

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

**IDENTIFIKACIJA UTJECAJA PRAGA TE – TO NA PODZEMNE  
VODE NEPOSREDNOG ZAOTALJA**

Diplomski rad

Filip Al Ahmed  
GI - 261

Zagreb, 2017.

## **IDENTIFIKACIJA UTJECAJA PRAGA TE – TO NA PODZEMNE VODE NEPOSREDNOG ZAOTALJA**

Filip Al Ahmed

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

### **SAŽETAK**

U ovom radu identificiran je utjecaj praga TE – TO na podzemne vode neposrednog zaotalja. Analizirani su podaci iz razdoblja od 1. siječnja 1994. do 31. prosinca 2000. godine. Za utvrđivanje veze korištene su statističke metode korelacije, regresije i kroskorelacije. Obrada podataka izvršena je u programu Microsoft Excel, korištenjem funkcije za korelaciju, primjenom odabranih regresijskih modela te namjenskog VBA programa za kroskorelaciju. Metodom korelacije dobiveni su koeficijenti koji ukazuju na pozitivnu korelaciju, odnosno da je porast visine vodostaja praćen porastom razine podzemne vode. Metodom linearne regresije dobiveni su koeficijenti determinacije. U jednom slučaju utvrđeno je kako regresijski model dobro predstavlja mjerene vrijednosti, dok u preostala tri slučaja regresijski model ne predstavlja dobro mjerene vrijednosti. Metodom kroskorelacije dobiveni su koeficijenti korelacije na temelju kojih su određeni vremenski podaci, odnosno zaostajanje jedne varijable za drugom.

Ključne riječi: prag TE – TO, vodostaj, piezometar, korelacija, regresija, kroskorelacija

Diplomski rad sadrži: 34 stranica, 18 slika i 17 referenca

Jezik izvornika: hrvatski

Diplomski rad pohranjen: Knjižnica Rudarsko-geološko-naftnog fakulteta  
Pierottijeva 6, Zagreb

Voditelj: Dr. sc. Kristijan Posavec, redoviti profesor RGNF

Ocjenjivači: Dr. sc. Kristijan Posavec, redoviti profesor RGNF  
Dr. sc. Andrea Bačani, redoviti profesor RGNF  
Dr. sc. Jelena Parlov, docent RGNF

Datum obrane: 19. prosinca 2017.

**IDENTIFICATION OF IMPACT OF RIVER DAM NEAR POWERPLANT  
ZAGREB ON SURROUNDING GROUNDWATER LEVEL**

Filip Al Ahmed

Thesis Completed: University of Zagreb  
Faculty of Mining, Geology and Petroleum Engineering  
Department of Geology and Geological Engineering  
Pierottijeva 6, 10000 Zagreb

**ABSTRACT**

In this thesis, the impact of the river dam near Thermal powerplant Zagreb on surrounding groundwater level had been identified. Data ranging from January 1<sup>st</sup> 1994 to December 31<sup>st</sup> 2000 was analysed. In order to determine the data relation, statistical methods correlation, regression and cross correlation had been used. Data analysis had been done in Microsoft Excel Software using correlation command, applying chosen regression models and with appropriate VBA code. Using correlation methods, correlation coefficients were determined. They show positive correlation, thus confirming water level growth followed by groundwater level growth. Using linear regression, coefficients of determination were determined. It had been shown with one result that the regression model represents valued measures well. In the rest of the cases, it had been shown that regression model represents valued measures poorly. Cross correlation method enabled calculating correlation coefficients which determined the time displacement, showing one variable lag in relation to another variable.

Keywords: river dam, water level, piezometer, correlation, regression, cross correlation,

Thesis contains: 34 pages, 18 pictures and 17 references

Origin language: Croatian

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

Supervisor: Full Professor Kristijan Posavec, PhD

Reviewers: Full Professor Kristijan Posavec, PhD  
Full Professor Andrea Bačani, PhD  
Assistant Professor Jelena Parlov, PhD

Date of defence: 19 December 2017

## SADRŽAJ

1. UVOD .....	1
2. ISTRAŽIVANO PODRUČJE .....	4
2.1. ZAGREBAČKI VODONOSNIK .....	4
2.2. GEOLOŠKE ZNAČAJKE VODONOSNIKA .....	5
2.3. HIDROGEOLOŠKE ZNAČAJKE VODONOSNIKA.....	6
2.4. PRAG TERMOELEKTRANA – TOPLANA (TE – TO) ZAGREB .....	7
3. METODE OBRADJE PODATAKA .....	11
3.1. KORELACIJA .....	12
3.2. REGRESIJA .....	13
3.3. KROSKORELACIJA .....	15
4. MJERNE POSTAJE I KORIŠTENI PODACI .....	16
5. REZULTATI OBRADJE PODATAKA .....	18
5.1. REZULTATI OBRADJE PODATAKA METODOM KORELACIJE .....	18
5.2. REZULTATI OBRADJE PODATAKA METODOM LINEARNE REGRESIJE..	22
5.3. REZULTATI OBRADJE PODATAKA METODOM KROSKORELACIJE.....	27
6. ZAKLJUČAK.....	31
7. LITERATURA .....	33

## POPIS SLIKA

Slika 2.1. Zagrebački vodonosnik s crpilištima i njegova lokacija u Republici Hrvatskoj (preuzeto iz Posavec, 2006) .....	4
Slika 2.2. Geološka karta (preuzeto iz Bačani i Šparica, 2001).....	5
Slika 2.3. Shematski profil zagrebačkog vodonosnog sustava (preuzeto iz Posavec, 2006)..	6
.....	6
Slika 2.4. Prag kod Termoelektrane – toplane (TE -TO) Zagreb (preuzeto s <a href="https://www.google.hr/maps/">https://www.google.hr/maps/</a> , 24. studenoga 2017.) .....	8
Slika 2.5. Karakteristični poprečni presjeci nadograđenog primarnog i sekundarnog praga te njihovo stanje prije nadogradnje (preuzeto iz Biondić, 1995).....	10
Slika 4.1. Prikaz položaja postaje TE – TO dovodni kanal i piezometara 892, 5225, 888 i 298.....	16
Slika 5.1. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 892 s koeficijentom korelacije .....	18
Slika 5.2. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 5225 s koeficijentom korelacije .....	19
Slika 5.3. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 888 s koeficijentom korelacije .....	20
Slika 5.4. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 298 s koeficijentom korelacije .....	21
Slika 5.5. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 892 s jednadžbom pravca i koeficijentom determinacije.....	23
Slika 5.6. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 5225 s jednadžbom pravca i koeficijentom determinacije.....	24
Slika 5.7. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 888 s jednadžbom pravca i koeficijentom determinacije.....	25
Slika 5.8. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 298 s jednadžbom pravca i koeficijentom determinacije.....	26
Slika 5.9. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 892 .....	27
Slika 5.10. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 5225.....	28

Slika 5.11. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 888	
.....	29
Slika 5.12. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 298	
.....	30

## 1. UVOD

U diplomskom radu identificiran je utjecaj praga TE – TO na podzemne vode neposrednog zaobalja primjenom statističkih metoda korelacije, regresije i kroskorelacije.

Statistička metoda korelacije, odnosno s njome povezani koeficijent korelacije  $r_{(x,y)}$ , mjeri jačinu odnosa između dvije varijable i izražava njihov linearni odnos. Pozitivna korelacija, u kojoj varijable  $x$  i  $y$  imaju jaku pozitivnu korelaciju, rezultira vrijednostima  $r$  bliskima  $+1$ . Negativna varijabla rezultira vrijednostima  $r$  bliskima  $-1$ . Koeficijenti korelacije veći od  $0,8$  generalno ukazuju na jaku korelaciju, dok koeficijenti korelacije manji od  $0,5$  generalno ukazuju na slabu korelaciju.

Analiza regresije koristi se kada se želi analizirati setove podataka, odnosno mjerenja koja su uređena u prostoru (npr. promjena sadržaja vlage u tlu s promjenom dubine) ili vremenu (npr. promjene razine podzemne vode u vremenu), kao i kada želimo analizirati varijable koje su u međusobnoj funkcionalnoj ovisnosti (npr. promjena razine podzemne vode u vodonosniku u ovisnosti o promjenama vodostaja rijeke). Varijabla koja se istražuje naziva se zavisnom varijablom i označuje s  $Y$ , dok se druga varijabla naziva nezavisnom i označuje s  $X$ , te se koristi kako bi se objasnio njezin utjecaj ili veza sa zavisnom varijablom. Potrebno je i definirati koeficijent determinacije  $R^2$  koji je prikaz reprezentativnosti regresijskog modela.

