Identifikacija hidrauličke veze rijeke Odre i podzemnih voda istočnog dijela zagrebačkog vodonosnika

Bedeniković, Tea

Master's thesis / Diplomski rad

2017

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://urn.nsk.hr/urn:nbn:hr:169:070965

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

Faculty of Mining, Geology and Petroleum Engineering Repository, University of Zagreb







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

IDENTIFIKACIJA HIDRAULIČKE VEZE RIJEKE ODRE I PODZEMNIH VODA ISTOČNOG DIJELA ZAGREBAČKOG VODONOSNIKA

Diplomski rad

Tea Bedeniković

GI-239

Zagreb, 2017.

Zahvaljujem....

Mentoru izv. prof. dr. sc. Kristijanu Posavcu na predloženoj temi, strpljenju i trudu tijekom izrade diplomskog rada i gospodinu Zoranu Čavloviću, voditelju Centra obrane od poplava iz Hrvatskih voda.

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

Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet

Diplomski rad

IDENTIFIKACIJA HIDRAULIČKE VEZE RIJEKE ODRE I PODZEMNIH VODA ISTOČNOG DIJELA ZAGREBAČKOG VODONOSNIKA

Tea Bedeniković

Diplomski rad izrađen: Sveučilište u Zagrebu
Rudarsko-geološko-naftni fakultet
Zavod za geologiju i geološko inženjerstvo
Pierottijeva 6, 10000 Zagreb

SAŽETAK

U ovom diplomskom radu je identificirana hidraulička veza rijeke Odre s podzemnim vodama istočnog dijela zagrebačkog vodonosnika. U analizama su korišteni podaci iz piezometra B-153 i hidrološke postaje Donja Poljana u razdoblju od 1.1.2004. do 31.8.2012. godine. Kako bi se utvrdila njihova veza, korištene su tri statističke metode: korelacija, regresija i kroskorelacija. Rezultati obrade prikazani su u obliku koeficijenata, dijagrama i korelograma u programu Microsoft Excel. Metodom korelacije dobiven je koeficijent korelacije koji pokazuje slabiju povezanost vodostaja Odre i razina podzemne vode zagrebačkog vodonosnika. Metodom regresije dobiven je nizak koeficijent determinacije koji ukazuje na nisku pouzdanost prognoziranja vodostaja rijeke Odre na temelju razine podzemne vode. Metodom kroskorelacije dobiveno je vrijeme zakašnjenja promjene vodostaja rijeke Odre na promjene razine podzemne vode.

Ključne riječi: rijeka Odra, zagrebački vodonosnik, korelacija, regresija, kroskorelacija, vodostaj
Diplomski rad sadrži: 25 stranica, 12 slika i 18 referenci
Jezik izvornika: hrvatski
Diplomski rad pohranjen: Knjižnica Rudarsko-geološko-naftnog fakulteta

Mentor: Izv. prof. dr. sc. Kristijan Posavec

Ocjenjivači: Izv. prof. dr. sc. Kristijan Posavec
Prof. dr. sc. Andrea Bačani
Doc. dr. sc. Željko Duić

Datum obrane: 17. ožujka 2017.

University of Zagreb
Faculty of Mining, Geology and Petroleum Engineering

Master's Thesis

IDENTIFICATION OF HYDRAULIC CONNECTIONS RIVER ODRA AND GROUNDWATER EASTERN PART OF ZAGREB AQUIFER

Tea Bedeniković

Thesis completed in: University of Zagreb
Faculty of Mining, Geology and Petroleum Engineering
Department of Geology and Geological Engineering
Pierottijeva 6, 10 000 Zagreb

ABSTRACT

In this thesis the hydraulic influence between water level of Odra river and groundwater level of eastern part of Zagreb aquifer was determined. The analysis used data from piezometers B-153 and hydrological station Donja Poljana in the period from 1.1.2004. to 31.8.2012. In order to determine their relationship, three statistical methods were used: correlation method, regression method and cross correlation method. Data results are presented in the form of coefficient, diagram and correlogram in Microsoft Excel. The correlation method obtained correlation coefficient which shows weaker connection betwen water level of Odra river and grounwater levels of Zagreb aquifer. The regression method obtained low coefficient of determination indicating low reliability of groundwater level data used to forecast water level data of Odra river. The cross correlation method determined lag time between water level of Odra river and groundwater level of Zagreb aquifer.

Keywords: river Odra, Zagreb aquifer, correlation, regression, cross correlation, water level
Thesis contains: 25 pages, 12 figures and 18references
Original in: Croatian
Thesis deposited in: Library of Faculty of Mining, Geology and Petroleum Engineering

Supervisor: Associate Professor Kristijan Posavec, PhD

Reviewers: Associate Professor Kristijan Posavec, PhD
Full Professor Andrea Bačani, PhD
Assistant Professor Željko Duić, PhD

Date of defense: March 17th, 2017

Sadržaj

1. UVOD 1
2. OPIS ISTRAŽIVANOG PODRUČJA 3
2.1 Lokacija istraživanog područja 3
2.2 Geologija 5
2.3 Hidrogeologija 7
2.4 Sifon Odra 9
3. MJERNA POSTAJA I KORIŠTENI PODACI 11
4. METODE OBRADE PODATAKA 14
4.1 Korelacija 14
4.2 Regresija 15
4.3 Kroskorelacija 17
5. REZULTATI OBRADE PODATAKA 18
5.1 Rezultati obrade podataka metodom korelacije 18
5.2 Rezultati obrade podataka metodom linearne regresije 19
5.3 Rezultati obrade podataka metodom kroskorelacije 20
6. DISKUSIJA 22
7. ZAKLJUČAK 23
8. LITERATURA 24

Popis slika

Slika 2-1. Prostorni položaj zagrebačkog vodonosnika (Bačani, 2015). 5
Slika 2-2. Geološka karta područja samoborskog i zagrebačkog vodonosnika. OGK List Zagreb, M 1:100 000 (Šikić i dr., 1972), OGK List Ivanić Grad M 1:100 000 (Basch, 1981), (preuzeto iz Kapuralić, 2013). 6
Slika 2-3. Shematski profil zagrebačkog vodonosnog sustava (Posavec, 2006). 8
Slika 2-4. Sifon Sava-Odra 10
Slika 2-5. Kanal Sava-Odra 10
Slika 3-1. Položaj mjerne stanice Donja Poljana i piezometra B-153 11
Slika 3-2. i 3-3. Vodokazne letve u naselju Čička Poljana 12
Slika 3-4. Snimka zaslona alata za kroskorelacijsku analizu (Posavec i Škudar, 2016). 13
Slika 5-1. Graf koji prikazuje rezultat dobiven metodom korelacije 18
Slika 5-2. Rezultati obrade podataka metodom linearne regresije RPV/Odra 19
Slika 5-3. Kroskorelogram 21

1. UVOD

U ovom radu identificiran je utjecaj rijeke Odre na podzemne vode istočnog dijela zagrebačkog vodonosnika. Pri obradi podataka korišteni su podaci Državnog hidrometeorološkog zavoda o vodostajima rijeke Odre izmjereni na hidrološkoj postaji Donja Poljana te podaci o razinama podzemne vode izmjereni u piezometru B-153 koji se nalazi u blizini hidrološke postaje Donja Poljana, u razdoblju od 1.1.2004. do 31.8.2012. Za identifikaciju utjecaja korištene su tri statističke metode: korelacija, regresija i kroskorelacija.

