sava and the Savica lakes. Cross-correlation methods were used to obtain cross-correlograms, which show that the Sava River influences the change in the water level of the Jarun with a lag of 85 hours. On the other hand, the Sava River has no effect on the water level of the Savica lakes.

Keywords: meander river, meanders, lake Jarun, lakes Savica, Sava river, water level, logger, correlation, regression, cross correlation

Thesis contains: 40 pages, three tables, 27 figures, i 25 references.

Original in: English

Archived in: Library of Faculty of Mining, Geology and Petroleum Engineering, Pierottijeva 6, Zagreb

Supervisor: Associate professor Jelena Parlov, PhD

Reviewers: Associate professor Jelena Parlov, PhD  
Full professor Kristijan Posavec, PhD  
Assistant professor Zoran Kovač, PhD

# Sadržaj

|                                               |    |
|-----------------------------------------------|----|
| 1. Uvod.....                                  | 1  |
| 2. Teorijske osnove.....                      | 2  |
| 2.1. Općenito o meandrirajućim rijekama ..... | 2  |
| 2.2. Geološke i hidrogeološke značajke .....  | 6  |
| 2.3. Metode interpretacije.....               | 11 |
| 3. Uspostava mjerenja vodostaja .....         | 18 |
| 3.1. Opis lokacija mjerenja.....              | 18 |
| 3.2. Metode mjerenja.....                     | 23 |
| 4. Rezultati mjerenja .....                   | 28 |
| 5. Interpretacija rezultata i diskusija ..... | 30 |
| 5.1. Rezultati korelacijskih analiza .....    | 30 |
| 5.2. Rezultati regresijskih analiza .....     | 31 |
| 5.3. Rezultati kroskorelacijskih analiza..... | 32 |
| 5.4. Diskusija.....                           | 35 |
| 6. Zaključak.....                             | 37 |
| 7. Literatura .....                           | 38 |

## POPIS SLIKA

|                                                                                                                                                                                                                             |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Slika 2.1 Rijeka Menderes u istočnoj Turskoj.....                                                                                                                                                                           | 2  |
| Slika 2.2 Shema nastanka mrtvaje (preuzeto i modificirano prema LDNR, 2013.).....                                                                                                                                           | 3  |
| Slika 2.3 Odnos današnje lokacije jezera i toka Save 1783. godine (digitalizirano iz: maps.arcanum.com).....                                                                                                                | 4  |
| Slika 2.4 Odnos današnje lokacije jezera i toka Save 1869. godine (digitalizirano iz: maps.arcanum.com).....                                                                                                                | 5  |
| Slika 2.5 Isječak OGK List Zagreb, M 1:100 000 (Šikić i dr., 1972.), OGK List Ivanić Grad M 1:100 000 (Basch, 1981.).....                                                                                                   | 6  |
| Slika 2.6 3D hidrogeološki model zagrebačkog vodonosnika (Bačani i Posavec, 2014.)...                                                                                                                                       | 8  |
| Slika 2.7 Karta ekvipotencijala zagrebačkog vodonosnika (Parlov, 2019.).....                                                                                                                                                | 9  |
| Slika 3.1 Lokacije jezera Jarun i Savica s položajima automatskih mjerača vodostaja i hidrološkim postajama.....                                                                                                            | 18 |
| Slika 3.2 Lokacija jezera Jarun te postavljenog automatskog mjerača .....                                                                                                                                                   | 19 |
| Slika 3.3 Plastična cijev učvršćena na tri mjesta za konstrukciju mosta na Jarunu. X=5071901,01 ; Y=454279,26.....                                                                                                          | 20 |
| Slika 3.4 Lokacija jezera Savica i TE-TO Zagreb te postavljenog automatskog mjerača ..                                                                                                                                      | 21 |
| Slika 3.5 Učvršćivanje cijevi za vodokaznu letvu u Velikom jezeru. X=5070381,70 ; Y=463169,77 .....                                                                                                                         | 22 |
| Slika 3.6 Automatski mjerac tvrtke HOB0 (u simbiozi s jezerskim živim svijetom nakon određenog vremena provedenog u vodi) .....                                                                                             | 23 |
| Slika 3.7 Preuzimanje izmjerenih podataka s automatskog mjerača pomoću odgovarajuće bazne stanice.....                                                                                                                      | 24 |
| Slika 3.8 Lijevo: ručni mjerac; desno: mjerenje razine podzemne vode u piezometru ručnim mjeracem .....                                                                                                                     | 25 |
| Slika 3.9 Unošenje referentne vrijednosti razine vode i odgovarajuće datoteke za izračun promjene razina vode u vremenu.....                                                                                                | 25 |
| Slika 3.10 Sučelje software-a HOBOWare .....                                                                                                                                                                                | 26 |
| Slika 3.11 Sučelje VBA aplikacije (Posavec i dr., 2017.).....                                                                                                                                                               | 27 |
| Slika 4.1 Grafički prikaz rezultata mjerenja na Jarunu, zelena krivulja predstavlja razinu vode (m), plava krivulja temperaturu (°C), a crne krivulje predstavljaju tlakove (ukupni puna linija, atmosferski crtkana) ..... | 28 |

|                                                                                                                                                                                                                             |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Slika 4.2 Grafički prikaz rezultata mjerenja na Savici, zelena krivulja predstavlja razinu vode (m), plava krivulja temperaturu (°C), a crne krivulje predstavljaju tlakove (ukupni puna linija, atmosferski crtkana) ..... | 29 |
| Slika 4.3 Nivogrami rijeke Save za razdoblje od 07.04. do 26.05.2022. godine .....                                                                                                                                          | 29 |
| Slika 5.1 Nivogrami rijeke Save i Jezera za razdoblje od 25.04. do 26.05.2022. godine ...                                                                                                                                   | 30 |
| Slika 5.2 Rezultati dobiveni obradom podataka metodom linearne regresije Sava (Podsused) / Jarun .....                                                                                                                      | 31 |
| Slika 5.3 Rezultati dobiveni obradom podataka metodom linearne regresije Sava (Zagreb) / Savica .....                                                                                                                       | 32 |
| Slika 5.4 Kroskorelogram Sava (Podsused žičara) / Jarun (lag 740) .....                                                                                                                                                     | 33 |
| Slika 5.5 Kroskorelogram Sava (Podsused žičara) / Jarun (lag 200) .....                                                                                                                                                     | 34 |
| Slika 5.6 Kroskorelogram Sava (Zagreb) / Savica .....                                                                                                                                                                       | 35 |

## POPIS TABLICA

|                                                                                                                   |    |
|-------------------------------------------------------------------------------------------------------------------|----|
| Tablica 2.1 Jačina veze varijabli ovisno o vrijednosti koeficijenta korelacije $r$ (Horvat i Mijoč, 2012.). ..... | 13 |
| Tablica 2.2 Tip veze ovisno o koeficijentu determinacije prema Chadoku (preuzeto iz: slidetodoc.com). .....       | 16 |
| Tablica 3.1 Rezultati geodetskih mjerenja 26.05.2022. ....                                                        | 22 |

# 1. Uvod

Rijeka Sava je na području Zagreba sve do 1899. godine bila neregulirana, meandrirajuća rijeka. Zbog akumulacijsko-erozijskog mehanizma korito rijeke Save je pored matice rijeke uslijed intenzivnog taloženja naplavnog materijala često mijenjalo položaj te snažno erodiralo obale stalno stvarajući nove rukavce, mrtvaje, sprudove i otoke. Zbog toga tok rijeke Save na zagrebačkom području nije činio jedinstveno korito kakvo je danas, već čitav splet manjih tokova i rukavaca čiji se položaj neprestano mijenjao. S početkom regulacije korita rijeke i izgradnjom nasipa, neki rukavci i mrtvaji ostali su trajno odsječeni od glavnog korita rijeke. Iz tog razloga, na području grada Zagreba postoji cijeli niz jezera čiji postanak je vezan upravo uz regulaciju toka rijeke Save, te vađenja šljunka za izgradnju nasipa i drugih pratećih objekata, a za koje se nikada nije uspostavilo kontinuirano praćenje vodostaja i utvrđivanje odnosa s rijekom Savom.