Kroskorelacija definira mjeru sličnosti dvije varijable, odnosno dva niza podataka. Ovom metodom želi se prikazati stupanj do kojeg se dva niza podataka koreliraju s obzirom na zaostajanje jedne varijable u odnosu na drugu. Jačina veze između dva vremenska niza definira se koeficijentom korelacije,  $r$ , koji se računa za svako uzastopno zaostajanje, a najveći određeni koeficijent korelacije određuje vremensko zaostajanje između dva vremenska niza.

Tako Ratkaj (2014) u svom radu identificira utjecaj rijeke Save na vodostaj jezera Jarun koristeći statističke metode korelacije, regresije i kroskorelacije. Koristio je podatke s 3 piezometra u neposrednoj blizini jezera Jarun, te podatke s hidrološke postaje Sava Zagreb, u razdoblju od 9. svibnja 2014. do 12. lipnja 2014. godine. Metodom korelacije dobio je visoke koeficijente korelacije koji su ukazali na vrlo dobru povezanost rijeke Save i jezera Jarun. Također je zaključio da vrijednosti koeficijenata korelacije opadaju što je piezometar udaljeniji od Save. Metodom regresije dobio je polinomne regresijske modele koji su mu omogućili prognoziranje vrijednosti razine podzemnih voda u piezometrima, uz

poznavanje vrijednosti visina vodostaja Save. Metodom kroskorelacije zaključio je da do reakcije porasta vodostaja jezera Jarun dolazi 1-2 dana nakon porasta visine vodostaja na Savi.

Škudar (2016) je u svom radu analizirao hidrauličku povezanost aluvijalnih i proluvijalnih naslaga zagrebačkog vodonosnika metodama korelacije, regresije i kroskorelacije. Koristio je podatke s 3 piezometra na području aluvija zagrebačkog vodonosnika i 2 piezometra koji se nalaze u proluvijalnim naslagama rubnog dijela vodonosnika. Podaci su analizirani za razdoblje od 1. kolovoza do 25. kolovoza 2015. godine. Dobiveni koeficijenti korelacije ukazali su na dobru hidrauličku povezanost aluvijalnih i proluvijalnih naslaga. Zaključio je da se korištenjem linearnih regresijskih modela mogu prognozirati razine podzemne vode u provijalnom dijelu vodonosnika pomoću razina podzemne vode u aluvijalnom dijelu, ali s niskom pouzdanošću. Metodom kroskorelacije odredio je vrijeme kašnjenja reakcije promjene razine podzemne vode u odnosu na promjenu razine podzemne vode u aluvijalnom dijelu vodonosnika.

Bedeniković (2017) je u svom radu identificirala hidrauličku vezu rijeke Odre s podzemnim vodama istočnog dijela zagrebačkog vodonosnika. U njezinom radu korišteni su podaci s piezometra B-153 i hidrološke postaje Donja Poljana iz razdoblja od 1. siječnja 2004 godine do 31. kolovoza 2012. godine. Metodom korelacije dobiven je koeficijent korelacije koji ukazuje na slabiju povezanost vodostaja Odre i razina podzemne vode zagrebačkog vodonosnika. Također je dobiven nizak koeficijent determinacije koji je ukazao na nisku pouzdanost prognoziranja vodostaja rijeke Odre na temelju razine podzemne vode. Kroskorelacija je omogućila dobivanje vremena zakašnjenja promjene vodostaja rijeke Odre na promjenu razine podzemne vode. U ovom radu na isti način je identificiran utjecaj praga kod Termoelektrane – toplane Zagreb (TE – TO) na razine podzemne vode neposrednog zaobalja. Utjecaj je identificiran obradom podataka o visini vodostaja rijeke Save na postaji TE – TO dovodni kanal 2092 i mjerenjima razine podzemne vode u 2 piezometra na lijevoj i 2 piezometra na desnoj obali Save, nizvodno od praga TE – TO. Piezometri 892 i 888 nalaze se u neposrednoj blizini praga, na lijevoj, odnosno desnoj obali Save, dok je piezometar 5225 nizvodno od praga na lijevoj obali, a piezometar 298 nizvodno na desnoj obali Save. Provedene su metode korelacije, regresije i kroskorelacije. U sva četiri slučaja dobiven je pozitivan smjer korelacije, što označuje pozitivnu korelaciju, odnosno da je kod sva četiri piezometra zabilježeno da je porast visine vodostaja rijeke Save praćen porastom razine podzemne vode, odnosno da padom




visine vodostaja rijeke Save pada i razina podzemne vode. Metodom linearne regresije dobiveni su regresijski modeli koji opisuju funkcionalnu ovisnost razine podzemne vode o vodostajima Save i pripadni koeficijenti determinacije. Samo je obradom podataka vodostaja Save u paru s piezometrom 892 zabilježen koeficijent determinacije  $R^2$  koji ukazuje na to da linija, odnosno regresijski model dobro predstavlja mjerene vrijednosti. Kod ostala tri piezometra dobiveni su regresijski modeli čiji koeficijenti determinacije ukazuju na lošiju funkcionalnu ovisnost analiziranih varijabla. Kroskorelacijskom analizom dobiveni su kroskorelogrami te koeficijenti korelacije. Traženi su najveći koeficijenti korelacije  $r$  koji određuju vremensko zaostajanje između dva vremenska niza. Obradom podataka sa sva 4 piezometra utvrđeno je kako su najveće razine podzemne vode zabilježene 1 do 3 dana nakon što je zabilježen najveći vodostaj Save na postaji TE – TO dovodni kanal 2092. Cilj rada bio je identifikacija utjecaja praga TE – TO na podzemne vode neposrednog zaobalja. Obradom navedenih podataka te korištenjem statističkih metoda postignut je cilj te je taj utjecaj identificiran.

## 2. ISTRAŽIVANO PODRUČJE

### 2.1. ZAGREBAČKI VODONOSNIK

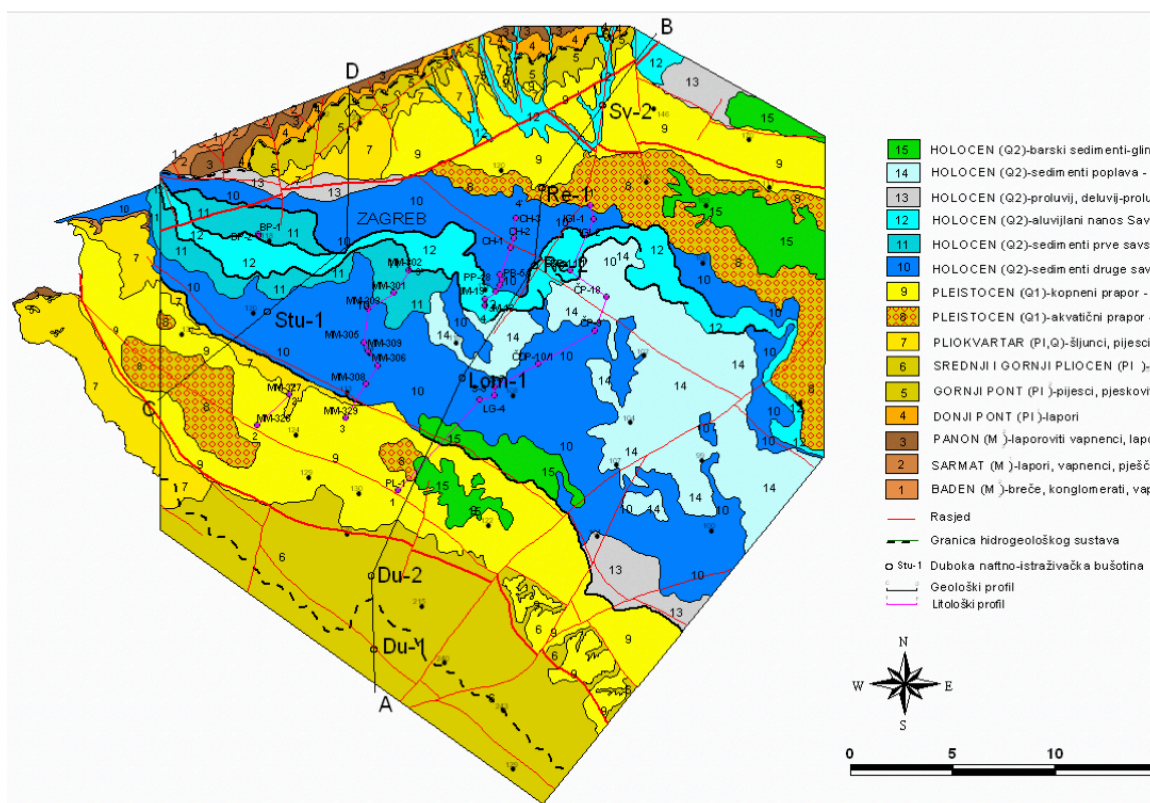
Zagrebački vodonosnik (slika 2.1.) nalazi se na području Grada Zagreba, duljine je oko 30 km i prosječne širine od 10 do 15 km, odnosno prostire se površinom od oko 350 km<sup>2</sup> (Bačani i Posavec, 2009). Prostiranje vodonosnika je smjera sjeverozapad – jugoistok, a definirano je položajem rijeke Save. Granicu vodonosnika na sjeveru određuje planinski dio kojeg čini Medvednica, a na jugu brežuljkasto područje Vukomeričkih Gorica. Vodonosnik je, zahvaljujući položaju rijeke Save, podijeljen na lijevo i desno zaobalje (Bačani i Posavec, 2014). S lijeve strane zaobalja nalaze se crpilišta Žitnjak, Sašnjak i Petruševac, odnosno Mala Mlaka, Zapruđe i Velika Gorica s desne strane zaobalja. Crpilišta se koriste za opskrbu oko 850.000 stanovnika. Za vrijeme duljih sušnih razdoblja za vodoopskrbu stanovništva se, osim navedenih vodocrpilišta, uključuju i manja vodocrpilišta koja su inače isključena iz vodoopskrbe. Također, uz uključivanje dodatnih vodocrpilišta, kao dodatne mjere opskrbe radi povećane potrebe stanovništva za pitkom vodom povećavaju se crpljenja na vodocrpilištima Petruševac i Velika Gorica (Posavec, 2006).