Korelacija je metoda kojom se može utvrditi jačina veze između vodonosnih sustava i njihovih rubnih uvjeta, a koja ukazuje na dominantnost i utjecaj pojedinog rubnog uvjeta kao što su primjerice oscilacije razina podzemne vode u vodonosnom sustavu. Metodom regresije može se odrediti funkcionalna ovisnost pojedinog rubnog uvjeta i događaja u sustavu, npr. infiltracije iz oborina (nezavisna varijabla) koja predstavlja rubni uvjet i razina podzemne vode (zavisna varijabla) koje predstavljaju događaje u sustavu. Metodom kroskorelacije utvrđuje se brzina interakcije odnosno samo vrijeme prijenosa tlaka podzemnom vodom (Posavec i Škudar, 2016.).

U pregledu literature nisu evidentirani slični radovi za područje rijeke Odre, no postoje radovi koji obrađuju iste statističke metode na drugim područjima.

Tako Vukojević (2010) u svom radu koristi metode korelacije, regresije i kroskorelacije kako bi identificirao utjecaje vodostaja rijeka Dunava i Drave na vodostaje jezera Sakadaš u razdoblju od 2002 do 2005. Dobiveni rezultati metodom korelacije ukazuju na vrlo visoku povezanost između navedenih vodostaja rijeka i jezera, tj. da porastom vodostaja rijeka dolazi do porasta vodostaja jezera. Metodom regresije utvrđena je vrlo dobra mogućnost prognoziranja vodostaja jezera i vodostaja rijeka. Metodom kroskorelacije dobiveni su odgovarajući korelogrami i koeficijenti kroskorelacije kojima je ustanovljeno vremensko zaostajanje promjene razine jezera Sakadaš uzrokovano promjenama razina rijeka Dunava i Drave.

Ratkaj (2014) koristi navedene metode kako bi identificirao utjecaj rijeke Save na jezero Jarun. Dobivene su različite vrijednosti koeficijenta korelacije ovisno o udaljenosti rijeke Save od sva 3 piezometra koji su smješteni u blizini jezera.

Točnije, vrijednost koeficijenta korelacije opada što je piezometar udaljeniji od rijeke Save. Metodom regresije dobivene su jednadžbe pravca za svaki od ispitivanih parova podataka, te koeficijenti determinacije. Jednadžbe pravca nam omogućuju prognoziranje razine podzemnih voda u piezometrima uz uvjet da znamo vrijednost vodostaja rijeke Save, a koeficijent determinacije nam ukazuje na točnost prognoziranih podataka. Metodom kroskorelacije određeno je vrijeme potrebno da dođe do promjene razine podzemne vode u piezometrima kada se promijeni vodostaj rijeke Save.

U ovom radu je metodom korelacije dobiven koeficijent korelacije koji ukazuje na stupanj povezanosti vodostaja rijeka Odre i razina podzemne vode izmjerene u piezometru. Metodom linearne regresije dobiveni su odgovarajući dijagrami, te jednadžbe pravaca kojima je ustanovljena linearna veza između vodostaja i razina podzemne vode. Metodom kroskorelacije utvrđeno je vrijeme reakcije promjene vodostaja rijeke Odre na promjenu razine podzemne vode istočnog zagrebačkog vodonosnika.

2. OPIS ISTRAŽIVANOG PODRUČJA

2.1 Lokacija istraživanog područja

Rijeka Odra je lijevi pritok rijeke Kupe koja u dužini od 45 km teče kroz Turopolje i Odransko polje. Izvorište rijeke Odre nije točno definirano. Prije melioracijskih zahvata izvorištem se smatrala rijeka Lomnica koja izvire ispod Vukomeričkih Gorica.

Danas se izvorištem rijeke smatra područje između Donjeg Podotočja i Čičke Poljane gdje se spaja više lokalnih potoka Kosnica, Ribnica i Siget u jedan tok. Ti su potoci neaktivni tijekom sušnih razdoblja pa je i količina vode u rijeci tada znatno manja. Sam tok rijeke Odre prekinut je odteretnim kanalom Sava-Odra već na šestom kilometru od mjesta njenog nastanka. Njene se vode u Čičkoj Poljani, kod sifona Odra, skreću u melioracijski kanal a djelomično se propuštaju u kanal koji se spaja s odteretnim kanalom Sava-Odra kod mjesta Veleševec. Južno od odteretnog kanala tok rijeke je gotovo netaknut, sve do ušća u rijeku Kupu (https://hr.wikipedia.org/wiki/Odra_(Hrvatska), 15.12.2016.).

Zbog svog vijugavog toka i na mjestima teško dostupne i divlje obale te zato što u nju utječe mnoštvo sitnih rječica i potoka, naziva se Turopoljskom Amazonom. Na nekim mjestima je jako plitka, a najveće izmjerene dubine su između 5 i 6 metara (Kronike Velike Gorice, 26.5.2015., URL: http://www.kronikevg.com/rijeka-odra/, 15.12.2016.).

Kako je visinska razlika između izvorišta rijeke i njenog ušća manja od 3 m, rijeka je sklona izlijevanju iz svog korita. Na putu od Čičke Poljane do ušća, rijeka prima nekoliko pritoka s desne strane, od kojih su najznačajniji potoci Buna i Lekenik, koji izviru u Vukomeričkim Goricama. Svojim tokom protječe kroz nizinu, rubom šume ili kroz šumu. Od kanala Sava-Odra, pa do sela Odra Sisačka uz njen tok nema naselja. (https://hr.wikipedia.org/wiki/Odra_(Hrvatska), 15.12.2016.)

Zbog malog pada (0,13%) rijeka pravi brojne meandre. Travnjaci i šume uz rijeku Odru, kao najniži dijelovi Turopolja i Odranskog polja, predstavljaju retenciju koja se povremeno i privremeno puni vodama Odre, Save i Kupe. Naime, pri visokim vodostajima vode Save i Kupe se izlijevaju u Odru koja tada teče u suprotnom smjeru i postupno plavi okolno područje. Poplavama pridonose i visoke podzemne vode te nepropusnost tla.

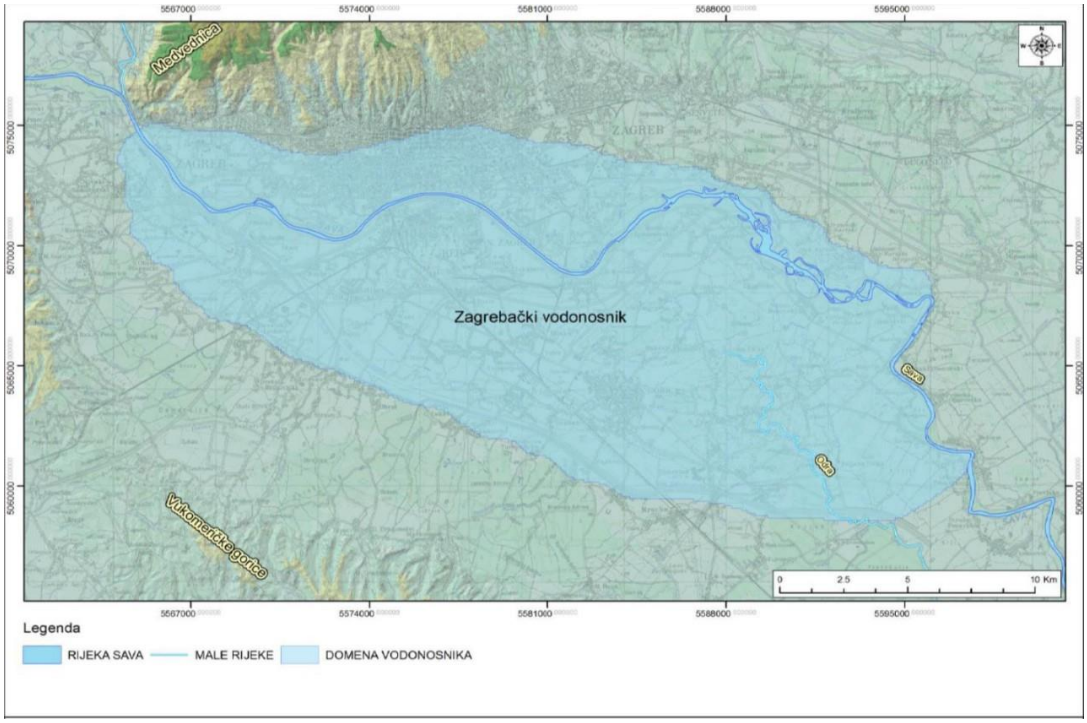
Odra je čista rijeka u kojoj su zabilježene 22 vrste riba, a također žive i vidre te dabrovi čije je tragove uz malo truda moguće uočiti na blatnjavim obalama rijeke. Stanište je i brojnim šumskim životinjama poput divlje svinje, srne, jelena i lisice.