Obzirom da je rijeka Sava prije regulacije toka, meandrirala cijelim zagrebačkim područjem te tako taložila materijal koji je danas sastavni dio zagrebačkog vodonosnika, te je danas usječena u vodonosnik i ima izravnu hidrauličku vezu s njim, može se pretpostaviti da postoji i hidraulička veza između jezera i rijeke.

Stoga je cilj ovoga rada definiranje odnosa rijeke Save i jezera Jarun i Savica. Za potrebe izrade diplomskog rada i institucijskog projekta NIVO postavljeni su automatski mjerači vodostaja jezera Jarun i Velikog jezera na Savici kako bi kontinuirano bilježili satne promjene. Mjerenje je trajalo od 07.04. za Jarun odnosno od 14.04. za Veliko jezero do 26.05.2022. godine. U tom razdoblju prikupljeno je 1174 satnih podataka za Jarun i 942 satna podatka za Veliko jezero. Podaci o satnim vodostajima rijeke Save preuzeti su s web stranice Državnog hidrometeorološkog zavoda Republike Hrvatske.

Za određivanje veze rijeke i jezera korištene su statističke metode korelacije, linearne regresije i kroskorelacije, a odnos Save i jezera kvantificiran je pomoću koeficijenta korelacije, determinacije i kroskorelacije te odgovarajućim grafovima i jednadžbama.

## 2. Teorijske osnove


### 2.1. Općenito o meandrirajućim rijekama

Riječ meandar potječe od imena maloazijske rijeke Meander, danas Menderes, koja je poznata po svome vrlo vijugavom toku (Slika 2.1). Hrvatska enciklopedija definira meandar kao krivudavi dio riječnoga toka, nalik na slovo S. U engleskoj literaturi postoji nekoliko termina koji detaljnije opisuju meandre s obzirom na oblik ili postanak. Primjerice, engl. *Oxbow* je uski meandar, u obliku slova U i ima ekstremnu zakrivljenost tako da između dva kraka ostaje samo mali dio zemlje. Termin engl. *False river* (ili stream) odnosi se na udubinu u poplavnoj ravnici u kojoj dolazi do zadržavanja vode nakon poplave, zatim tu je i pojam engl. *Oxbow lake* – vodeno tijelo (jezero) u obliku polumjeseca, smješteno blizu glavnog toka rijeke, u napuštenom kanalu nekadašnjeg meandra (mrtvaje), koje nije stalno prisutno (povremeno se pojavljuje) i koje je nastalo ili presijecanjem vrata meandra ili zapunjavanjem dijela meandra siltoznim materijalom.



Slika 2.1 Rijeka Menderes u istočnoj Turskoj

Postanak meandra karakterističan je za riječne doline maloga nagiba, na mjestima gdje je nanošenje (akumulacija) materijala veće od erozije, odnosno gdje je horizontalna erozija veća od vertikalne. S vremenom se vrat meandra sužava i na kraju odvaja napuštenu petlju meandra. Promjenom toka rijeke napuštena meandarska petlja ostane potpuno izolirana od glavnog kanala te nastaju riječna jezera i mrtvaje (Slika 2.2). (Hrvatska enciklopedija, 2021.; BBC, 2013.; Tetra Tech, 2003.).




Slika 2.2 Shema nastanka mrtvaje (preuzeto i modificirano prema LDNR, 2013.)

Sudbinu riječnog jezera i mrtvaje određuje ponašanje glavnog riječnog kanala. Mrtvaja se može postupno zapuniti sedimentom i pretvoriti u močvaru ili baru ako:


- riječni kanal ostaje blizu mrtvaje;
- postoji veza između vodenih tijela (rijeke i mrtvaje);
- mrtvaja prima vodu i sediment iz rijeke za vrijeme velikih voda.

Međutim, ako su glavni riječni kanal i mrtvaja minimalno povezani (kroz nasipe, velike udaljenosti, itd.), mrtvaja može ostati duboko vodeno tijelo dulje vrijeme (Saucier, 1994.).

Rijeka Sava je na području grada Zagreba, prije nego što su izgrađeni nasipi te tako umjetno usmjeren njen tok, također meandrira što se može vidjeti na starim topografskim kartama (Slika 2.3 i Slika 2.4). Meandrira je cijelim područjem između Medvednice, Samoborskog gorja i Vukomeričkih gorica te tako formirala tri aluvijalne terase odlažući materijal donesen iz uzvodnog dijela (aluvijalni nanosi).




Slika 2.3 Odnos današnje lokacije jezera i toka Save 1783. godine (digitalizirano iz: [maps.arcanum.com](http://maps.arcanum.com))



Slika 2.4 Odnos današnje lokacije jezera i toka Save 1869. godine (digitalizirano iz: [maps.arcanum.com](https://maps.arcanum.com))

## 2.2. Geološke i hidrogeološke značajke


Šire područje grada Zagreba je u razdoblju srednjeg i gornjeg pleistocena bilo ispunjeno jezerima i močvarama, dok su okolna gorja (Medvednica, Marijagorička Brda i Žumberačko gorje) bila izložena procesima intenzivne erozije i denudacije. Materijal nastao erozijom, potocima je nošen do jezera i močvara gdje se taložio (Velić i Saftić, 1991.). Početkom holocena, promjena klime i učestali tektonski procesi omogućili su prodor rijeke Save čime započinje transport materijala s područja Alpa (Velić i Durn, 1993.). Transport materijala bio je promjenjivog intenziteta uslijed čestih klimatskih promjena. Intenzivan transport materijala zbivao se za vrijeme toplih i vlažnih razdoblja, dok je za vrijeme hladnih i suhih razdoblja intenzitet padao. S obzirom na promjenjive uvjete taloženja koji su vladali, istaložene aluvijalne naslage odlikuje izrazita heterogenost i anizotropija te neujednačena debljina naslaga. Danas, na površini terena u dolinskom dijelu područja nalazimo upravo naslage srednjeg i gornjeg pleistocena te holocena (Slika 2.5).



Slika 2.5 Isječak OGK List Zagreb, M 1:100 000 (Šikić i dr., 1972.), OGK List Ivanić Grad M 1:100 000 (Basch, 1981.).


*Tumač oznaka: dpr – deluvij i proluvij: zaglinjeni siltovi i pijesci te kaotični materijal (valutice, nezaobljeni i slabozaobljeni fragmenti obližnjih stijena); a – aluvij: šljunci, pijesci i gline; pr – proluvij: šljunci, pijesci, gline a<sub>1</sub> – najniža terasa: šljunci, pijesci, podređeno gline; a<sub>2</sub> – srednja terasa: šljunci, pijesci; a<sub>3</sub> – najviša terasa: vapnenački konglomerati; ap – sedimenti poplava: pjeskovito-glinoviti ili glinoviti siltovi s prelazom u sitnozrne gline; am – aluvij mrtvaja: sitnozrne nevezane stijene predstavljene muljevima, izgrađenim od glinovitih siltova i siltoznih glina sa neraspadnutim organskim ostacima; l – kopneni beskarbonatni les: glinoviti silt; l<sub>b</sub> – barski les: siltozne gline; Pl, Q – šljunci, pijesci, gline (plioleistocen); Pl<sup>2</sup><sub>1</sub> – pijesci, pjeskoviti i glinoviti lapori, gline (gornji pont); Pl<sup>1</sup><sub>1</sub> – lapori, laporovite gline, podređeno pijesci, pješčenjaci, šljunci i konglomerati (donji pont); <sup>2</sup>M<sub>3</sub><sup>1,2</sup> – vapnoviti lapori, podređeno pijesci, pješčenjaci, šljunci i konglomerati (gornji panon); <sup>1</sup>M<sub>3</sub><sup>1,2</sup> – laporoviti vapnenci, vapnoviti lapori, podređeno pijesci i pješčenjaci (donji panon); <sup>2</sup>M<sub>3</sub><sup>2</sup> – vapnoviti lapori, pijesci, pješčenjaci, konglomerati i breče (panon); <sup>1</sup>M<sub>3</sub><sup>1</sup> – vapnoviti, glinoviti i kremični lapori, laporoviti vapnenci i pješčenjaci (donji sarmat); <sup>2</sup>M<sub>2</sub><sup>2</sup> – organogeni i bioklastični vapnenci, pješčenjaci, vapnoviti i glinoviti lapori (gornji torton); <sup>3,4</sup>K<sub>2</sub><sup>3</sup> – breče, konglomerati, vapnenci, lapori, pješčenjaci (kampan-mastriht); T3 – dolomiti, podređeno vapnenci, dolomitični vapnenci i šejli; T2 – dolomiti, podređeno vapnenci, lapori, rožnjaci, tufovi i tufiti; T1 – pješčenjaci, siliti, vapnenci, podređeno dolomiti i vapnoviti lapori; D, C? – ortometamorfiti.*