Slika 2.1. Zagrebački vodonosnik s crpilištima i njegova lokacija u Republici Hrvatskoj (preuzeto iz Posavec, 2006)


## 2.2. GEOLOŠKE ZNAČAJKE VODONOSNIKA

Zagrebački vodonosnik čine srednje i gornje pleistocenske, te holocenske naslage (slika 2.2.). To je područje tijekom srednjeg i gornjeg pleistocena bilo jezersko i močvarno, a okolno gorje (Medvednica, Marijagorička Brda i Žumberačko gorje) bilo je podložno intenzivnoj eroziji i denudaciji. Trošeni materijal nošen je potocima i taložen u jezerima i močvarama (Velić i Saftić, 1991). Početkom holocena, klimatski i tektonski procesi omogućili su prodor rijeke Save čime je započeo transport materijala s područja Alpa (Velić i Durn, 1993). Transport materijala bio je promjenjivog intenziteta zbog čestih klimatskih promjena. Za vrijeme toplih i vlažnih razdoblja bio je intenzivan, dok se njegova intenzivnost smanjivala za vrijeme suhih i hladnih razdoblja. Osim klimatskih promjena, tektonski pokreti također su utjecali na procese taloženja (Velić et al., 1999). Posljedica takvih uvjeta taloženja je izrazita heterogenost i anizotropija vodonosnika te neujednačena debljina naslaga.



Slika 2.2. Geološka karta (preuzeto iz Bačani i Šparica, 2001)

U profilu se razlikuju dva vodonosna sloja: prvi vodonosni sloj s dominantno aluvijalnim naslagama rijeke Save i drugi vodonosni sloj s dominantno jezersko barskim naslagama (slika 2.3.). Prvi vodonosni sloj sastoji se pretežito od srednje do fino zrnatog šljunka i pijeska s proslojcima gline i praha, s debljinom od 5 m na zapadu do 50 m na istoku. Drugi vodonosni sloj čine pretežito naslage šljunka i pijeska s lećama silta i gline, s debljinom od 20 m na zapadu do 60 m na istoku. U krovini vodonosnog sloja nalaze se pijesci ili siltozne gline debljine oko 3 m (negdje i manje), dok se u podini nalaze sivo – plave i sivo – zelene gline, različite plastičnosti, u kojoj se javljaju vapnene konkreције, a registrirana je i pojava treseta (Urumović i Mihelčić, 2000).



Slika 2.3. Shematski profil zagrebačkog vodonosnog sustava (preuzeto iz Posavec, 2006)

### 2.3. HIDROGEOLOŠKE ZNAČAJKE VODONOSNIKA

Zagrebački vodonosnik je otvoreni vodonosnik što znači da mu gornju granicu saturacije čini vodna ploha pod atmosferskim tlakom. Rubne granice u hidrauličkom smislu čine nepropusna granica na sjeveru, granica dotjecanja na zapadu, granica dotjecanja na jugu, te granica otjecanja na istoku.

Regionalni smjer toka podzemne vode je od zapada prema istoku/jugoistoku, odnosno paralelno toku rijeke Save. Smjerovi toka podzemne vode u značajnoj mjeri ovise o vodostajima rijeke Save. Posavec (2006) analizom karata ekvipotencijala zaključuje da za vrijeme visokih vodostaja Save rijeka napaja vodonosnik na cijelom području toka kroz zagrebački vodonosnik, dok za vrijeme niskih vodostaja rijeka drenira vodonosnik na

nekim dijelovima toka što nepovoljno utječe na crpne količine, posebno u vrijeme sušnih razdoblja.


Napajanje vodonosnika se osim (1) infiltracijom iz rijeke Save, odvija i (2) infiltracijom oborina, (3) infiltracijom iz propusne vodoopskrbne i kanalizacijske mreže, (4) dotjecanjem po zapadnoj granici iz susjednog samoborskog vodonosnika, te (5) dotjecanjem po južnoj granici vodonosnika s područja Vukomeričkih Gorica. Analize kretanja razina podzemne vode u razdoblju od 1950. godine, tj. od kada mjerenja traju pa do danas pokazale su da su razine podzemne vode od 1950. godine opadale sve do sredine 1993. godine, u prosjeku 1 – 2 m svakih 10 godina na području cijelog vodonosnika. Početkom devedesetih godina prošloga stoljeća trend opadanja razina nakratko je zaustavljen izgradnjom praga na rijeci Savi kod termoelektrane – toplane (TE – TO) Zagreb i to na području uzvodno od praga, no ubrzo nakon izgradnje trend opadanja je nastavljen sličnim intenzitetom. Razlozi opadanja razine podzemne vode mogu se najvećim dijelom potražiti u (1) izgradnji nasipa za obranu od poplava duž rijeke Save koje je najvećim dijelom uzrokovano izgradnjom akumulacija na Savi uzvodno Zagreba, regulacijom pritoka i šljunčarenjem iz korita Save (Bonacci i Trninić, 1986), a za posljedicu ima snižavanje vodostaja rijeke Save; te u (3) sve većoj eksploataciji podzemne vode za potrebe vodoopskrbe Grada Zagreba. Ukupna crpna količina na zagrebačkim se crpilištima od 1983. godine, kada je iznosila oko 3300 l/s, povećala do danas na oko 4700 l/s, dok je 1993. iznosila oko 4000 l/s, što znači da se kontinuirano povećavala za oko 700 l/s svakih 10 godina. To povećanje crpne količine nije povezano isključivo s ubrzanim razvojem grada i povećanjem broja stanovnika, nego i sa sve starijom vodoopskrbnom mrežom čiji procijenjeni gubici prema podacima Vodoopskrbe i odvodnje d.o.o. iznose više od 40% (Posavec, 2006).

#### 2.4. PRAG TERMOELEKTRANA – TOPLANA (TE – TO) ZAGREB

Na razinu podzemne vode u velikoj mjeri utječe i prag kod Termoelektrane – toplane Zagreb (slika 2.4.) koji se nalazi 2,5 km uzvodno od crpilišta Petruševac. Prosječni pad vodostaja Save na području Zagreba iznosi 0,4 m/km, dok na dijelu toka od hidrološke stanice TE – TO dovodni kanal do TE – TO donja voda, čija je udaljenost oko 620 m, iznosi u prosjeku 5 – 8 m/km. Ovakva razlika vodostaja rijeke Save na maloj udaljenosti



uzrokuje oko 20 puta veći prosječni pad vodostaja rijeke Save nego na ostalim dijelovima toka, a što se uvelike odražava i na razine podzemne vode (Posavec, 2006).