Područje livada uz rijeku Odru te dio Turopoljskog luga evidentirani su u Prostornom planu Zagrebačke županije u kategoriji zaštićenoga krajolika. Izvorište Odre tj. okolica sela Jagodno evidentirana je kao zaštićeni krajolik.

Prema najnovijim, iako još službeno neprihvaćenim planovima Hrvatskih voda, Turopolje i Odransko polje će i dalje imati funkciju retencija. Rijeka Sava je najčešće opterećena različitim onečišćivačima i moguća je opasnost onečišćivanju livadnog i šumskog tla, nakon što se takva voda izlije putem odteretnog kanala Sava – Odra ili iz same Odre. (DUMBOVIĆ – RUŽIĆ, V., Hrvatsko društvo za zaštitu ptica i prirode: poplavna dolina rijeke Drave. URL: http://www.ptice.hr/index_projekti_drustva_iba_podrucja_011.htm (15.12.2016.))

2.2 Geologija

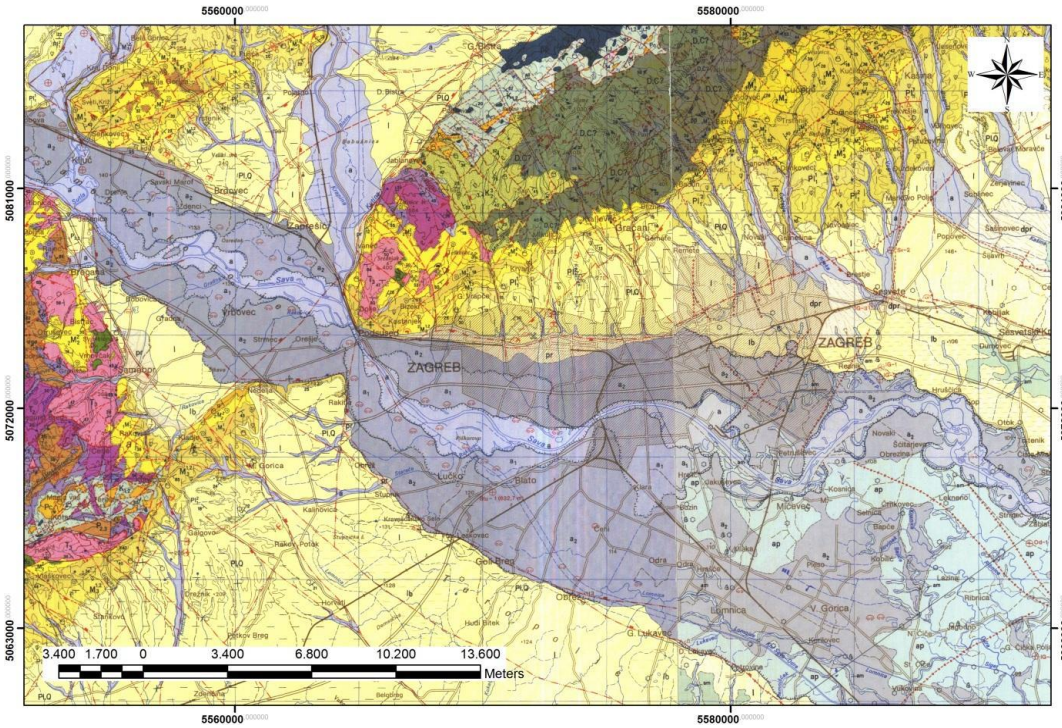
Zagrebački vodonosnik čine šljunkovito-pjeskovite naslage kvartarne starosti saturirane vodom koje se nalaze na području Grada Zagreba između Podsuseda na zapadu, Rugvice na istoku, Medvednice na sjeveru i Vukomeričkih Gorica na jugu (slika 2-1). Prostire se duž rijeke Save, pravcem sjeverozapad – jugoistok u dužini od oko 30 km, s prosječnom širinom od 10 do 15 km. Ukupna površina rasprostiranja mu iznosi 350 km^2, a rijeka Sava ga dijeli na lijevo i desno zaobalje (Bačani i Posavec, 2009).



Slika 2-1. Prostorni položaj zagrebačkog vodonosnika (preuzeto iz Bačani, 2015).

Zagrebački vodonosni sustav kvartarne je starosti taložen tijekom gornjeg i srednjeg pleistocena i holocena (slika 2-2). To područje je tijekom srednjeg i gornjeg pleistocena bilo jezersko i močvarno, a okolno gorje (Medvednica, Marijagorička brda i Žumberačko gorje) bilo je kopno podložno intenzivnoj eroziji i denudaciji (Posavec, 2006). Erodirani materijal s raznim udjelima šljunka, pijeska, praha i gline nošen je potocima te taložen u močvarama i jezerima. U dijelu područja Savske doline ispod površinskih naslaga nabušene su naslage koje djelomice odgovaraju onima koje se nalaze na području Medvednice.

Početkom holocena, tektonski i klimatski procesi omogućili su prodor i formiranje rijeke Save, čime je započeo transport materijala s područja Alpa (Velić i Durn, 1993). Transport materijala bio je promjenljivog 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 i dr., 1999). Posljedica takvih uvjeta taloženja je izrazita heterogenost i anizotropija vodonosnika te neujednačena debljina naslaga.



Slika 2-2. Geološka karta područja samoborskog i zagrebačkog vodonosnika. OGK List Zagreb, M 1:100 000 (Šikić i dr., 1972), OGK List Ivanić Grad M 1:100 000 (Basch, 1981), (preuzeto iz Kapuralić, 2013).