Srednje i gornje pleistocenske naslage zajedno s holocenskim naslagama tvore jedinstveni vodonosni sustav koji se dominantno sastoji od tri vrste naslaga: pijesaka i šljunaka koji čine vodonosni sloj te prahovite gline, odnosno glinovitih prahova koji tvore „nepropusni“ sloj u podini vodonosnika, a ponegdje i u krovini vodonosnika. Kao što je prikazano na slici 2.6, sustav se sastoji od tri sloja: krovinskih naslaga, prvog vodonosnog sloja koji je dominantno sastavljen od aluvijalnih materijala donesenih rijekom Savom u holocenu te drugog vodonosnog sloja s dominantno jezersko-barskim naslagama koje su se taložile u srednjem i gornjem pleistocenu (Posavec, 2006. ; Bačani i Posavec, 2014.).



*Slika 2.6 3D hidrogeološki model zagrebačkog vodonosnika (Bačani i Posavec, 2014.).*

S obzirom da se radi o otvorenom vodonosniku, krovinu vodonosnika čini vodna ploha koja je u kontaktu s rijekom Savom koja je svojim koritom usječena u aluvijalne holocenske naslage. Rijeka Sava za vrijeme visokih voda napaja vodonosnik duž cijelog toka (Slika 2.7). Napajanje podzemne vode iz Save prvenstveno ovisi o trajanju i učestalosti vodostaja te o temperaturi koja utječe na hidrauličku vodljivost naslaga na dnu rijeke, koritu Save (tj. širini korita te debljini i hidrauličkoj vodljivosti naslaga (pretežito šljunci) na dnu Save) i vodonosnom sloju (tj. razini podzemne vode i parametrima vodonosnika). Prihranjivanje vodonosnika se djelomično odvija i infiltracijom oborina, kao i infiltracijom iz propusne kanalizacijske i vodovodne mreže. Za vrijeme niskih voda na pojedinim dijelovima toka Sava drenira vodonosnik te time nepovoljno utječe na razine podzemne vode. To dreniranje se izravno odražava na smanjenje dostupnih količina vode za vrijeme dužih sušnih razdoblja (Posavec, 2006.). Vodonosnik je na sjeveru omeđen, u hidrauličkom smislu, nepropusnim granicama, na zapadu se vodonosnik puni dotjecanjem iz susjednog Samoborskog vodonosnika, dok se po južnoj granici puni dotjecanjem vode s Vukomeričkih Gorica. Granica otjecanja nalazi se na istoku vodonosnika. Generalno se podzemna voda kreće od zapada prema istoku (jugoistoku) (Slika 2.7) (Posavec, 2006.).



Slika 2.7 Karta ekvipotencijala zagrebačkog vodonosnika (Parlov, 2019.).

Holocenske naslage, koje čine glavni vodonosni sloj, dominantno su izgrađene od šljunaka karakteriziranih visokom hidrauličkom vodljivošću (u zapadnim predjelima hidraulička vodljivost je vrlo visoka te iznosi više od 3000 m/dan, prema istoku se njene vrijednosti snižavaju sve do iznosa manjih od 1000 m/dan). Naslage imaju utvrđenu dobru povezanost s rijekom Savom pa se može pretpostaviti da će i stari savski rukavci (mrtvaji) pokazati sličnu hidrauličku povezanost s rijekom.

Prema Basch-u (1983.), ovisno o načinu postanka (antropogeno ili prirodno) i propusnosti materijala u podlozi, razlikuju se stara napuštena korita vodotokova i mrtvaje. Stara napuštena korita vodotokova su nastala, najvećim dijelom, kao posljedica regulacijskih radova na vodonepropusnim terenima. Mogu se pronaći na području Save u sedimentima močvarnog prapora. Suprotno njima, pretežno prirodnim putem, na vodopropusnoj podlozi izgrađenoj od savskih aluvijalnih sedimenata, nastale su mrtvaje i dijelovi napuštenih protočnih korita. Ovdje se mogu izuzeti staro korito Lomnice i pojedine savske mrtvaje, koje su formirane izgradnjom kanala Sava-Odra, odnosno izradom nasipa i regulacijom korita Save u novije vrijeme.

Unutar izdvojenih mrtvaja i napuštenih korita vodenih tokova mogu se pratiti sve faze njihovog razvoja. Tako primjerice, na području savskog aluvija i dijelu toka Lonje između Zeline i Lomnice postoje oblici s permanentnom sedimentacijom, koji su još uvijek, za vrijeme visokog vodostaja, u povremenoj, površinskoj vezi s matičnim tokom, ili je ta veza podzemna. U njima se stalno zadržava voda, čija količina zavisi o razini podzemne vode. Prelazni stadij čine oblici faza zamočvarenja sa smanjenom sedimentacijom, koja je praćena odlaganjem organskih ostataka. U završnom stadiju razvoja, dijelovi starih korita i meandri samo su povremeno, u vrijeme kišnih razdoblja, pod vodom. To su pretežno već veoma plitka, sedimentima zapunjena korita, koja se, zbog veće vlažnosti tla, od okoline razlikuje razvojem močvarnog bilja. Sedimenti mrtvaja i starih vodenih tokova su sitnozrne, nevezane stijene predstavljene muljevima, izgrađenim od glinovitih siltova i siltoznih glina, koji sadrže znatne količine neraspadnutih organskih ostataka. Na području savskog aluvija u sastav im ulaze i sitnozrni, zaglinjeni pijesci. Veoma su tanki i nevelikog prostranstva – vezani neposredno na područje napuštenog korita (Basch, 1983.).

## 2.3. Metode interpretacije

Metode interpretacije, korištene u ovome radu, su metode korelacije, regresije i kroskorelacije. Temelje se na usporedbi dvaju varijabli, bilo zavisnih ili nezavisnih ili njihovoj kombinaciji. Te varijable su u ovome slučaju vodena tijela, rijeka (nezavisna) i jezera (zavisna). Iz odnosa dvaju niza podataka mogu se izračunati koeficijenti korelacije, determinacije i kroskorelacije koji nam govore o jakosti veze između tih dvaju varijabli, tj. postojanju veze.

### 2.3.1. Korelacija

Korelacija ili povezanost je odnos ili međuovisnost dvaju mjerljivih varijabli (Žugaj, 2000.).

Primjenom metode korelacije može se odrediti jačina veze između vodonosnih sustava i njihovih rubnih uvjeta. Ovisno o jačini veze može se utvrditi dominantnost i utjecaj pojedinog rubnog uvjeta, primjerice oscilacije razina površinskih ili podzemnih voda vodonosnih sustava, ali i osjetljivost vodonosnih sustava na njihove ulaze i izlaze (Posavec i Škudar, 2016.).


Jačine veza izražene su koeficijentom korelacije. On ne ovisi o mjernim jedinicama u kojima su izražene vrijednosti varijable, tj. bezdimenzionalan je. Iako postoji više koeficijenata korelacije za različite slučajeve, prilikom rada s linearnim modelima najčešće se koristi Pearsonov koeficijent korelacije (Ratkaj, 2014.).