Slika 2.4. Prag kod Termoelektrane – toplane (TE -TO) Zagreb (preuzeto s <https://www.google.hr/maps/>, 24. studenoga 2017.)

TE – TO Zagreb puštena je u pogon 1962. godine s dva bloka ukupne snage 33,2 MW. Za osiguranje potrebnih količina rashladne vode, na lijevoj obali Save je izgrađena crpna stanica s dovodnim kanalom (TE – TO dovodni kanal). 1979. godine izgrađen je novi blok snage 120 MW koji je zahtijevao znatno veće količine rashladne vode.

Problemi vezani za opskrbu TE – TO Zagreb rashladnom vodom pojavili su se prvi puta krajem 1981. godine kada je na presjeku zahvata zabilježen ekstremno niski vodostaj. Pojave niskih vodostaja, a time i obustave rada postrojenja postajale su sve učestalije pa se moralo pristupiti sanaciji problema. Prijedlozi su bili sljedeći: (1) izgradnja podvodnog regulacijskog praga u koritu rijeke Save, (2) izgradnja pomoćne crpne stanice uz postojeću i (3) izgradnja precrpne stanice. Provedene su analize rezultati kojih su pokazali da je najpovoljnije rješenje izvedba podvodnog regulacijskog praga koji bi trebao imati dvije osnovne namjene: (1) formiranje vodne razine potrebne za nesmetani rad crpki i (2) stabilizacija dna riječnog korita uzvodno od pregradnog presjeka (Biondić, 1995).


Prvi prag od gabiona izgrađen je na lokaciji 87 m nizvodno od postojeće crpne stanice s prosječnom kotom krune od 106,1 m n.m. Bio je sastavljen od četiri glavna dijela: madraca kao zaštite riječnog dna, tijela od gabiona, obaloutvrda na lijevoj i desnoj obali (kombinacija madraca i krupnokamenog nabačaja) i zaštite uzvodnog i nizvodnog pokosa lomljenim kamenom.

Postupnim urušavanjem primarnog praga ponovno se ugrozila opskrba grada toplinskom energijom. Stoga se 1986. godine pristupilo izgradnji novog praga, 5,6 m uzvodno od osi starog praga. Konstrukcija ovog praga se sastojala od: tijela (dva reda betonskih blokova veličine 1,4 m x 1,4 m x 1,4 m), zaštite slapišta (red betonskih blokova veličine 0,8 m x 0,8 m x 0,8 m), uzvodne zaštite dna (gabioni), te obaloutvrda na lijevoj i desnoj obali.

Tijekom eksploatacije sekundarnog praga došlo je do znatnijeg slijeganja krune pa ostvareni uspor nije osiguravao opskrbu TE – TO Zagreb dovoljnim količinama rashladne vode. Prag je 1989. godine ponovno morao biti saniran. Sanacija je predviđala nadvišenje krune primarnog praga formiranjem nasipa od kamenih blokova kote 106,75 m n.m. i izgradnju sekundarnog praga nizvodno od primarnog čija je namjena bila zaštita slapišta primarnog praga od daljnje erozije (Biondić, 1995).

U razdoblju od 1989. do 1992. godine primarni i sekundarni prag doživjeli su znatnije promjene projektiranih konstruktivnih elemenata, iako opskrba rashladnom vodom TE – TO Zagreb nije bila ugrožena. Došlo je do sniženja krune primarnog praga i smanjenja funkcionalnosti obzirom na stvaranje projektiranog uspora. Istovremeno je došlo i do oštećenja sekundarnog praga što je uzrokovalo nestabilnost korita nizvodno od primarnog praga. Ovakva situacija dovela je do poremećaja i smanjenja stabilnosti nizvodnog pokosa primarnog praga te njegovog postupnog rušenja. Krajem 1990. godine pojavile su se ekstremno visoke vode koje su prouzročile štete na desnoj obali nizvodno od osi primarnog praga. Prilikom povlačenja vode došlo je do aktiviranja rukavca Save što je prouzročilo djelomično rušenje obaloutvrde na desnoj obali. Razina vode je onemogućila pristup mjestu oštećenja zbog čega su ona postajala sve veća. Ova oštećenja su uzrokovala promjenu uvjeta tečenja pa je na desnom dijelu primarnog praga došlo do sniženja kote krune za 80 cm. Niža kota imala je za posljedicu koncentraciju toka na desnom dijelu korita, odnosno neravnomjerno tečenje preko krune. Time su na tom dijelu povećane vučne sile, čime je erozija krune postala veća od one predviđene projektom. Bilo je neophodno pristupiti novoj sanaciji.

Nova sanacija dovršena je krajem lipnja 1993. godine, a obuhvatila je ublažavanje nizvodnog pokosa primarnog praga zbog smanjenja brzine vode u slapištu, povišenje krune primarnog praga na kotu 107 m n.m., te sanaciju sekundarnog praga i obaloutvrda. Karakteristični poprečni presjeci nadograđenog primarnog i sekundarnog praga, te njihovo stanje prije nadogradnje prikazani su na slici 2.5. Nakon završetka sanacije izvršeno je hidrografsko snimanje karakterističnih poprečnih presjeka Save na području pragova. Na osnovi rezultata snimanja zabilježeno stanje uzeto je kao nulto stanje koje će biti osnova kod daljnjeg monitoringa efekata praga (Biondić, 1995).



Slika 2.5. Karakteristični poprečni presjeci nadograđenog primarnog i sekundarnog praga te njihovo stanje prije nadogradnje (preuzeto iz Biondić, 1995)



### 3. METODE OBRADJE PODATAKA

Za identifikaciju utjecaja praga TE – TO na neposredno zaobalje podaci su obrađivani sljedećim metodama: korelacijom, regresijom i kroskorelacijom. Primjena korelacijskih, regresijskih i kroskorelacijskih modela česta je u analizi vremenskih nizova podataka u hidrogeologiji, odnosno hidrologiji. Neki od slučajeva primjena modela su primjene na vremenske nizove razina podzemne vode, vodostaja rijeka, jezera ili potoka, ili pak istjecanja na izvorima.

Da bi objasnili statističke parametre koji opisuju pouzdanost korelacije i regresije, potrebno je također objasniti i statističke parametre poput aritmetičke sredine (eng. *Mean*), varijance (eng. *Variance*), standardne devijacije (eng. *Standard deviation*) i kovarijance (eng. *Covariance*); i termine kao što su populacija (eng. *Population*) i uzorak (eng. *Sample*), a koji su usko povezani s metodama. Termini populacija i uzorak predstavljaju dva važna koncepta u statistici. Populacija se sastoji od dobro definiranog seta (konačnog ili beskonačnog) elemenata, dok je uzorak podskup elemenata uzet iz populacije (Davis, 2002).

Jedna od najčešćih ocjena nekog seta populacije ili uzorka je njegova srednja vrijednost. Postoji nekoliko različitih ocjena srednje vrijednosti koje se u praksi koriste, mod (eng. *Mod*) koji predstavlja vrijednost koje se pojavljuje s najvećom učestalošću, medijan (eng. *Median*) koji predstavlja vrijednost od koje je pola podataka u setu veće, a pola manje, te aritmetička sredina koja je definirana kao suma svih podataka u setu podijeljena s brojem podataka.

Sljedeća od najčešćih ocjena, odnosno karakteristika populacije ili uzorka je širenje ili disperzija oko aritmetičke sredine. Općenito se koriste samo dvije vrijednosti za ocjenu širenja ili disperzije oko aritmetičke sredine. Jedna je varijanca, a druga je korijen iz varijance, a koji se naziva standardna devijacija. Varijancu možemo promatrati kao srednje kvadratno odstupanje svih podataka od aritmetičke sredine populacije. Da bi se opisalo širenje podataka oko aritmetičke sredine u jedinicama mjernih podataka, koristi se statistički parametar standardna devijacija. Male vrijednosti standardne devijacije ukazuju na činjenicu da su mjerni podaci gusto grupirani oko aritmetičke sredine, dok velike vrijednosti ukazuju da su mjerni podaci široko raspršeni oko aritmetičke sredine.

Aritmetička sredina, varijanca i standardna devijacija statistički su parametri kojima opisujemo set podataka jedne varijable, odnosno njezinu srednju ili centralnu

vrijednost (aritmetička sredina), kao i širenje ili disperziju seta podataka te varijable oko aritmetičke sredine (varijanca i standardna devijacija).