Tumač oznaka: a – aluvij: šljunci, pijesci i gline; pr – proluvij: šljunci, pijesci, gline; a_1 – najniža terasa: šljunci, pijesci, podređeno gline; a_2 – srednja terasa: šljunci, pijesci; a_3 – najviša terasa: vapnenački konglomerati; l – kopneni beskarbonatni les: glinoviti silt; l_b – barski les: siltozne gline; Pl,Q – šljunci, pijesci, gline (pliopleistocen); Pl_1^2 – pijesci, pjeskoviti i glinoviti lapori, gline (gornji pont); Pl_1^1 – lapori, laporovite gline, podređeno pijesci, pješčenjaci, šljunci i konglomerati (donji pont); $^2M_3^{1,2}$ – vapnoviti lapori, podređeno pijesci, pješčenjaci, šljunci i konglomerati (gornji panon); $^1M_3^{1,2}$ –laporoviti vapnenci, vapnoviti lapori, podređeno pijesci i pješčenjaci (donji panon); $M_3^{1,2}$ – vapnoviti lapori, pijesci, pješčenjaci, konglomerati i breče (panon); $_1M_3^1$ – vapnoviti, glinoviti i kremični lapori, laporoviti vapnenci i pješčenjaci (donji sarmat); $_2M_2^2$ – organogeni i bioklastični vapnenci, pješčenjaci, vapnoviti i glinoviti lapori (gornji torton); $_1M_2^2$ – vapnoviti lapori i pješčenjaci, bioklastični vapnenci (donji torton); αqα – dacito-andeziti; $_1M_2^1$ – konglomerati, šljunci, pijesci, gline, ugljen (donji helvet); Pc – breče, konglomerati, pješčenjaci, lapori, grebenski i bioklastični vapnenci (paleocen); $_{3,4}K_2^3$ - breče, konglomerati, vapnenci, lapori, pješčenjaci (kampan-mastriht); K_2 – breče, konglomerati, šejli, lapori, karbonatni klastiti, vapnenci, rožnjaci; $K_{1,2}$ – pješčenjaci, šejli, vapnenci, rožnjaci (apt-turon); ββ – dijabazi i spiliti; v – gabri; J_3 – vapnenci, silificirani vapnenci, rožnjaci; J_{1-2} - vapnenci, vapnenačke breče, silificirani vapnenci, rožnjaci, podređeno dolomiti; T,J – vapnenci, dolomitično vapnenci (retolijas); T_3 – dolomiti, podređeno vapnenci, dolomitični vapnenci i šejli; T_2 – dolomiti, podređeno vapnenci, lapori, rožnjaci, tufovi i tufiti;

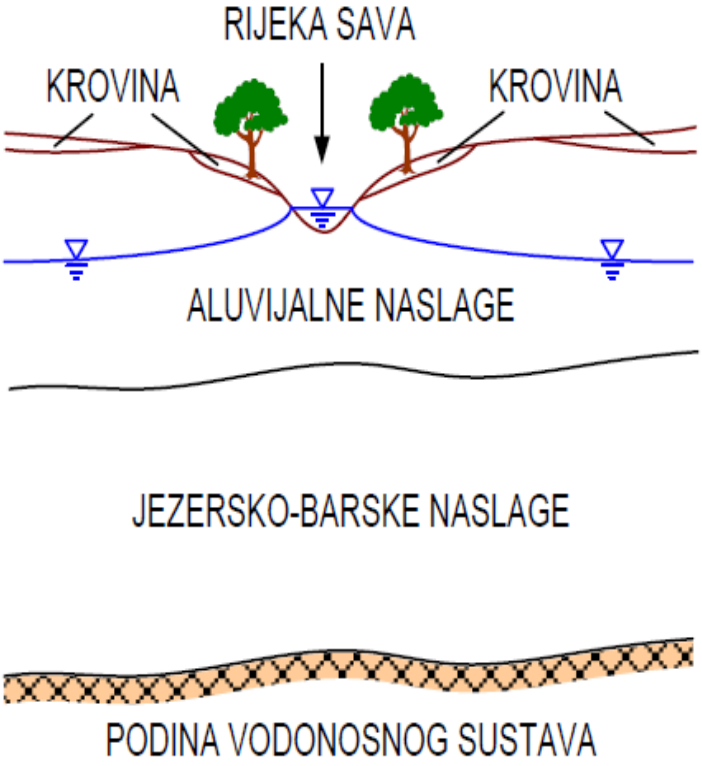
T_1 – pješčenjaci, siltiti, vapnenci, podređeno dolomiti i vapnoviti lapori; P,T – pješčenjaci, šejli, siltiti, gips; $P_{2,3}$ – brečokonglomerati, konglomerati, pješčenjaci, šejli siltit, vapnenci, dolomiti, gips; P_1? – mramori, mramorni škriljci, kvarc-sericitni i kvarc-kloritni škriljci; D,C? – ortometamorfiti; D.C – parametamorfiti.

2.3 Hidrogeologija

Zagrebački vodonosnik je otvoreni vodonosnik što znači da mu gornju granicu saturacije čini vodna ploha pod atmosferskim tlakom. Rubne granice vodonosnika čine u hidrauličkom smislu - nepropusna granica na sjeveru, granica dotjecanja na zapadu, granica dotjecanja na jugu te granica otjecanja na istoku. Generalni smjer toka podzemne vode je od zapada prema istoku/jugoistoku.

Napajanje vodonosnika se u najvećoj mjeri ostvaruje (1) infiltracijom iz rijeke Save; (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. Za vrijeme visokih voda rijeka Sava napaja vodonosnik duž cijeloga toka, dok za vrijeme srednjih i niskih voda na pojedinim dijelovima toka dolazi do dreniranja vodonosnika što nepovoljno utječe na razine podzemne vode (Posavec, 2006).

Zagrebački vodonosnik možemo podijeliti na dva vodonosna sloja (slika 2-3). Prvi sloj se sastoji pretežito od aluvijalnih naslaga rijeke Save (srednje do fino zrnati šljunak i pijesak s proslojcima gline i praha) s debljinom od 5 m na zapadu pa do 50 m na istoku te širine od 100 m na zapadu do 10 000 m na istoku. Drugi vodonosni sloj sastoji se pretežito od jezersko-barskih naslaga (šljunak i pijesak s lećama siltita i gline) s debljinom od 20 m na zapadu pa do 60 m na istoku. U krovini se nalaze pijesci ili siltozne gline debljine oko 3 m (negdje i manje) dok u podini vodonosnog sloja nalazimo sivo-plave i sivo-zelene gline, različite plastičnosti, u kojoj se javljaju vapnene konkrecije, a registrirana je i pojava treseta. Sava je svojim koritom usječena u aluvijalne holocenske naslage izgrađene od šljunaka izrazito velike hidrauličke vodljivosti koji čine glavni vodonosni sloj. U zapadnim dijelovima vodonosnika hidraulička vodljivost je veća od 3000 m/dan, a prema istoku opada do ispod 1000 m/dan (Urumović i Mihelčić, 2000). Najveća vrijednost transmisivnosti je oko 50000 m^2/dan.



Slika 2-3. Shematski profil zagrebačkog vodonosnog sustava (Posavec, 2006).

2.4 Sifon Odra

Sifon Odra prikazan je na slici 2-4. On je u principu stalno otvoren!

Sifon se zatvara kada se izjednače vodostaji u kanalu Sava - Odra i na sifonu Odra.

Razlog zatvaranja je sprečavanje istjecanja vode iz kanala Sava - Odra u rijeku Odru.

Kanal Sava - Odra (slika 2-5) u funkciji je obrane od poplava grada Zagreba. Funkcionira na način da se velike vode rijeke Save rasterećuju preko preljeva Jankomir te se kanalom dužine cca 30 km odvode u retenciju Odransko polje. Odransko polje kao retencioni prostor osim što se puni vodama iz kanala Sava - Odra na ranije opisani način, puni se i od oborina sa pripadajućeg sliva Vukomeričkih gorica, vodotoka Lomnica, Ribnica, Želin, Bapča, Koravec, Burdeljski potok itd., a moguće je i punjenje kupskim vodama.