Koeficijent korelacije  $r_{jk}$ , predstavlja omjer kovarijance dvije varijable  $cov_{jk}$  i umnoška njihovih standardnih devijacija  $s_j$  i  $s_k$  (Davis, 2002., [Correlation Coefficient -- from Wolfram MathWorld](#)):

$$r_{jk} = \frac{cov_{jk}}{s_j s_k} \quad (2-1)$$

Vrijednost koeficijenta korelacije iznosi od +1 do -1. Koeficijent 1 pokazuje savršenu ovisnost dvije varijable, dok negativan predznak pokazuje da se jedna varijabla mijenja inverzno u odnosu na drugu. Ako je korelacija vrlo slaba ili ako je nema, vrijednosti koeficijenta korelacije bliske su nuli (Slika 2.8). Općenito, koeficijenti korelacije veći od 0,8

ukazuju na jaku korelaciju dok koeficijenti korelacije manji od 0,5 ukazuju na slabu korelaciju (Posavec i Škudar, 2016.).



Slika 2.8 Dijagrami rasipanja (engl. Scatter dijagram) za različite vrijednosti koeficijenta korelacije (Preuzeto iz Korelacije - Znanost Blog; datum: 24.03.2022.)

Podjela jačine veze između varijabli, ovisno o vrijednosti koeficijenta, prikazana je u tablici 2.1.

Tablica 2.1 Jačina veze varijabli ovisno o vrijednosti koeficijenta korelacije  $r$  (Horvat i Mijoč, 2012.).

| Apsolutna vrijednost koeficijenta korelacije $r$ | Jačina veze između varijabli |
|--------------------------------------------------|------------------------------|
| $ r  = 1$                                        | Potpuna korelacija           |
| $0,8 \leq  r  < 1$                               | Jaka korelacija              |
| $0,5 \leq  r  < 0,8$                             | Srednje jaka korelacija      |
| $0,2 \leq  r  < 0,5$                             | Relativno slaba korelacija   |
| $0 <  r  < 0,2$                                  | Neznatna korelacija          |
| $ r  = 0$                                        | Bez korelacije               |

### 2.3.2. Regresija

Primjenom metode regresije može se odrediti funkcionalna ovisnost pojedinog rubnog uvjeta i događaja u sustavu, primjerice ovisnost infiltracije iz oborina (nezavisna varijabla) koja predstavlja rubni uvjet i razine podzemne vode (zavisna varijabla) koje predstavljaju događaje u sustavu. Dobivena funkcija (jednadžba), u slučaju da dobro opisuje promjene zavisne varijable u funkciji nezavisne varijable, može poslužiti primjerice za prognoziranje oscilacija razina podzemne vode (zavisna varijabla), a da pritom ne treba izvoditi detaljne konceptualne modele ili složenije matematičke modele te ih rješavati primjenom kompleksnih analitičkih, odnosno numeričkih metoda (Posavec i Škudar, 2016.).

Osim za analiziranje varijabli u međusobnoj funkcionalnoj ovisnosti (npr. promjena razine podzemne u vodonosniku u ovisnosti o promjenama vodostaja rijeke ili infiltraciji oborina) koristi se i za analiziranje setova podataka odnosno mjerenja uređenih u prostoru (npr. promjena sadržaja vlage u tlu s promjenom dubine) ili vremenu (npr. promjena razine podzemne vode u vremenu). Prema tome, za analizu regresije treba poznavati lokacije gdje su provedena mjerenja i vrijeme kada su provedena, ali i tendencija samih mjerenih podataka. Tendencija se koristi za interpolaciju između mjerenja, ekstrapolaciju izvan mjerenih podataka te u konačnici za donošenje zaključaka o postojanju ili nepostojanju trenda (Posavec i Škudar, 2016.).

S obzirom na prirodu proučavanih procesa, poznatu varijablu predstavljaju vrijeme ili udaljenost odnosno dubina te položaj u prostoru. Drugu varijablu, koja je raspodijeljena duž razmatranog kontinuuma tj. prostora ili vremena, predstavljaju npr. razina podzemne vode ili sadržaj vlage u tlu. Druga varijabla, varijabla  $Y$ , predstavlja slučajnu varijablu, dok su

varijable  $X$ , npr. dubina ili vrijeme, varijable koje predstavljaju fiksnu varijablu. Stoga je zadatak prognozirati  $Y$  varijablu u funkciji varijable  $X$ , to se postiže podešavanjem linije minimizacijom odstupanja od varijable  $Y$  (Posavec i Škudar, 2016.).

Zavisna ili regresirana varijabla  $Y$  je ona varijabla koja se istražuje, njena pojedinačna mjerenja označuju se s  $y_i$ . Odstupanja od pojedinačnih mjerenja se, prilikom podešavanja linije, minimiziraju. Nezavisna varijabla  $X$  naziva se još i regresor, njena pojedinačna mjerenja označavaju se s  $x_i$ . Stoga se jednadžba podešene linije može pisati kao:

$$\hat{y}_i = b_0 + b_1 x_i \quad (2-2)$$

gdje je:

$\hat{y}_i$  – procijenjena vrijednost  $y_i$  za odnosnu vrijednost  $x_i$ ,

$b_0$  – odsječak na osi  $Y$ ,

$b_1$  – koeficijent smjera pravca.

Odstupanja koja su također interesantna za razmatranje, definiraju se kao  $\hat{y}_i - y_i$ , odnosno promatra se razlika između prognozirane i izmjerene vrijednosti zavisne varijable. Da bi se dobila najbolje podešena linija, potrebno je tu razliku minimizirati na način da je:

$$\sum_{i=1}^n (\hat{y}_i - y_i)^2 = \text{minimum} \quad (2-3)$$

Kod regresije se razmatra odstupanje podešene linije tj. odstupanje regresijskog modela od aritmetičke sredine zavisne varijable  $Y$  i odstupanje mjerenih vrijednosti zavisne varijable  $y_i$  od te iste aritmetičke sredine (Posavec i Škudar, 2016.). Kako bi se odredila mjera podešenosti linije, tj. regresijskog modela koji predstavlja mjeru korisnosti modela, potrebno je definirati koeficijent determinacije  $R^2$  (engl. *Coefficient of determination, Goodness of fit*) (Davis, 2002.; Montgomery i Runger, 2003.). Prema tome potrebno je definirati dva termina koji opisuju promjenu zavisne varijable  $Y$ .

Prvi termi definiran je kao ukupna suma kvadrata ( $SS_T$ ) od  $Y$  (engl. *total sum of squares*), a opisuje odstupanja pojedinačnih mjerenja zavisne varijable  $Y$  od njihove aritmetičke sredine:

$$SS_T = \sum_{i=1}^n (y_i - \bar{Y})^2 \quad (2-4)$$

gdje je:

$y_i$  – pojedinačna mjerenja zavisne varijable  $Y$ ,

$\bar{Y}$  – aritmetička sredina pojedinačnih mjerenja zavisne varijable  $Y$ .

Drugi termin definiran je kao suma kvadrata zbog regresije ( $SS_R$ ) (engl. *sum of squares due to regression*), a opisuje odstupanja procijenjenih, tj. prognoziranih vrijednosti zavisne varijable  $Y$  od njihove aritmetičke sredine:

$$SS_R = \sum_{i=1}^n (\hat{y}_i - \bar{Y})^2 \quad (3-4)$$

gdje je:

$\hat{y}_i$  – procijenjena vrijednost  $y_i$  za odnosnu vrijednost  $x_i$ ,

$\bar{Y}$  – aritmetička sredina pojedinačnih mjerenja zavisne varijable  $Y$ .

Mjera točnosti aproksimacije linijom, tj. mjera točnosti regresijskog modela mjerenim vrijednostima odnosno mjera korisnosti modela definira se kao:

$$R^2 = \frac{SS_R}{SS_T} \quad (3-1)$$

gdje je:

$R^2$  – koeficijent determinacije

Koeficijent determinacije  $R^2$  predstavlja mjeru koja omogućuje procjenu točnosti podešavanja linije, tj. regresijski model reprezentira mjerene podatke i određuje pouzdanost prognoziranja zavisne varijable pomoću dobivenog regresijskog modela. Ako linija tj. regresijski model dobro reprezentira mjerene vrijednosti,  $R^2$  će biti blizak jedinici dok će u suprotnom biti blizak nuli ( $0 \leq R^2 \leq 1$ ). Vrijednost koeficijenta determinacije daje postotak mjerenih podataka koji su najbliže podešenoj liniji tj. regresijskom modelu. Primjerice ako je  $R^2 = 0,85$ , to znači da se 85% ukupnog odstupanja varijable  $Y$  od podešene linije tj. regresijskog modela, može objasniti linearnim odnosom između varijabli  $X$  i  $Y$  odnosno podešenom linijom tj. regresijskim modelom, dok preostalih 15% od ukupnog odstupanja ostaje neobjašnjeno. Jedna do korisnijih relacija je ta da drugi korijen iz koeficijenta determinacije  $R^2$  predstavlja višestruki koeficijent korelacije  $R$  koji je algebarski ekvivalentan koeficijentu korelacije  $r$  danom u jednadžbi 2-1 (Posavec i Škudar, 2016.).