Potrebno je i objasniti statistički termin kovarijanca, a koja predstavlja mjeru širenja ili disperzije dvije varijable oko zajedničke srednje vrijednosti, odnosno njihove aritmetičke sredine. Kao što varijanca opisuje širenje ili disperziju oko aritmetičke sredine jedne varijable, kovarijanca opisuje širenje ili disperziju oko zajedničke aritmetičke sredine dvije varijable (Posavec i Škudar, 2016).

### 3.1. KORELACIJA

Korelacija, odnosno s njome povezani koeficijent korelacije,  $r_{(x,y)}$ , mjeri jačinu odnosa između dvije varijable i izražava njihov linearni odnos. Koeficijent korelacije,  $r_{(x,y)}$ , zapravo predstavlja omjer kovarijance dvije varijable,  $cov_{xy}$  i umnoška njihovih standardnih devijacija,  $s_x$  i  $s_y$  (Davis, 2002):

$$r_{xy} = \frac{cov_{xy}}{s_x s_y}. \quad (3.1.)$$

Jedinica u kojima se izražava kovarijanca je umnožak jedinica dviju varijabli, a to je i jedinica umnoška standardnih devijacija u nazivniku. Stoga se sve jedinice krata pa je koeficijent korelacije,  $r_{xy}$ , bezdimenzijska veličina. S obzirom da kovarijanca dviju varijabli može biti jednaka umnošku standardnih devijacija varijabli, no ne može biti veća, koeficijent korelacije ima raspon od +1 do -1.

Pozitivna korelacija, u kojoj varijable  $x$  i  $y$  imaju jaku pozitivnu korelaciju, rezultira vrijednostima  $r$  bliskima +1. Vrijednost  $r$  jednaka +1 označava savršenu pozitivnu spregu dviju varijabli. Pozitivne vrijednosti ukazuju na odnos varijabli  $x$  i  $y$  u kojem kod porasta vrijednosti varijable  $x$ , također rastu i vrijednosti varijable  $y$ .

Negativna korelacija, u kojoj varijable  $x$  i  $y$  imaju jaku negativnu korelaciju, rezultiraju vrijednostima  $r$  bliskima -1. Vrijednost  $r$  jednaka -1 označava savršenu negativnu spregu dvije varijable. Negativne vrijednosti ukazuju na odnos varijabli  $x$  i  $y$  u kojem kod porasta vrijednosti varijable  $x$ , vrijednosti varijable  $y$  opadaju.

Ako je korelacija vrlo slaba ili ako je nema, vrijednosti  $r$  bliske su nuli. Koeficijenti korelacije veći od 0,8 generalno ukazuju na jaku korelaciju, dok koeficijenti korelacije manji od 0,5 generalno ukazuju na slabu korelaciju

(<http://mathbits.com/MathBits/TISection/Statistics2/correlation.htm>, preuzeto 16. studenoga 2017.).

### 3.2. REGRESIJA

Analiza regresije koristi se kada se želi analizirati setove podataka, odnosno mjerenja koja su uređena u prostoru (npr. promjena sadržaja vlage u tlu s promjenom dubine) ili vremenu (npr. promjena razine podzemne vode u vremenu), kao i kada želimo analizirati varijable koje su u međusobnoj funkcionalnoj ovisnosti (npr. promjena razine podzemne vode u vodonosniku u ovisnosti o promjenama vodostaja rijeke ili pak infiltraciji oborina) (Posavec i Škudar, 2016).

Varijabla koja se istražuje naziva se zavisnom varijablom i označuje s  $Y$ , dok se druga varijabla naziva nezavisnom i označuje s  $X$ . Nezavisna varijabla se koristi kako bi se objasnio njezin utjecaj ili veza sa zavisnom varijablom.

Utjecaj nezavisne varijable na vrijednost zavisne može se matematički izraziti regresijskim modelom:

$$Y = f(X_1, X_2, \dots, X_k) + \varepsilon \quad (3.2.)$$

Iako se regresijskim modelom objašnjava funkcionalna zavisnost varijabla, on također sadrži i stohastičku komponentu  $\varepsilon$ , koja predoduje nesistematske utjecaje na zavisnu varijablu.

Model koji izražava vezu između zavisne i jedne nezavisne varijable nazivamo jednostavnim regresijskim modelom. Ako model izražava vezu između zavisne i dviju ili više nezavisnih varijabli, nazivamo ga modelom višestruke regresije. Regresijski modeli mogu izražavati linearne i nelinearne veze između promatranih varijabli.

Osnovni regresijski model je model linearne regresije:

$$y = ax + b \quad (3.3.)$$

gdje su:  $y$  – najvjerojatniji rezultat varijable  $y$  za određeni rezultat varijable  $x$ ,  $a$  – koeficijent nagiba, a  $b$  – odsječak na osi  $y$ .

Ovakvim modelom pokušavamo objasniti veličinu  $y$  preko samo jedne veličine  $x$ , dok se svi ostali utjecaji zanemaruju. Takav pristup je u praksi opravdan jer ionako nismo u mogućnosti uvrstiti sve utjecaje na  $y$ .

Polazna točka u regresijskoj analizi je dijagram raspršenja koji služi za grafički prikaz točke u koordinatnom sustavu. One predstavljaju niz uređenih parova rezultata mjerenja. Na os  $x$  nanose se vrijednosti varijable  $x$ , a na os  $y$  vrijednosti varijable  $y$ . Na temelju rasporeda tih točaka možemo uočiti postojanje veze među varijablama, kao i njezin oblik, smjer i jačinu. Na dijagramu se crta linija koja najbolje opisuje te točke i ona se naziva regresijski model, i oblika je jednadžbe (3.2.) (Škudar, 2016).

Da bi odredili mjeru podešenosti linije, tj. regresijskog modela, odnosno mjeru korisnosti modela, potrebno je definirati statistički parametar koji nazivamo koeficijentom determinacije  $R^2$  (eng. *Coefficient of determination*). Vrijednosti koeficijenta determinacije kreću se od 0 do 1. Ako linija, odnosno regresijski model dobro reprezentira mjerene vrijednosti,  $R^2$  će biti blizak jedinici, dok će u slučaju loše reprezentativnosti biti blizak nuli. Dakle, osnovna funkcija koeficijenta determinacije je prikaz reprezentativnosti regresijskog modela. Vrijednost koeficijenta  $R^2$  daje nam postotak mjerenih podataka koji su najbliže podešenoj liniji, tj. regresijskom modelu. Ako je npr.  $R^2 = 85\%$ , 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 15% ukupnog odstupanja ostaje neobjašnjeno.

Jedna od korisnih relacija je ta da drugi korijen iz koeficijenta determinacije  $R^2$  predstavlja višestruki koeficijent korelacije,  $R$ ;  $R = \sqrt{R^2}$ , a koji je algebarski ekvivalentan koeficijentu korelacije  $r$  (Davis, 2002).

### 3.3. KROSKORELACIJA

Kroskorelacija definira mjeru sličnosti dvije varijable, odnosno dva niza podataka. Ovom metodom želi se prikazati stupanj do kojeg se dva niza podataka koreliraju s obzirom na zaostajanje jedne varijable u odnosu na drugu. Zbog toga je ovu metodu najprikladnije koristiti za usporedbu vremenski ovisnih nizova podataka. Usporedbom vremenskih nizova podataka dobivaju se podaci o jakosti veze dva niza, kao i međusobni vremenski zaostatak, odnosno razmak između varijabla u poziciji njihove maksimalne usklađenosti (Davis, 2002).

Jačina veze između dva vremenska niza definira se koeficijentom korelacije,  $r$ , koji se računa za svako uzastopno zaostajanje, a najveći određeni koeficijent korelacije određuje vremensko zaostajanje između dva vremenska niza. Koeficijenti se grafički prikazuju pomoću kroskorelograma. Kroskorelogram se crta tako da se u koordinatnom sustavu na os  $x$  nanose vremenski koraci, a na os  $y$  koeficijenti korelacije. Na kroskorelogramu uočavamo za koji smo vremenski korak dobili najveći koeficijent korelacije te bilježimo njegov iznos. Vremenski korak s najvećim koeficijentom korelacije je vrijeme zakašnjenja reakcije kada su vremenske reakcije u najvećem skladu (Škudar, 2016).

U kroskorelacijskoj analizi mjerenja vremenskih nizova podataka trebaju međusobno vremenski odgovarati, odnosno mjerenja trebaju biti obavljena u isto vrijeme. U ovom slučaju to je isti dan jer je učestalost mjerenja 1 dan.