Takva situacija se javlja već nekoliko zadnjih godina, u slučaju pojave visokih voda rijeke Kupe, Korane, Mrežnice, Dobre, Gline. Tada uz visoke vodostaje rijeke Save kod Siska dolazi do uspora, tj. do nemogućnosti ulijevanja rijeke Kupe u Savu pa dolazi do povratnih voda u rijeku Odru te samim time i dodatnog punjenja retencije Odranskog polja. Takva situacija traje sve dok vodostaji rijeke Save ne padnu na vrijednosti koje omogućavaju normalni tok rijeke Odre i Kupe, tj, mogućnost uljeva Odre u Kupu i Kupe u Savu što je osnovni preduvjet za pražnjenje retencionih voda iz Odranskog polja putem rijeke Odre u Kupu, odnosno Savu.



Slika 2-4. Sifon Sava-Odra

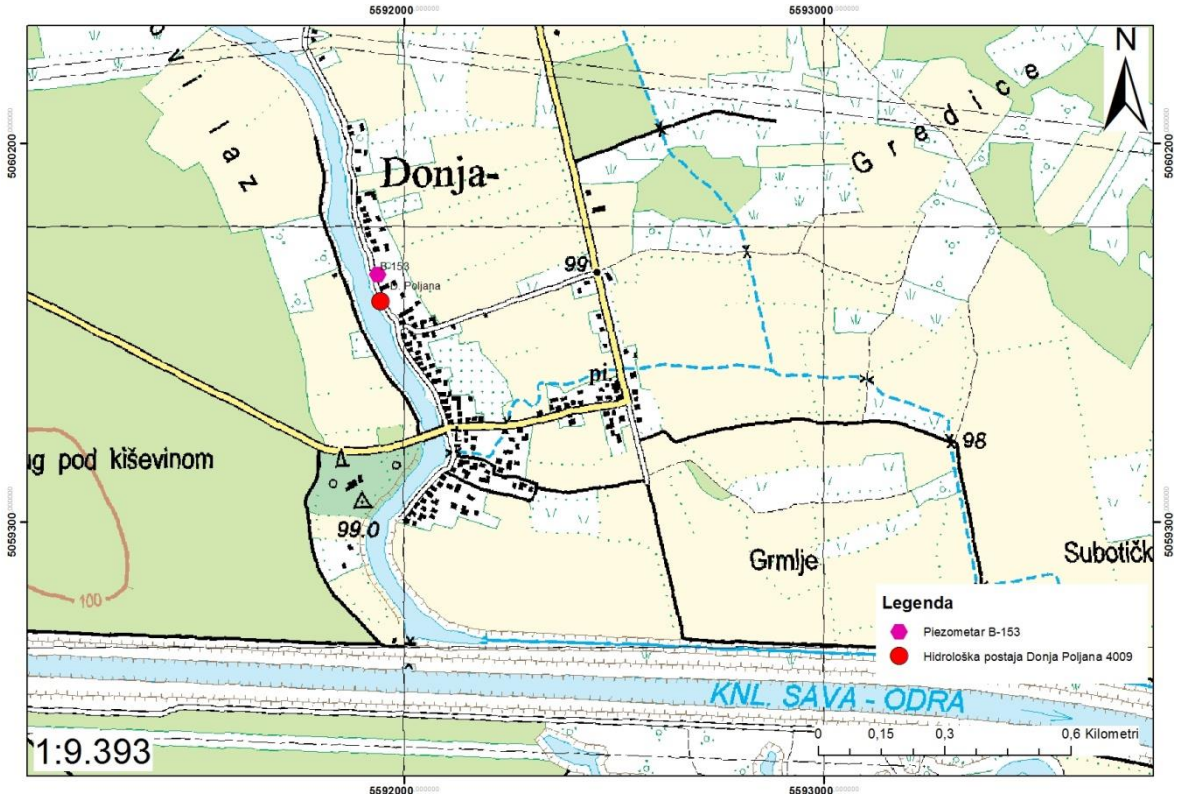


Slika 2-5. Kanal Sava-Odra

3. MJERNA POSTAJA I KORIŠTENI PODACI

Mjerna postaja Donja Poljana nalazi se na rijeci Odri u blizini naselja Čička Poljana na području istočnog zagrebačkog vodonosnika. Na slikama 3-2 i 3-3 prikazane su 3 vodokazne letve na kojima se izravno očitava visina vodostaja rijeke Odre, a čija je nulta točka (kota nula) geodetski snimljena, odnosno određena joj je apsolutna nadmorska visina koja iznosi 95,82 m-n.m. Mjerenja vodostaja obavlja Državni hidrometeorološki zavod u Zagrebu. Na toj mjernoj postaji prvi put su mjerenja započela 19.09.1946., a zadnja mjerenja su izvršena 31.08.2012. godine. Nakon toga više nisu zabilježena nikakva mjerenja jer je postaja ukinuta. O tome odlučuje nadležna institucija Hrvatske vode koja postavlja atest mjerača vodostaja.

Mjerenja razine podzemne vode provodi se u piezometru B-153 koji se nalazi nedaleko od mjerne postaje Donja Poljana (slika 3-1). Mjerenja u piezometrima obavlja Državni hidrometeorološki zavod u Zagrebu (DHMZ).



Slika 3-1. Položaj mjerne stanice Donja Poljana i piezometra B-153



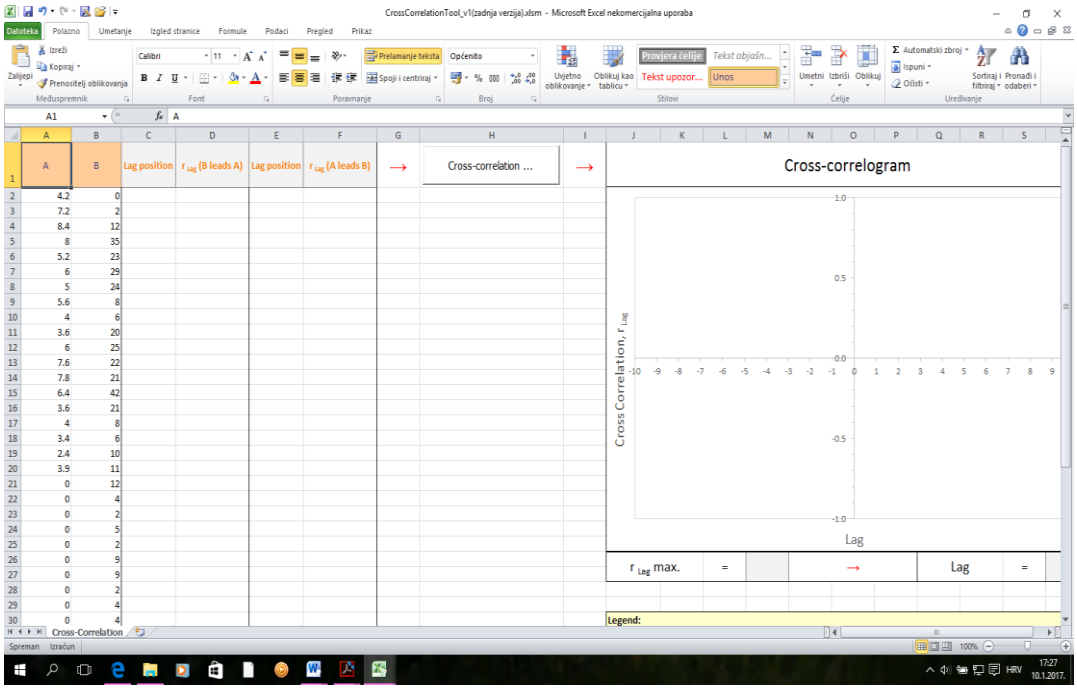
Slika 3-2. i 3-3. Vodokazne letve u naselju Čička Poljana

U ovom radu korišteni su podaci o vodostajima i razinama podzemne vode u razdoblju od 1.1.2004. do 31.8.2012. godine. Mjerenja vodostaja Odre obavljena su na dnevnoj bazi dok su mjerenja razina podzemne vode, a koja se obavljaju 3 do 4 puta tjedno, interpolirana metodom linearne interpolacije, čime su dobivena dnevna mjerenja. Linearna interpolacija razina podzemne vode u svrhu dobivanja dnevnih mjerenja bila je neophodna kako bi se mogle izvršiti statističke metode korelacije, regresije i kroskorelacije.