U Tablica 2.2 prikazana je podjela prisutnosti, odnosno jakosti veze s obzirom na vrijednost koeficijenta determinacije  $R^2$ .

Tablica 2.2 Tip veze ovisno o koeficijentu determinacije prema Chadoku (preuzeto iz: [slidetodoc.com](http://slidetodoc.com)).

| Koeficijent determinacije $R^2$ | Jačina veze          |
|---------------------------------|----------------------|
| 0,00                            | Odsutnost veze       |
| 0,00 – 0,25                     | Slaba veza           |
| 0,25 – 0,64                     | Veza srednje jakosti |
| 0,64 – 1,00                     | Čvrsta veza          |
| 1,00                            | Potpuna veza         |

### 2.3.3. Kroskorelacija

Promjene pojedinih rubnih uvjeta, primjerice oscilacije vodostaja velikih rijeka, mogu biti iznimno brze te tako u vrlo kratkom vremenu mogu uzrokovati značajne promjene u samom vodonosnom sustavu (oscilacije razina podzemne vode). Istraživanje brzine interakcije pojedinog rubnog uvjeta i događaja u vodonosnom sustavu bitno je pri karakterizaciji istraživanog vodonosnog sustava te pri izradi njegovog konceptualnog modela. Brzinu interakcije odnosno samo vrijeme prijenosa tlaka podzemnom vodom, može se odrediti primjenom metode kroskorelacije (Posavec i Škudar, 2016.).

Kros-korelacija definira mjeru sličnosti dviju varijabli odnosno dvaju niza podataka tj. stupanj do kojeg se dva niza koreliraju s obzirom na zaostajanje jedne varijable u odnosu na drugu. Proces njihove usporedbe za svako uzastopno zaostajanje naziva se kros-korelacija (Davis, 2002.). Najprimjerenije ju je koristiti za usporedbu dvaju vremenskih nizova. Jačina veze između dva vremenska niza definirana je koeficijentom korelacije  $r$ , koji se računa za svako uzastopno zaostajanje. Najveći određeni koeficijent korelacije određuje vremensko zaostajanje između dva vremenska niza. U kroskorelacijskoj analizi mjerenja vremenskih nizova trebaju biti obavljana u isto vrijeme kako bi međusobno vremenski odgovarala. Nulto zaostajanje predstavlja poravnanje dva vremenska niza na isto, početno vrijeme mjerenja, a usporedba se radi kako za nulto zaostajanje tako i za svako sljedeće uzastopno zaostajanje, uključujući i pozitivne i negativne pozicije vremenskog zaostajanja, pri čemu vremenski niz A slijedi vremenski niz B i obratno. Rezultati kroskorelacijske analize prikazuju se na kros-korelogramu (Posavec i Škudar, 2016.).

Jačina veze između vremenskih nizova određuje se preko koeficijenta korelacije,  $r$ , koristeći istu jednadžbu kao i za običnu linearnu korelaciju (jednadžba 2-1). Jednadžba 2-1

primjenjuje se samo na segmente dva vremenska niza koji se preklapaju. Stoga apsolutni maksimalni broj pozicija koje se preklapaju iznosi  $n-2$ , pri čemu  $n$  označava broj podataka u danim vremenskim nizovima (Posavec i Škudar, 2016.).

### 3. Uspostava mjerenja vodostaja

#### 3.1. Opis lokacija mjerenja


Za potrebe određivanja veze između jezera i rijeke Save, postavljeni su automatski mjerači vodostaja u jezera Jarun i Veliko jezero na Savici. Lokacije automatskih mjerača i hidroloških postaja na kojima se mjeri vodostaj Save prikazane su na Slika 3.1.



Slika 3.1 Lokacije jezera Jarun i Savica s položajima automatskih mjerača vodostaja i hidrološkim postajama

**Jezero Jarun** smješteno je između Horvaćanske ceste i lijeve obale rijeke Save te naselja Horvati, Srednjaci, Gajevo i Gredice na istoku, Staglišće na sjeveru te Vrbani i Prečko na zapadu. Jezero Jarun se sastoji od dva povezana jezera, Veliko jezero i Malo jezero te šest otoka (Otok Univerzijade, Otok Trešnjevka, Otok Hrvatske mladeži, Otok divljine, Otok veslača i Otok ljubavi) (Slika 3.2). Jarun je nekada bio dio rukavca rijeke Save, a njegov

današnji oblik počeo je poprimati tek 1964. nakon velike Zagrebačke poplave kada je tok rijeke Save potpuno izmijenjen izgradnjom velikih nasipa. Prekidom kontakta sa Savom, Jarun je ubrzo poprimio močvarne karakteristike. Međutim zbog velikih potreba za šljunkom koji se tada koristio za izgradnju nasipa prenamijenjen je u šljunčaru iz koje su se eksploatirale ogromne količine šljunka pa velikim produbljivanjem naposljetku postaje današnje Jarunsko jezero ([www.zgportal.com](http://www.zgportal.com)).



*Slika 3.2 Lokacija jezera Jarun te postavljenog automatskog mjerača*

Automatski mjerač za praćenje vodostaja Jaruna postavljen u jezero na sredini mosta, a nalazi se u cijevi koja je fiksirana u temelju srednjeg stupa mosta te vertikalno iznad za samu metalnu konstrukciju mosta (Slika 3.3). Plastična cijev promjera 10 cm je duga 7,5 m. Cijev je odmaknuta cca 20 cm od samog dna jezera kako ne bi došlo do začepljenja cijevi te prekida komunikacije s vodom iz jezera. Unutar cijevi je, osim automatskog mjerača za razinu vode koji se nalazi u vodi pri dnu cijevi, postavljen i automatski mjerač neposredno kod ušća cijevi kako bi mjerio atmosferski tlak. Mjerači vise na čeličnim sajlama.




*Slika 3.3 Plastična cijev učvršćena na tri mjesta za konstrukciju mosta na Jarunu.  $X=5071901,01$  ;  $Y=454279,26$*

**Jezera Savica** nalaze se u prostoru između Radničke ceste i lijeve obale rijeke Save, a u bližem okruženju smješteni su: stambena naselja Savica Šanci i Borovje, termoelektrana – toplana (TE-TO), te gospodarska zona oko Radničke ceste,.


Jezera su nekada bila dio rukavca Save koji je prekinut izgradnjom nasipa radi zaštite od poplava. Jednako kao i Jarun i ova jezera su se koristila za vađenje šljunka i pijeska za građenje privatnih stambenih objekata te obližnje toplane TETO. Upravo zahvaljujući toplani koja povremeno upušta vodu u jezera, ona imaju približno jednak vodostaj kroz cijelu godinu. Voda se obično upušta sredinom petog mjeseca ili na zahtjev ribočuvara. Ukupno se na tome području nalazi 12 Jezera (Slika 3.4), od kojih su, prema informacijama dobivenih

od strane ribočuvara, jedino su jezera Plavac (dubina 5 m), Stara Savica i Ušće (~5 m) dio originalnih meandara, dok su ostala jezera: Veliko jezero (~7 m), Mala graba, Mazutara, Žuta graba, Lopočara, Vrbova (~6 m), Ciganska, Hawai (~3 m) i Potkova (~5 m), nastala uslijed vađenja šljunka.



*Slika 3.4 Lokacija jezera Savica i TE-TO Zagreb te postavljenog automatskog mjerača*

Automatski mjerač za praćenje vodostaja postavljen je u Velikom jezeru kod vodokazne letve. Postavljen je u perforiranu plastičnu cijev promjera 10 cm i dužine 2,30 m. Cijev je postavljena do dna jezera i učvršćena za vodokaznu letvu. U nju je također postavljen automatski mjerač za mjerenje atmosferskog tlaka. Cijev je izdignuta 30 cm iznad vodokazne letve kako mjerač koji mjeri atmosferski tlak ne bi došao u kontakt s vodom prilikom visokih vodostaja (Slika 3.5).