#### 4. MJERNE POSTAJE I KORIŠTENI PODACI

Visina vodostaja rijeke Save mjerena je na postaji TE – TO dovodni kanal oznake 2092, koja se nalazi uzvodno od pragova. Korišteni su podaci iz razdoblja od 1994. do 2000. godine, a mjerenja su provedena od strane Hidroing d.o.o. Za potrebe ovog rada također su korišteni podaci o razinama podzemne vode mjerene na 4 piezometara s oznakama: 892, 5225, 888 i 298. Mjerenja na piezometrima obavlja Državni hidrometeorološki zavod (DHMZ). Piezometri 892 i 5225 nalaze se na lijevoj obali Save, kao i postaja TE – TO dovodni kanal 2092, dok se piezometri 888 i 298 nalaze na desnoj obali Save (slika 4.1.).



Slika 4.1. Prikaz položaja postaje TE – TO dovodni kanal i piezometara 892, 5225, 888 i 298

Za potrebe ovog rada korišteni su podaci o vodostajima rijeke Save mjereni na postaji TE – TO dovodni kanal na dnevnoj razini, od 1. siječnja 1994. godine do 31. prosinca 2000. godine. Kako su razine podzemne vode u piezometrima također mjerene od siječnja 1994. godine do kraja prosinca 2000. godine, ali u prosjeku svaka 3 do 4 dana, te

podatke bilo je potrebno interpolirati metodom linearne interpolacije. Postupkom linearne interpolacije dobiveni su podaci o razinama podzemne vode na dnevnoj razini te je nakon toga bilo moguće provesti statističke metode korelacije, regresije i linearne interpolacije. Ukoliko je razmak između dva mjerenja razine podzemne vode bio veći od 4 dana, podaci nisu korišteni u analizi.

Za statističku obradu podataka korišteni su alati programa Microsoft Excel. Koeficijent korelacije  $r$  dobiven je upotrebom naredbe CORREL. Funkciji se definiraju vrijednosti varijable  $x$  i  $y$ , a ona sama izračunava vrijednost koeficijenta korelacije  $r$ .

Koeficijent determinacije  $R^2$  dobiven je upotrebom alata za analizu podataka. Odabirom alata i zadavanjem naredbe *Regression*, te zadavanjem zavisne, odnosno nezavisne varijable dobiveni su koeficijent determinacije  $R^2$ , ali i koeficijent korelacije  $r$ , koji je poslužio kao provjera točnosti ranije provedene funkcije CORREL.


Metoda kroskorelacije provedena je pomoću namjenski izrađenog računalnog VBA programa (Posavec et al., 2017). Sučelje je jednostavno te lako za korištenje, prvenstveno je potrebno raspolagati s dva vremenska niza podataka koji se unose u program. Ova metoda je vrlo pouzdana i točna, te omogućuje primjenu na velike setove podataka, kao što je i ovdje bio primjer.

## 5. REZULTATI OBRADJE PODATAKA

### 5.1. REZULTATI OBRADJE PODATAKA METODOM KORELACIJE

Ovom metodom korelirane su vrijednosti vodostaja rijeke Save na postaji TE – TO dovodni kanal 2092 i vrijednosti razina podzemne vode na piezometrima 892, 5225, 888 i 298. Rezultati obrade kod sva 4 piezometra pokazuju povezanost između razine vodostaja rijeke Save i razina podzemne vode u piezometrima. Smjer korelacije je pozitivan u sva 4 slučaja što pokazuje da porast vodostaja rijeke Save prati porast razina podzemne vode u piezometrima.

Slika 5.1. prikazuje graf kojim su prikazani rezultati korelacije visina vodostaja Save izmjenjenih na postaji TE – TO 2092 i razina podzemne vode izmjenjenih na piezometru 892, i koeficijent korelacije  $r$ .




Slika 5.1. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 892 s koeficijentom korelacije



Koeficijent korelacije  $r$  u ovom slučaju je 0,79 što ukazuje na jaku korelaciju, odnosno da je porast vodostaja rijeke Save zabilježen na postaji TE – TO 2092 praćen porastom razine podzemne vode zabilježenim na piezometru 892.


Na slici 5.2. prikazan je graf s rezultatima korelacije visina vodostaja Save izmjerenih na postaji TE – TO 2092 i razina podzemne vode izmjerenih na piezometru 5225.



Slika 5.2. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 5225 s koeficijentom korelacije

U ovom slučaju, korelacijom visina vodostaja rijeke Save na postaji TE – TO 2092 i razina podzemne vode mjerene na piezometru 5225 dobiven je koeficijent korelacije  $r=0,68$ , koji ukazuje na dobru korelaciju, s pozitivnim smjerom.


Na slici 5.3. prikazan je graf s rezultatima korelacije visina vodostaja Save izmjerenih na postaji TE – TO 2092 i razina podzemne vode izmjerenih na piezometru 888.



Slika 5.3. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 888 s koeficijentom korelacije

U ovom slučaju izračunat je koeficijent korelacije  $r$  koji iznosi 0,58 te ukazuje na slabiju korelaciju, ali pozitivan smjer pa porastom razine vodostaja rijeke Save na mjernoj postaji TE – TO 2092 raste razina podzemne vode mjerena na piezometru 888.

Na slici 5.4. prikazani su rezultati korelacije visina vodostaja Save izmjerenih na postaji TE – TO 2092 i razina podzemne vode izmjerenih na piezometru 298.



Slika 5.4. Prikaz rezultata korelacije visine vodostaja Save TE – TO 2092 i RPV piezometra 298 s koeficijentom korelacije

U slučaju korelacije podataka razina podzemne vode piezometra 298 i visina vodostaja rijeke Save izmjerenih na postaji TE – TO 2092 dobiven je koeficijent korelacije  $r=0,55$ , što ukazuje na slabiju korelaciju, ali isto kao u prethodnom slučaju, pozitivan smjer korelacije.

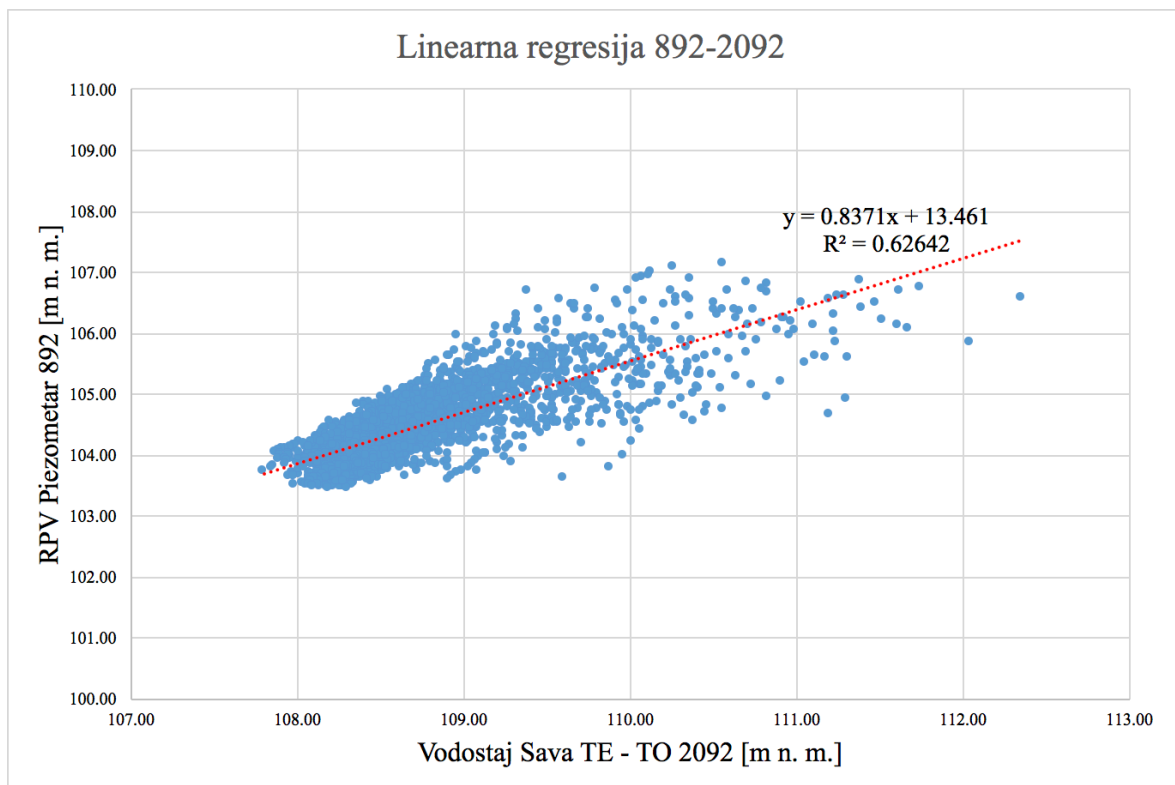
## 5.2. REZULTATI OBRADJE PODATAKA METODOM LINEARNE REGRESIJE

Metodom linearne regresije obrađeni su podaci o razinama podzemne vode izmjenjenima na 4 piezometra: 892, 5225, 888 i 298; i podaci o visinama vodostaja rijeke Save izmjenjenima na mjernoj postaji TE – TO dovodni kanal 2092.