Metoda korelacije i metoda regresije su izvršene u programu Microsoft Excel koji posjeduje alate za statističku obradu podataka kao i mogućnosti grafičkog prikaza vremenskih nizova.

Metoda kroskorelacije je provedena u otvorenom VBA (Visual Basic for Application) računalnom kodu (Posavec i Škudar, 2016) (slika 3-4). To je besplatna aplikacija, a obrada vremenskih nizova je brza, pouzdana i objektivna što osigurava dosljednost u izvođenju obrada i primjenjivost na velike setove podataka.

Navedene metode i dobiveni rezultati objašnjeni su u narednim poglavljima.



Slika 3-4. Snimka zaslona alata za kroskorelacijsku analizu (Posavec i Škudar, 2016).

4. METODE OBRADE PODATAKA

4.1 Korelacija

Korelacija predstavlja suodnos ili međusobnu povezanost između različitih pojava predstavljenih vrijednostima dviju varijabli.

Koeficijenti korelacije izražavaju mjeru povezanosti između dvije varijable i njihov linearni odnos. Postoji više koeficijenata korelacije koji se koriste u različitim slučajevima. U praksi se prilikom rada s linearnim modelima najčešće koristi Pearsonov koeficijent korelacije. Vrijednost svakog koeficijenta korelacije mora biti između -1 i +1, uključujući i -1 i +1. Koeficijent +1 podrazumijeva savršenu ovisnost dviju varijabli, a koeficijent -1 znači da se jedna varijabla mijenja inverzno u odnosu na drugu.

Jednadžba za koeficijent korelacije glasi:

$$r(x,y)= \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}} \quad (4\text{-}1)$$

pri čemu su x i y vrijednosti podataka koje obrađujemo dok su $\bar{x}$ i $\bar{y}$ aritmetičke sredine uzorka podataka (Ratkaj, 2014).

Pozitivan (+) smjer korelacije pokazuje da porast vrijednosti varijable X prati porast vrijednosti varijable Y te isto tako da opadanje vrijednosti varijable X prati opadanje vrijednosti varijable Y. Negativan (-) smjer korelacije pokazuje da porast vrijednosti varijable X prati opadanje vrijednosti varijable Y i obratno. 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 (Posavec i Škudar, 2016).

U diplomskom radu koeficijent korelacije izračunan je iz niza podataka uz pomoć Microsoft Excela i funkcije CORREL.

4.2 Regresija

Metoda regresije može biti primijenjena pri analizi bilo kojeg seta podataka s dvije varijable kada je korisno promatrati jednu od varijabli kao funkciju druge varijable. Varijabla koja se promatra je zavisna varijabla (Y), a druga varijabla je nezavisna (X) (Davis, 2002). Matematički izraz koji pokazuje kako na vrijednost zavisne varijable utječe vrijednost jedne ili više nezavisnih varijabli naziva se regresijski model.

Opći oblik jednadžbe (regresijskog modela) je:

$$Y=f(X_1, X_2,\ldots X_k) + \varepsilon \tag{4-2}$$

Model se sastoji od deterministčkog dijela, koji predstavlja matematičku funkciju kojom se izražava zavisnost zavisne varijable od određenog broja nezavisnih varijabli i stohastičkog dijela koji predstavlja odstupanje od funkcionalne zavisnosti (ε).

Model koji izražava vezu između zavisne i jedne nezavisne varijable nazivamo jednostavni regresijski model. Regresijski modeli mogu izražavati linearne i nelinearne veze između promatranih varijabli.

Najjednostavniji regresijski model je model jednostavne linearne regresije:

$$y=ax+b \tag{4-3}$$

gdje je: y - najvjerojatniji rezultat varijable y za određeni rezultat varijable x, a - koeficijent nagiba, b - odsječak na osi y.

Ovakvim modelom pokušavamo objasniti veličinu y preko samo jedne veličine (x), a svi ostali utjecaji se 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 na kojemu se grafički prikazuju točke u koordinatnom sustavu. One predstavljaju niz uređenih parova rezultata mjerenja. Na os x nanose se vrijednosti za varijablu x, a na os y vrijednosti za y.

Na temelju rasporeda tih točaka možemo uočiti postojanje veze među varijablama, njen oblik, smjer i jačinu. Na dijagramu se crta pravac koji najbolje opisuje te točke i on se naziva regresijski model koji je oblika jednadžbe (4-3) (Škudar, 2016).

U analizi reprezentativnosti regresijskog modela koristi se koeficijent determinacije R^2. R^2 predstavlja mjeru koja nam omogućuje da odredimo koliko dobro podešena linija tj. regresijski model reprezentira mjerene podatke i određuje pouzdanost prognoziranja zavisne varijable pomoću dobivenog regresijskog modela. Vrijednosti R^2 kreću se u rasponu od 0 do 1. Kad je R^2 bliže jedinici onda regresijski model dobro reprezentira mjerene vrijednosti. Vrijednost koeficijenta determinacije R^2 daje nam postotak mjerenih podataka koji su najbliže podešenoj liniji tj. regresijskom modelu. Koeficijent determinacije je algebarski ekvivalentan koeficijentu korelacije ($r = \sqrt{R^2}$) (Davis, 2002).

U diplomskom radu regresijska analiza izvršena je uz pomoć Microsoft Excela, te je uz pomoć istog softvera izrađen graf. Na x osi se nalazila nezavisna varijabla (razina podzemne vode u piezometru), a na y osi zavisna varijabla (vodostaj rijeke Odre), te je dobiven pravac koji najbolje opisuje dobivene vrijednosti.

4.3 Kroskorelacija

Kroskorelacija je statistička metoda kojom se određuje stupanj povezanosti dvaju vremenskih nizova podataka. Takvom metodom dobivaju se podaci o jakosti veze između dva vremenska niza, ali i vremenski zaostatak. Vremenski zaostatak je zapravo razmak između varijabli u trenutku njihove maksimalne usklađenosti. Koeficijent kroskorelacije računa se isto kao i koeficijent linearne korelacije (Davis, 2002).

Kroskorelacija je korelacija između dvije vremenske serije koje su jedna u odnosu na drugu relativno pomaknute u vremenu. Kroskorelacijska analiza bitna je u proučavanju odnosa između vremenskih serija jer jedna serija može imati zakašnjelu reakciju prema drugoj seriji. Funkcija kroskorelacije dvije vremenske serije je koeficijent kroskorelacije kao funkcija vremenskog koraka tj. zaostajanja (engl. *lag*). U pojedinom vremenskom koraku funkciju kroskorelacije možemo promatrati kao koeficijent korelacije dvije vremenske serije, od kojih je jedna pomaknuta za određen broj vremenskih jedinica (Škudar, 2016).

Kroskorelacijska analiza se provodi tako da se za svaki vremenski korak računa koeficijent korelacije, odnosno kroskorelacije. Koeficijenti se grafički prikazuju na korelogramu, odnosno kroskorelogramu. Korelogram se crta tako da se u koordinatnom sustavu na x os nanose vremenski koraci, a na y os koeficijenti. Na korelogramu uočavamo za koji smo vremenski korak dobili najveći koeficijent kroskorelacije te njegov iznos. Vremenski korak s najvećim koeficijentom kroskorelacije je vrijeme zakašnjenja reakcije kad su vremenske serije u najvećem skladu (Škudar, 2016).