Slika 3.5 Učvršćivanje cijevi za vodokaznu letvu u Velikom jezeru.  $X=5070381,70$  ;  $Y=463169,77$

Za obje lokacije automatskog mjerača izvedena su i geodetska mjerenja kako bi se utvrdile točne koordinate i referentne vrijednosti nadmorskih visina (Tablica 3.1). Referentne vrijednosti mjerene su od vrha poklopca plastične cijevi pa zatim korigirane za debljinu plastičnog poklopca (3 mm).

Tablica 3.1 Rezultati geodetskih mjerenja 26.05.2022.

| Naziv            | X(N) HTRS96 | Y(E) HTRS96 | Referentna visina<br>[m n.m.] |
|------------------|-------------|-------------|-------------------------------|
| Jarun_cijev_most | 5071901,01  | 454279,26   | 118,01                        |
| Savica_cijev     | 5070381,7   | 463169,77   | 109,88                        |

### 3.2. Metode mjerenja

Podatci o visini vodostaja rijeke Save, mjereni na hidrološkim postajama Sava Zagreb (šifra 3121) i Sava Podsused Žičara (šifra 3087), preuzeti su sa stranice Državnog hidrometeorološkog zavoda (DHMZ-a) koji ujedno i izvodi mjerenja vodostaja Save (preuzeti podaci se odnose na dojave automatskih stanica i nisu verificirani od strane DHMZ-a). Podatci o vodostajima jezera Jarun i Savica izmjereni su od strane Rudarsko-geološko-naftnog fakulteta u Zagrebu.


Razine vode u jezerima izmjerene su automatskim mjeračima tvrtke HOBO (Slika 3.6). Kako bi se dobile promjene razine voda u vremenu potrebna su dva uređaja, jedan koji mjeri atmosferski tlak (tzv. baro) te jedan koji je uronjen u vodu, koji mjeri ukupni tlak (hidrostatski + atmosferski). Iz razlike ukupnog i atmosferskog tlaka dobiva se tlak stupca vode, te se uz pomoć ručnog mjerenja dubine do vode i poznate nadmorske visine ruba cijevi (kota nule) izračuna vodostaj u datom trenutku.



*Slika 3.6 Automatski mjerač tvrtke HOBO (u simbiozi s jezerskim živim svijetom nakon određenog vremena provedenog u vodi)*


Automatski mjerači rade na bateriju i imaju unutarnju memoriju u koju spremaju izmjerene podatke. Imaju mogućnost podešavanja zapisa podataka u određenim vremenskim intervalima (sekunda, minuta, sat...). Za potrebe ovoga rada zadani interval mjerenja iznosi jedan sat.

Za upravljanje automatskim mjeračima te za preuzimanje izmjerenih podataka koristi se HOBOWare software tvrtke ONSET COMPUTER CORPORATION. Automatski mjerači se povezuju sa software-om pomoću adaptera ukopčanog preko USB porta u računalo (Slika 3.7).




*Slika 3.7 Preuzimanje izmjerenih podataka s automatskog mjerača pomoću odgovarajuće bazne stanice*

Razinu vode potrebno je izmjeriti i ručnim mjeračem (Slika 3.8) te zapisati točno vrijeme mjerenja iz razloga što je software-u potrebna referentna vrijednost od koje može izmjerene razlike tlakova prevesti u iznos promjena razina vode kroz vrijeme. Postoje mjerači s milimetarskom i centimetarskom podjelom. Mjerna traka je namotana na koloturu koja ima u sebi ugrađen prijemnik sa zvučnim i svjetlosnim signalom koji reagira na senzor koji se nalazi na vrhu mjerne trake. Senzor u kontaktu s vodom šalje signal prijemniku. Očitavanje se vrši u ravnini geodetski određene kote nula koja je najčešće zadana na vrhu cijevi (Slika 3.8).




Slika 3.8 Lijevo: ručni mjerač; desno: mjerenje razine podzemne vode u piezometru ručnim mjeračem

HOBOWare software korišten je za pripremu podataka, preuzetih iz memorije automatskih mjerača, za daljnju obradu. Prije učitavanja podataka vodostaja software nudi opciju za unos referentne razine podzemne vode te unos datoteke s mjerenim atmosferskim tlakovima (Slika 3.9). Na taj način automatski može izračunati sve promjene razina vode koje su se događale u razdoblju mjerenja.



Slika 3.9 Unošenje referentne vrijednosti razine vode i odgovarajuće datoteke za izračun promjene razina vode u vremenu


Software nadalje te podatke prikazuje u zadanim intervalima mjerenja u broječanom (tablica) i grafičkom (dijagram) obliku, a ima i opciju uključivanja i isključivanja pojedinih dijelova grafikona radi lakše preglednosti podataka (Slika 3.10). Nudi i mogućnost spremanja grafičkih i tabličnih podataka.



Slika 3.10 Sučelje software-a HOBOWare

Podatci spremljeni u obliku .txt, .csv, ili .xls datoteke dalje su obrađivani u Microsoft Excel-u, software-u koji je sastavni dio Office paketa tvrtke Microsoft. Excel funkcionira kao tablični kalkulator i primjenjuje se za obradu i analizu podataka te za njihov grafički prikaz. Software je jednostavan za korištenje i sastoji se od raznih dodataka koji pomažu pri obavljanju zadataka. Ima pregršt mogućnosti: programiranje pomoću formula, organizacija podataka, kreiranje lista i baza podataka koje se mogu jednostavno naknadno nadograđivati, kreiranje tablica itd. Ima i mogućnost spremanja podataka u raznim oblicima pa je stoga kompatibilan i s mnogim drugim software-ima. U ovome radu Microsoft Excel je korišten za izvođenje statističkih analiza korelacije i regresije.


Statistička analiza kroskorelacije provedena je u otvorenom računalnom kodu VBA (Visual Basic for Application) (Posavec i dr., 2017.). To je aplikacija razvijena za brzu, pouzdanu i objektivnu obradu vremenskih nizova čime je osigurana dosljednost pri izvođenju obrada podataka te primjenjivost na velike setove podataka (Slika 3.11).



Slika 3.11 Sučelje VBA aplikacije (Posavec i dr., 2017.)


## 4. Rezultati mjerenja

Satna mjerenja vodostaja na Jarunu provedena su u razdoblju od 07.04. do 26.05.2022. godine. U tih 50 dana prikupljena su 1174 podataka o promjenama vodostaja. Na slici 4.1 može se vidjeti da je u dva navrata došlo do povećanja razine vode u jezeru, između njih bilo je razdoblje stagnacije vodostaja, a u posljednjih 20 dana zabilježeno je kontinuirano opadanje vodostaja. Temperatura vode je kontinuirano u vremenu rasla što je u skladu s razdobljem u godini iako je ujedno i nadprosječno visoka za ovo razdoblje godine.




Slika 4.1 Grafički prikaz rezultata mjerenja na Jarunu, zelena krivulja predstavlja razinu vode (m), plava krivulja temperaturu (°C), a crne krivulje predstavljaju tlakove (ukupni puna linija, atmosferski crtkana)

Satna mjerenja vodostaja na Savici provedena su u razdoblju od 14.04. do 26.05.2022. godine te su prikupljena 942 podatka o promjenama razine vode. Na slici 4.2 vidljiv je konstantan pad razine vode u jezeru, skoro obrnuto proporcionalan porastu temperature.



Slika 4.2 Grafički prikaz rezultata mjerenja na Savici, zelena krivulja predstavlja razinu vode (m), plava krivulja temperaturu (°C), a crne krivulje predstavljaju tlakove (ukupni puna linija, atmosferski crtkana)


Na slici 4.3 prikazani su nivogrami rijeke Save za period od 07.04. do 26.05.2022. Zbog nedostatka podataka u periodu između 22.04. i 25.04. dobiveni rezultati mjerenja vodostaja na jezerima nisu obrađivani od dana kada se počelo s mjerenjima, već su obrađivani od 25.04. jer niz podataka za obradu mora biti neprekinut kako bi rezultati provedenih analiza u narednom poglavlju bili što točniji.