Podaci su obrađeni u programu Microsoft Excel, korištenjem naredbe *Regression* smještene unutar alata za analizu podataka. Redom su u paru obrađeni podaci iz jednog piezometra i postaje TE – TO dovodni kanal 2092. Na osi x su nanese vrijednosti visina vodostaja rijeke Save izmjerenih na postaji TE – TO dovodni kanal 2092, i te vrijednosti predstavljaju nezavisne varijable. Na osi y nanese su vrijednosti mjerenja razina podzemne vode iz piezometara, i te vrijednosti predstavljaju zavisnu varijablu.


Zadavanjem naredbe dobiveni su koeficijenti determinacije  $R^2$  i jednadžbe pravaca. Pomoću jednadžbe pravca možemo izračunati razinu vode u piezometru ako znamo razinu vodostaja na mjernoj stanici. Koeficijent determinacije  $R^2$  određuje pouzdanost prognoziranja zavisne varijable pomoću dobivenog regresijskog modela.

Analizom podataka o razinama podzemne vode u piezometru 892 i podataka o visinama vodostaja Save na postaji TE – TO dovodni kanal dobiven je sljedeći graf (slika 5.5.), s jednadžbom pravca  $y=0,8371x + 13,461$  i koeficijentom determinacije  $R^2=0,62642$ . Ovakav koeficijent determinacije ukazuje na to da regresijski model dobro opisuje mjerene vrijednosti.




Slika 5.5. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 892 s jednadžbom pravca i koeficijentom determinacije

Analizom podataka o razinama podzemne vode u piezometru 5225 i podataka o visinama vodostaja Save na postaji TE – TO dovodni kanal dobiven je sljedeći graf (slika 5.6.), s jednadžbom pravca  $y=0,8457x + 10,384$  i koeficijentom determinacije  $R^2=0,46463$ . Ovakav koeficijent determinacije ukazuje na to da regresijski model ne opisuje dobro mjerene vrijednosti, odnosno, da je rasap podataka oko linije trenda prevelik.




Slika 5.6. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 5225 s jednadžbom pravca i koeficijentom determinacije

Analizom podataka o razinama podzemne vode u piezometru 888 i podataka o visinama vodostaja Save na postaji TE – TO dovodni kanal dobiven je sljedeći graf (slika 5.7.), s jednadžbom pravca  $y=0,779x + 19,689$  i koeficijentom determinacije  $R^2=0,3408$ . Ovakav koeficijent determinacije ukazuje na to da regresijski model ne opisuje dobro mjerene vrijednosti, odnosno da je rasap podataka oko linije trenda prevelik.



Slika 5.7. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 888 s jednadžbom pravca i koeficijentom determinacije

Analizom podataka o razinama podzemne vode u piezometru 298 i podataka o visinama vodostaja Save na postaji TE – TO dovodni kanal dobiven je sljedeći graf (slika 5.8.), s jednadžbom pravca  $y=0,6541x + 32,63$  i koeficijentom determinacije  $R^2=0,30764$ . Ovakav koeficijent determinacije ukazuje na to da regresijski model ne opisuje dobro mjerene vrijednosti, odnosno da je rasap podataka oko linije trenda prevelik.




Slika 5.8. Prikaz rezultata linearne regresije vodostaja Save TE – TO 2092 i piezometra 298 s jednadžbom pravca i koeficijentom determinacije



### 5.3. REZULTATI OBRADJE PODATAKA METODOM KROSKORELACIJE


Metoda kroskorelacije obavljena je pomoću namjenski izrađenog računalnog VBA programa (Posavec et al., 2017). Za svaki piezometar pojedinačno, koji predstavlja jedan vremenski niz podataka, u paru s vremenskim nizom podataka o visini vodostaja, metoda je obavljena u 50 vremenskih koraka. Metodom su izračunati koeficijenti korelacije  $r$ , odnosno tražen je najveći koeficijent korelacije koji određuje vremensko zaostajanje između dva vremenska niza.

Slika 5.9. prikazuje kroskorelogram dva vremenska niza, vodostaja Save izmjerenih na postaji TE – TO dovodni kanal 2092, i razina podzemne vode izmjerenih na piezometru 892. Najveći koeficijent korelacije  $r$  iznosi 0,813 te je zabilježen na vremenskom koraku 1, što znači da je najveća razina podzemne vode na piezometru 892 zabilježena unutar jednog dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Da bi preciznije utvrdili koliko je sati potrebno za reakciju, trebali bi na raspolaganju imati satna mjerenja.




Slika 5.9. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 892

Slika 5.10. prikazuje kroskorelogram vremenskih nizova podataka s vodostajima Save izmjerenih na postaji TE – TO dovodni kanal 2092, i razinama podzemne vode izmjerenih na piezometru 5225. Najveći koeficijent korelacije  $r$  iznosi 0,738 te je zabilježen na vremenskom koraku 2, što znači da je najveća razina podzemne vode na piezometru 5225 zabilježena unutar dva dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Da bi preciznije utvrdili koliko je sati potrebno za reakciju, trebali bi na raspolaganju imati satna mjerenja.



Slika 5.10. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 5225


Na slici 5.11. prikazan je kroskorelogram vremenskih nizova podataka s vodostajima Save izmjerenih na postaji TE – TO dovodni kanal 2092, i razinama podzemne vode izmjerenih na piezometru 888. Najveći koeficijent korelacije  $r$  iznosi 0,609 te je zabilježen na vremenskom koraku 2, što znači da je najveća razina podzemne vode na piezometru 888 zabilježena unutar dva dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Da bi preciznije utvrdili koliko je sati potrebno za reakciju, trebali bi na raspolaganju imati satna mjerenja.



Slika 5.11. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 888

Na slici 5.12. prikazan je kroskorelogram vremenskih nizova podataka s vodostajima Save izmjerenih na postaji TE – TO dovodni kanal 2092, i razinama podzemne vode izmjerenih na piezometru 298. Najveći koeficijent korelacije  $r$  iznosi 0,595 te je zabilježen na vremenskom koraku 3, što znači da je najveća razina podzemne vode na piezometru 298 zabilježena unutar tri dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Da bi preciznije utvrdili koliko je sati potrebno za reakciju, trebali bi na raspolaganju imati satna mjerenja.

U ovom slučaju primijećeno je najveće odstupanje. To se može objasniti velikim vremenskim razmacima u mjerenjima razine podzemne vode u ovom piezometru. Samim time, pouzdanost podataka se znatno smanjuje.



Slika 5.12. Kroskorelogram vodostaja Save TE – TO dovodni kanal 2092 i piezometra 298

## 6. ZAKLJUČAK

Identifikacija utjecaja praga TE – TO na podzemne vode neposrednog zaobalja određena je primjenom metoda korelacije, linearne regresije i kroskorelacije.

Metodom korelacije dobiveni su sljedeći rezultati; korelacijom piezometra 892 s mjernom postajom TE – TO dovodni kanal 2092 dobiven je koeficijent korelacije  $r=0,79$  što ukazuje na jaku pozitivnu korelaciju, odnosno da je porast visine vodostaja rijeke Save izmjerenog na postaji TE – TO dovodni kanal praćen porastom razine podzemne vode izmjerenog na piezometru 892. Korelacija piezometra 5225 s mjernom postajom TE – TO dovodni kanal 2092 rezultirala je koeficijentom korelacije  $r=0,68$ , koji ukazuje na dobru pozitivnu korelaciju, odnosno i na ovoj postaji je zabilježeno da porast razine podzemne vode u piezometru prati porast visine vodostaja rijeke Save zabilježen na postaji TE – TO dovodni kanal 2092. Korelacijom piezometra 888 s mjernom postajom TE – TO dovodni kanal 2092 dobiven je koeficijent korelacije 0,58 koji ukazuje na slabiju korelaciju. Unatoč tome, korelacija je pozitivna te se nastavio trend porasta razine podzemne vode koji prati porast visine vodostaja rijeke Save na mjernoj postaji TE – TO dovodni kanal 2092. Posljednji setovi podataka obrađeni ovom metodom su izmjereni na piezometru 298 i mjernoj postaji TE – TO dovodni kanal 2092. Metodom je dobiven koeficijent korelacije 0,55 koji ukazuje na slabiju korelaciju, ali pozitivan smjer korelacije.