U kros-korelacijskoj analizi, mjerenja vremenskih nizova trebaju međusobno vremenski odgovarati, odnosno, mjerenja trebaju biti obavljana u isto vrijeme, npr. na isti dan ako je učestalost mjerenja npr. 1 dan. 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 (Posavec i dr., 2017).

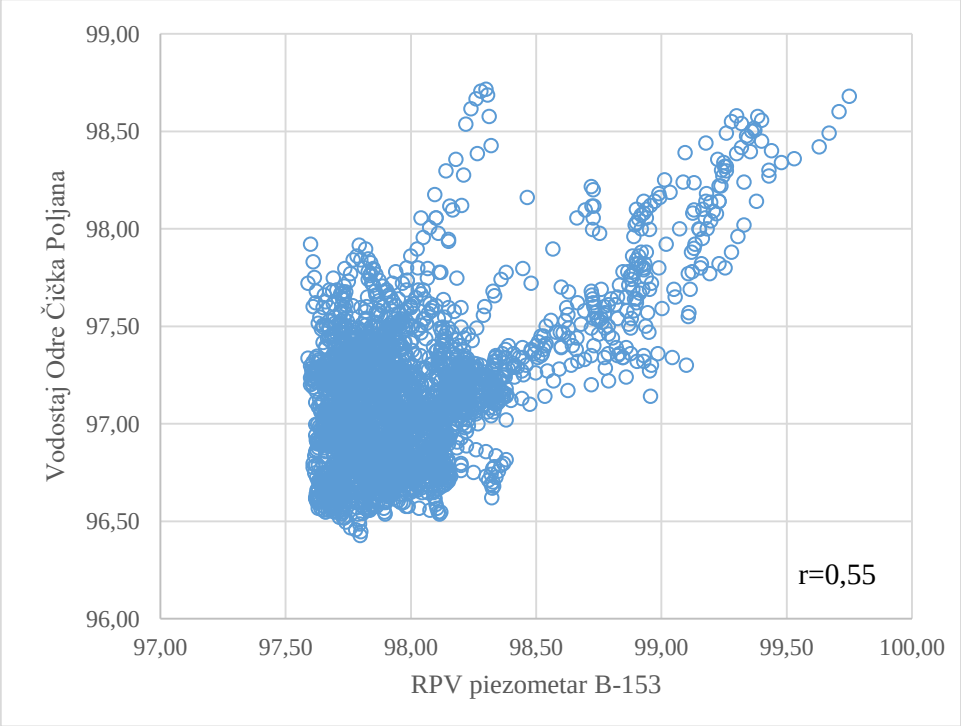
U slučaju kroskoreliranja iste vremenske serije najveći koeficijent kroskorelacije će biti na vremenskom koraku 0, te će se vrijednost koeficijenta jednako smanjivati i u negativnom i u pozitivnom vremenskom koraku. U slučaju zamjene vremenskih serija dobit će se isti podaci samo suprotnog predznaka (Ratkaj, 2014).

5. REZULTATI OBRADE PODATAKA

5.1 Rezultati obrade podataka metodom korelacije

Korelacijom vodostaja rijeke Odre i podzemnih voda istočnog zagrebačkog vodonosnika dobiven je koeficijent korelacije 0,55, koji ukazuje na slabiju povezanost. Smjer korelacije je pozitivan te pokazuje kako porast vodostaja rijeke Odre prati porast razine podzemnih voda u piezometru B-153. Isto tako, pad vodostaja rijeke Odre prati pad razina podzemne vode u piezometru B-153.

Na slici 5-1. prikazan je graf koji je izrađen u programu Microsoft Excel i koji prikazuje te rezultate.

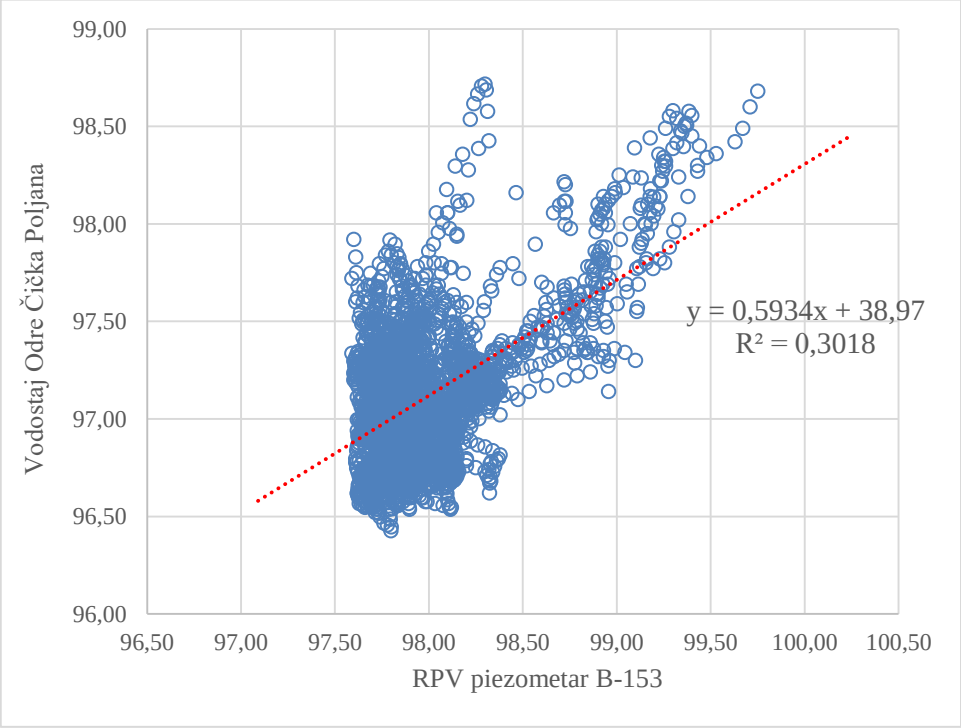


Slika 5-1. Graf koji prikazuje rezultat dobiven metodom korelacije

5.2 Rezultati obrade podataka metodom linearne regresije

Metodom linearne regresije obrađeni su podaci o razini podzemne vode u piezometru te vodostaj rijeke Odre. Analiza je provedena u računalnom programu Microsoft Excel. Rezultati mjerenja razine podzemne vode i vodostaja prikazani su kao točke u koordinatnom sustavu. Na osi X nanošeni su rezultati mjerenja razine podzemne vode iz piezometra B-153 koji predstavlja nezavisnu varijablu. Na osi Y nanošeni su rezultati mjerenja vodostaja rijeke Odre koji predstavlja zavisnu varijablu. U koordinatnom sustavu točke su opisane pravcem i njemu pripadajućom jednadžbom. Pomoću jednadžbe pravca regresije moguće je prognozirati vodostaj rijeke Odre ako znamo razinu podzemne vode u piezometru. Uz jednadžbu pravca dobiven je i koeficijent determinacije R^2, koji ukazuje na točnost vodostaja dobivenih izračunom iz jednadžbe pravca.

Analizom vodostaja rijeke Odre i razina podzemne vode izmjerene u piezometru B-153 dobivena je jednadžba pravca y = 0,5934x + 38,97 te koeficijent determinacije R^2 = 0,3018. Vrijednost koeficijenta determinacije nam ne ukazuje na precizno izračunavanje vodostaja rijeke Odre na temelju razine podzemne vode u piezometru (slika 5-2).