Slika 4.3 Nivogrami rijeke Save za razdoblje od 07.04. do 26.05.2022. godine

## 5. Interpretacija rezultata i diskusija

Provedene su analize korelacije, regresije i kroskorelacije za dva vremenska niza od 742 podatka prikupljena na jezerima i na hidrološkim postajama na Savi u razdoblju od 25.04. do 26.05. (Slika 5.1). Sava predstavlja nezavisnu varijablu, dok jezera predstavljaju zavisnu varijablu. Opis rezultata slijedi u narednim poglavljima.



Slika 5.1 Nivogrami rijeke Save i Jezera za razdoblje od 25.04. do 26.05.2022. godine

### 5.1. Rezultati korelacijskih analiza

Korelacijom vodostaja rijeke Save izmjerenih na postaji Podsused žičara (šifra 3087, kota nule 119,134 m n.m.) i vodostaja jezera Jarun, dobivena je vrijednost koeficijenta korelacije  $r$  u iznosu od 0,3160. Prema tablici 2.1 vidljivo je da se radi o relativno slaboj korelaciji između Save i jezera Jarun. Odnosno da se s promjenom vodostaja rijeke Save kod postaje Podsused žičara vodostaj u Jarunu značajno ne mijenja.


Korelacijom vodostaja rijeke Save izmjerenih na postaji Zagreb (šifra 3121, kota nule 112,260 m n.m.) i vodostaja Velikog jezera koji pripada sustavu jezera Savica, dobivena je vrijednost

koeficijenta korelacije  $r$  u iznosu od 0,4912. Prema tablici 2.1 vidljivo je da se radi o relativno slaboj korelaciji između Save i jezera Savica. Odnosno da se s promjenom vodostaja rijeke Save kod postaje Zagreb vodostaj u jezerima značajno ne mijenja.

## 5.2. Rezultati regresijskih analiza


Analiza linearne regresije provedena je na istim nizovima podataka prikupljenih s mjernih postaja na Savi te s jezera kao u prethodnom poglavlju. Podatci o vodostaju rijeke Save opisani su na x-osi i oni predstavljaju nezavisnu varijablu. Zavisnu varijablu predstavljaju jezera i njihovi podatci su smješteni na y-osi. Na temelju tih podataka dobivene su jednadžbe pravca koje nam služe za prognozu vodostaja jezera ovisno o budućim promjenama vodostaja na rijeci Savi. Za svaki odnos izračunat je i koeficijent determinacije koji nam služi za procjenu pouzdanosti prognoze kretanja vodostaja prilikom promjene vodostaja Save.

Analizom vodostaja rijeke Save izmjenjenog na postaji Podsused žičara i vodostaja izmjenjenog na jezeru Jarun dobivena je jednadžba  $y = 0,0403x + 107,47$  i koeficijent determinacije  $R^2 = 0,0999$  (Slika 5.2). Prema Tablica 2.2 dobiveni koeficijent determinacije ukazuje na slabu vezu između Save i Jaruna.



Slika 5.2 Rezultati dobiveni obradom podataka metodom linearne regresije Sava (Podsused) / Jarun

Analizom vodostaja rijeke Save izmjerenog na postaji Zagreb i vodostaja izmjerenog na Velikom jezeru na Savici dobivena je jednadžba  $y = 0,0278x + 106,13$  i koeficijent determinacije  $R^2 = 0,2412$  (Slika 5.33). Prema Tablica 2.2. dobiveni koeficijent determinacije ukazuje na slabu vezu između Save i jezera Savica.



*Slika 5.3 Rezultati dobiveni obradom podataka metodom linearne regresije Sava (Zagreb) / Savica*


Iz rezultata dobivenih linearnom regresijom može se zaključiti slično kao i iz rezultata dobivenih korelacijom da jezera Jarun i Savica s rijekom Savom imaju slabu povezanost.

### **5.3. Rezultati kroskorelacijskih analiza**


Metoda kroskorelacije provedena je pomoću VBA koda u Excel-u (Posavec i dr., 2017) te su dobiveni kroskorelogrami. S kroskorelograma možemo očitati na kojem je vremenskom koraku najveća vrijednost koeficijenta kroskorelacije. Taj vremenski korak nam ujedno govori i tzv. vrijeme zakašnjenja reakcije, odnosno u našem slučaju vrijeme potrebno za promjenu vodostaja jezera prilikom promjene vodostaja rijeke Save.

Prvo su izvedeni kroskorelogrami od 740 vremenskih koraka (Lag) kako bi se vidjelo gdje je najveći pozitivni pik na kroskorelogramu (Slika 5.4). Ovisno o poziciji najvećeg pozitivnog pika broj vremenskih koraka je zatim umanjen na 200.

Na korelogramu vremenske serije vodostaja Save (postaja Podsused žičara) te vodostaja jezera Jarun najveći koeficijent kroskorelacije iznosi 0,598 i zabilježen je na 85. vremenskom koraku (Slika 5.5). Iz toga je vidljivo da dolazi do porasta vodostaja jezera Jarun 85 sati nakon porasta vodostaja rijeke Save.




*Slika 5.4 Kroskorelogram Sava (Podsused žičara) / Jarun (lag 740)*



*Slika 5.5 Kroskorelogram Sava (Podsused žičara) / Jarun (lag 200)*

Na korelogramu vremenske serije vodostaja Save (postaja Zagreb) te vodostaja jezera Savica najveći koeficijent kroskorelacije iznosi 0,612, zabilježen je na vremenskom koraku – 410 (Slika 5.6). Rezultat kroskorelacijske analize ukazuje na situaciju u kojoj jezero Savica utječe na vodostaj u rijeci Savi. Na Slika 5.1 je vidljivo da to nije slučaj, stoga se može zaključiti da Veliko jezero na Savici nema vezu s rijekom Savom.



Slika 5.6 Kroskorelogram Sava (Zagreb) / Savica

## 5.4. Diskusija

Jezero Jarun i Sava imaju niske koeficijente korelacije i regresije jer postoji zakašnjenje u reakciji što se pokazalo kroskorelacijskom analizom. S obzirom da je jezero Jarun nekada bilo dio starog Savskog toka, a sada već dugi niz godina nije, zakašnjenje u reakciji može se objasniti tzv. kolmiranjem korita jezera, tj. zamuljivanjem ili zamočvarenjem. Kao i sva jezera koja nemaju konstantnu vezu s površinskim tokovima, jezero Jarun je sklono kolmiranju. U razdobljima izrazito visokih vodostaja dolazi do povratnog djelovanja rijeke Save i prelijevanja vode u jezero Jarun, međutim vodostaji takvih razmjera su sve rjeđi. Tako da je porijeklo zamuljivanja velikom većinom organskog porijekla. Međutim zbog sportskih i ostalih aktivnosti na jezeru ono se povremeno održava čišćenjem dna jezera od mulja, čime se proces zamuljivanja značajno usporava.

Sličnu sudbinu kao Jarun doživjela su i jezera Savica, nastala su na gotovo isti način, međutim jezera su već prošla kroz proces potpunog kolmiranja i njihova veza sa Savom gotovo da ne postoji. To nam potvrđuju i rezultati provedenih analiza. Iako su slični koeficijenti korelacije i determinacije kao i za Jarun, na kroskorelogramu (Slika 5.6) je evidentno da ne postoji veza

između rijeke Save i jezera Savica. To se može vidjeti i na nivogramima (Slika 5.1). Za razliku od Jaruna, dno Savice se ne održava što znači da će se u budućnosti dubina jezera sve više smanjivati, najviše uslijed biogenih procesa kao što su raspadanje živih organizama (riba, školjkaša, ptica itd.) i dijelova biljaka i drveća, koji obitavaju unutar jezera i u njihovoj neposrednoj blizini.