Nadalje je provedena metoda linearne regresije. Analizom podataka razina podzemne vode u piezometru 892 i visina vodostaja Save mjerenih na postaji TE – TO dovodni kanal 2092 dobiveni su jednadžba pravca  $y=0,8371x + 13,461$  i koeficijent determinacije  $R^2=0,62642$ . Ovakav koeficijent determinacije ukazuje da regresijski model dobro opisuje mjerene vrijednosti. Sljedeći setovi podataka bili su oni s piezometra 5225 i mjerne postaje TE – TO dovodni kanal 2092. Dobiveni su jednadžba pravca  $y=0,8457x + 10,384$  i koeficijent determinacije  $R^2=0,46463$ . Ovakav koeficijent determinacije ukazuje da regresijski model ne opisuje dobro mjerene vrijednosti, odnosno, da je rasap podataka oko linije trenda prevelik. Analizom podataka s piezometra 888 i mjerne postaje TE – TO dovodni kanal 2092 dobiveni su sljedeći rezultati:  $y=0,779x + 19,689$  i koeficijent determinacije  $R^2=0,3408$ . I u ovom slučaju vrijednost koeficijenta determinacije ukazuje na to da regresijski model ne opisuje dobro mjerene vrijednosti, odnosno da je rasap podataka oko linije trenda prevelik. Posljednji u nizu setova podataka analiziranih metodom linearne regresije su oni s razinama podzemnih voda u piezometru 298 i

visinama vodostaja Save na mjernoj postaji TE – TO dovodni kanal 2092. Dobiveni su jednadžba pravca  $y=0,6541x + 32,63$  i koeficijent determinacije  $R^2=0,30764$ . Kao u prethodna dva slučaja, i ovdje je zaključeno da regresijski model ne opisuje dobro mjerene vrijednosti, odnosno i u ovom slučaju je rasap podataka oko linije trenda prevelik.

Na kraju je prema istom principu provedena metoda kroskorelacije. Kod prvog para seta podataka dobiven je maksimalni koeficijent korelacije  $r=0,813$ , zabilježen na vremenskom koraku 1, što znači da je najveća razina podzemne vode na piezometru 892 zabilježena unutar jednog dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Kroskorelacijom sljedećeg para seta podataka dobiven je koeficijent korelacije  $r=0,738$  koji je zabilježen na vremenskom koraku 2, što znači da je najveća razina podzemne vode na piezometru 5225 zabilježena unutar dva dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Kroskorelacijom vremenskih nizova podataka s vodostajima Save izmjerenih na postaji TE – TO dovodni kanal 2092, i razinama podzemne vode izmjerenih na piezometru 888 dobiven je najveći koeficijent korelacije  $r=0,609$  koji je zabilježen na vremenskom koraku 2, što također znači da je najveća razina podzemne vode na piezometru 888 zabilježena unutar dva dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Na posljednjem vremenskom nizu podataka dobiven je maksimalni koeficijent korelacije  $r=0,595$ , zabilježen na vremenskom koraku 3, što znači da je najveća razina podzemne vode na piezometru 5225 također zabilježena unutar tri dana nakon što je zabilježen najviši vodostaj Save na postaji TE – TO dovodni kanal 2092. Ovakvo odstupanje prisutno je vjerojatno zbog velikog vremenskog razmaka između određenih mjerenja razine podzemne vode na ovom piezometru. Da bi preciznije utvrdili koliko je sati potrebno za reakciju, trebali bi na raspolaganju imati satna mjerenja.

Promatranjem svih rezultata primijećena je bolja povezanost visine vodostaja na postaji s piezometrima na lijevoj obali Save. To je moguće objasniti značajnijim prihranjivanjem piezometara podzemnom vodom na lijevoj obali Save u odnosu na piezometre na desnoj obali. S pretpostavkom da su podaci ispravni, moguće je i da je komunikacija izraženija s lijevom obalom zbog crpljenja na vodocrpilištu Petruševac koje stvara konus depresije. Također, može se uočiti utjecaj udaljenosti piezometara u odnosu na postaju TE – TO dovodni kanal 2092. Tako je zaključeno da se vrijednosti izračunatih koeficijenata smanjuju na lijevoj, odnosno desnoj obali Save povećanjem udaljenosti piezometara od mjerne postaje.

## 7. LITERATURA

- Bačani, A. i Posavec, K. (2009): Elaborat zaštitnih zona vodocrpilišta Velika Gorica. Zagreb: Rudarsko–geološko–naftni fakultet.
- Bačani, A i Posavec, K. (2014): Elaborat o zonama zaštite izvorišta Grada Zagreba. Zagreb: Rudarsko-geološko-naftni fakultet.
- Bačani, A. i ŠPARICA, M. (2001): Geology of the Zagreb aquifer system. 9<sup>th</sup> international Congress of the geological society of Greece. (26<sup>th</sup>-28<sup>th</sup> September 2001). Proceedings, vol XXXIV, No. 5, 1973-1979, Athens.
- Bedeniković, T. (2017): Identifikacija hidrauličke veze rijeke Odre i podzemnih voda istočnog dijela zagrebačkog vodonosnika: diplomski rad. Zagreb: Rudarsko-geološko-naftni fakultet.
- Biondić, D. (1995): Morfološke prognoze korita Save: magistarski rad. Zagreb: Građevinski fakultet.
- Davis, J.C. (2002): Statistics and Data Analysis in Geology, Third Edition. John Wiley & Sons Inc., New York.
- Posavec, K. (2006): identifikacija i prognoza minimalnih razina podzemne vode zagrebačkog aluvijalnog vodonosnika modelima recesijskih krivulja: doktorska disertacija. Zagreb: Rudarsko-geološko-naftni fakultet.
- Posavec, K. i Škudar, S. (2016): Korelacijsko, regresijsko i kros-korelacijsko modeliranje vremenskih podataka u hidrogeologiji: 1. Hrvatski znanstveni skup iz geomatematike i nazivlja u geologiji zbornik recenziranih radova i sažetaka. Zagreb: Rudarsko-geološko-naftni fakultet, str 75-90.
- Posavec, K., Vukojević, P., Ratkaj, M. i Bedeniković, T. (2017): Cross-correlation Modelling of Surface Water – Groundwater Interaction Using Excel Spreadsheet Application, Rudarsko-geološko-naftni zbornik, 32, 1, 25-32.
- Ratkaj, M. (2014): Identifikacija utjecaja vodostaja rijeke Save na vodostaj jezera Jarun: diplomski rad. Zagreb: Rudarsko-geološko-naftni fakultet.
- Škudar, S. (2016): Hidraulička povezanost aluvijalnih i proluvijalnih naslaga zagrebačkog vodonosnika: diplomski rad. Zagreb: Rudarsko-geološko-naftni fakultet.
- Urumović, K. i Mihelčić, D. (2000): Podzemne vode savskog vodonosnika. Hidrologija i vodni resursi Save u novim uvjetima: zbornik radova. Slavonski brod: okrugli stol.

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, p. 71-90.

Velić, J. i Saftić, B. (1991): Subsurface Spreading and Facies Characteristics od Middle Pleistocene Deposits between Zaprešić and Samobor. *Geološki vjesnik*, vol. 44, p. 69-82.

Velić, J, Saftić, B, i Malvić, J. (1999): Lithologic Composition and Stratigraphy of Quaternary Sediments in the Area of the “Jakuševac“ Waste Depository (Zagreb, Northern Croatia). *Geologia Croatica*, vol. 52, no. 2, p. 119-130.

<https://www.google.hr/maps/>, pristup internet stranici 24. studenoga 2017. godine.

<http://mathbits.com/MathBits/TISection/Statistics2/correlation.htm>, pristup internet stranici 16. studenoga 2017. godine