## 6. Zaključak

Utjecaj rijeke Save (nezavisna varijabla) na vodostaj jezera Jarun i Savica (zavisna varijabla) opisan je pomoću statističkih analiza korelacije, linearne regresije i kroskorelacije. Analize su provedene na satnim mjerenjima vodostaja rijeke Save preuzetih za stranica DHMZ-a te na satnim mjerenjima vodostaja jezera provedenim od strane RGN fakulteta za razdoblje od 25.04. do 26.05.2022. godine. Za potrebe mjerenja vodostaja jezera postavljeni su automatski mjerači u plastične cijevi u Jarunu i u Velikom jezeru na jezerima Savica.

Statističkom metodom korelacije dobiveni su koeficijenti korelacije iz kojih se može protumačiti da je veza između Save i jezera Jarun i Savica slaba. Točnije, za odnos vodostaja Save (Podsused žičara) i Jaruna dobiven je koeficijent korelacije 0,3160. Iz odnosa vodostaja Save (Zagreb) i Savice dobiven je koeficijent korelacije 0,4912.

Statističkom metodom linearne regresije dobivena je jednadžba pravca te koeficijent determinacije za oba odnosa. Pravac nam omogućuje prognoziranje vrijednosti vodostaja u jezerima s obzirom na promjenu vodostaja Save, a o vjerojatnosti pouzdanosti prognoze nam govori koeficijent determinacije. Koeficijent determinacije za odnos Sava (Podsused žičara) / Jarun iznosi 0,0999, za odnos Sava (Zagreb) / Savica iznosi 0,2412,. Na temelju izračunatih koeficijenata determinacije može se zaključiti jednako kao i za koeficijent korelacije, da je funkcionalna veza između Save i jezera Jarun i Savica slaba.

Primjenom statističke metode kroskorelacije i iz dobivenih kroskorelograma očitano je na kojem je vremenskom koraku prva najveća pozitivna vrijednost koeficijenta kroskorelacije. Taj vremenski korak nam ujedno govori i tzv. vrijeme zakašnjenja reakcije, odnosno u našem slučaju vrijeme u satima potrebno za promjenu vodostaja jezera prilikom promjene vodostaja rijeke Save. Na kroskorelogramu Sava (Podsused žičara) / Jarun najveći koeficijent kroskorelacije iznosi 0,598 i zabilježen je na 85. vremenskom koraku. Kroskorelogram Sava (Zagreb) / Savica ima najveći koeficijent kroskorelacije 0,612 te je zabilježen na vremenskom koraku – 410. Na pozitivnoj strani kroskorelograma sve su vrijednosti niže što upućuje na zaključak da rijeka Sava nema utjecaj na vodostaj jezera Savica.

Iz dobivenih rezultata vidljivo je da veza između Save i Jaruna postoji te da je zakašnjenje reakcije jezera na promjene vodostaja rijeke Save 85 sati. Za odnos rijeke Save i jezera Savica može se zaključiti da veza ne postoji.

## 7. Literatura

- BAČANI, A. i POSAVEC, K. (2014). Elaborat o zonama zaštite izvorišta grada Zagreba. Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet, Zagreb.
- BASCH, O. (1981): Osnovna geološka karta, M 1:100 000, List Ivanić Grad. Geološki zavod Zagreb, OOUR za geologiju i paleontologiju
- BASCH, O. (1983). Osnovna geološka karta, M 1:100 000, Tumač za list Ivanić-Grad, Beograd.
- DAVIS, J. C. (2002). Statistics and Data Analysis in Geology, Third Edition. John Wiley & Sons Inc., New York. [Correlation Coefficient -- from Wolfram MathWorld](#)
- LDNR, False River Watershed Council, and C.H. Fenstermaker & Associates, L.L.C. (2013). False River; Watershed Study: Discharge Bayou and the Chenal Drainage Network Assessment.
- HORVAT, J. i MIJOČ J. (2012). Osnove statistike. Zagreb: Naklada Ljevak., str. 476.
- MONTGOMERY, D. C. i RUNGER, G. C. (2003.). Applied Statistics and Probability for Engineers, Third Edition. John Wiley & Sons, Inc., New York, 706 p.
- PARLOV, J., KOVAČ, Z.; NAKIĆ, Z. i BAREŠIĆ, J. (2019). Using Water Stable Isotopes for Identifying Groundwater Recharge Sources of the Unconfined Alluvial Zagreb Aquifer (Croatia). *Water* **2019**, 11, 2177.
- POSAVEC, K. (2006). Identifikacija i prognoza minimalnih razina podzemne vode zagrebačkoga aluvijalnog vodonosnika modelima recesijskih krivulja. Doktorska disertacija, RGN fakultet, Zagreb: Arhiv Rudarsko-geološko-naftnog fakulteta. Sveučilište u Zagrebu.
- POSAVEC, K. i ŠKUDAR, S. (2016). Korelacijsko, regresijsko i kros-korelacijsko modeliranje vremenskih podataka u hidrogeologiji. U: 1. Hrvatski znanstveni skup iz geomatematike i nazivlja u geologiji: zbornik recenziranih radova i sažetaka, Zagreb: RGN fakultet, 2016, str. 75-90.
- POSAVEC, K., VUKOJEVIĆ, P., RATKAJ, M. i BEDENIKOVIĆ, T. (2017). Cross-correlation modelling of surface water – Groundwater interaction using the excel spreadsheet application. Rudarsko-geološko-naftni zbornik. 32. 25-32. 10.17794/rgn.2017.1.4.

RATKAJ, M. (2014). Identifikacija utjecaja vodostaja rijeka Save na vodostaj jezera Jarun. Diplomski rad, RGN fakultet, Zagreb.

SAUCIER, R. T. (1994). Geomorphology and Quaternary Geologic History of the Lower Mississippi Valley. Vicksburg, Mississippi: U.S. Army Engineer Waterways Experiment Station.

ŠIKIĆ, K., BASCH, O. i ŠIMUNIĆ, A. (1972): Osnovna geološka karta, M 1:100 000, List Zagreb. Institut za geološka istraživanja, Zagreb

Tetra Tech. (2003): Total Maximum Daily Load for Sediment/Siltation - Moon Lake - Coahoma and Tunica Counties, Mississippi [Final report - September 2003]. Fairfax, VA: Tetra Tech, Inc.

VELIĆ, J. i DURN, G. (1993): Alternating Lacustrine-Marsh Sedimentation and Subaerial Exposure Phases during Quaternary: Prečko, Zagreb, Croatia. Geologia Croatica, vol. 46, no. 1, str. 71-90

VELIĆ, J. i SAFTIĆ, B. (1991): Subsurface Spreading and Facies Characteristics of Middle Pleistocene Deposits between Zaprešić and Samobor. Geološki vjesnik, 44, 69–82.

ŽUGAJ, R. (2000): Hidrologija. RGN fakultet, Zagreb

### **Web izvori:**

BBC. (2013). Standard Grade Bitesize Geography- Processes Forming River Landscapes: Revision, Page 2.

[http://www.bbc.co.uk/bitesize/standard/geography/rivers/river\\_forming/revision/2/](http://www.bbc.co.uk/bitesize/standard/geography/rivers/river_forming/revision/2/) - neaktivna stranica

Hrvatska enciklopedija, mrežno izdanje. Leksikografski zavod Miroslav Krleža, 2021. Meandar. Pristupljeno 18. 3. 2022. <http://www.enciklopedija.hr/Natuknica.aspx?ID=39708>.

<https://slidetodoc.com/9-regresija-i-korelacija-jednodimenzionalna-analiza-istraivanje-jedne/> Pristupljeno 26.04.2022.

<https://www.zgportal.com/o-zagrebu/povijest-zagrebackih-naselja/jarun/> Pristupljeno 26.04.2022.

<https://belizagrebgrad.com.hr/skriveni-zagreb-jezera-koja-se-nalaze-samo-pola-sata-od-centra-a-rijetki-za-njih-znaju/> Pristupljeno 26.04.2022

<https://maps.arcanum.com/en/map/firstsurvey-croatia/?layers=145&bbox=1761271.5603756225%2C5739518.241207327%2C1797636.4765822953%2C5752952.048928446> Pristupljeno 20.06.2022

<https://maps.arcanum.com/en/map/thirdsurvey25000/?layers=osm%2C129&bbox=1759327.9205466672%2C5740016.549668232%2C1795692.83675334%2C5753450.357389351>  
Pristupljeno 20.06.2022