Slika 5-2. Rezultati obrade podataka metodom linearne regresije RPV/Odra

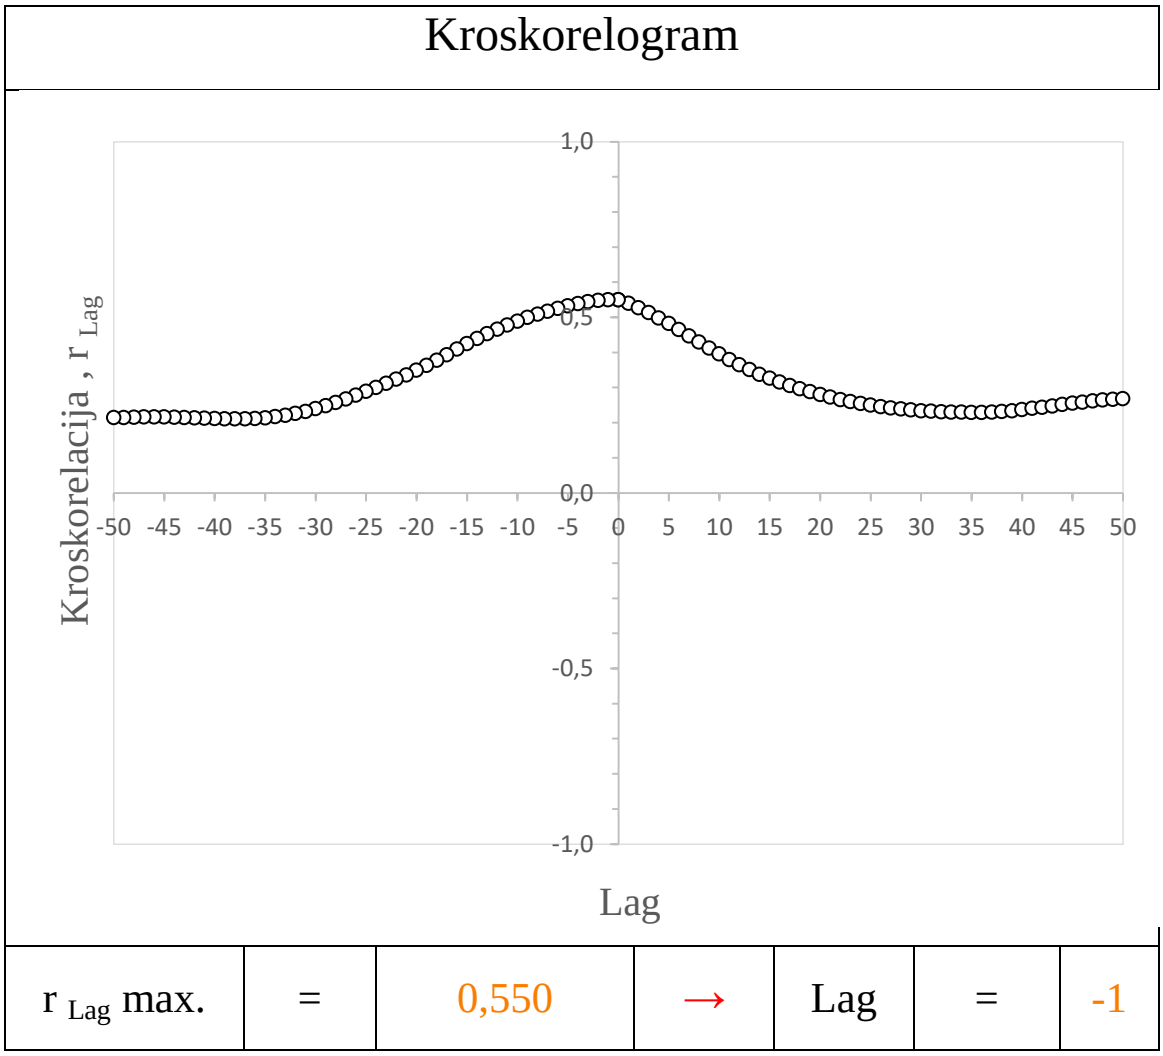
5.3 Rezultati obrade podataka metodom kroskorelacije

Metoda kroskorelacije obavljena je u 30 vremenskih koraka, pomoću VBA koda koji nudi Excel aplikacija (Posavec i Škudar, 2016).

Na korelogramu vremenske serije vodostaja Odre i razina podzemne vode piezometra B-153 najveći koeficijent kroskorelacije iznosi 0,55. Zabilježen je u negativnom dijelu vremenske serije na vrijednosti -1, što znači da je vremensko zaostajanje promjena vodostaja rijeke Odre 1 dan u odnosu na razinu podzemne vode istočnog zagrebačkog vodonosnika (slika 5-3).

Rezultati su pokazali brzu reakciju, tj. brzo širenje tlaka sa vremenom prijenosa tlaka podzemne vode od 1 dan koji je očekivan uslijed vrlo male udaljenosti između rijeke Odre i piezometra.

Također, slabije međudjelovanje male rijeke Odre i razina podzemne vode ukazuje na jako izražen proces u rijeci koje dovodi do začepljenja njenog korita sedimentom/muljem koji se taloži s obzirom na znatno manju energiju strujanja vode u rijeci Odri.



r Lag max.	=	0,550	→	Lag	=	-1

Slika 5-3. Kroskorelogram

6. DISKUSIJA

Vrlo veliki problem je nedostatak mjerne postaje uzvodno, a čime su dobiveni rezultati mjerodavni samo za uže područje oko mjerne postaje Donja Poljana 4009, odnosno nizvodnog dijela Odre na istočnom dijelu zagrebačkog vodonosnika.

Da imamo još jednu mjernu postaju mogli bi interpolirati vodostaje Odre i na više mjesta raditi statističke analize (metode korelacije, regresije i kroskorelacije) na većem broju piezometara i vidjeti je li na svim dijelovima podjednako hidraulički povezana s podzemnom vodom. Time bi dobili rezultate koji bi bili mjerodavni za šire područje.

7. ZAKLJUČAK

Identifikacija utjecaja vodostaja rijeke Odre na razinu podzemne vode istočnog zagrebačkog vodonosnika opisana je trima statističkim metodama, metodom linearne korelacije, regresije i kroskorelacije. Za analizu su korištena mjerenja u razdoblju od 1.1.2004 do 31.8.2012. godine.

Dobiveni rezultati su pokazali sljedeće:

Metodom korelacije dobiven je koeficijent korelacije koji iznosi 0,55. On upućuje na slabiju povezanost vodostaja Odre i razina podzemne vode. Prema tome, porastom vrijednosti razine podzemne vode rastu i vrijednosti vodostaja, a smanjenjem razine podzemne vode padaju vodostaji.

Metodom linearne korelacije dobivena je jednadžba regresijskog modela i koeficijent determinacije koji ukazuje na pouzdanost prognoziranja zavisne varijable pomoću regresijskog modela. U ovom slučaju taj koeficijent iznosi 0,3 te ne ukazuje na pouzdanost prognoziranja vodostaja rijeke Odre na temelju razina podzemne vode.

Metodom kroskorelacije dobiven je koeficijent kroskorelacije koji je zajedno s vremenskim korakom nanesen na graf, kroskorelogram. Vremenski korak kod kojeg je koeficijent kroskorelacije maksimalan odgovara vremenu zaostajanja promjena vodostaja rijeke Odre na promjenu razina podzemne vode koji iznosi 1 dan.

8. LITERATURA

BAČANI, A. (2015): Hidrogeologija 2. Interna skripta.

BAČANI, A. I POSAVEC, K. (2009): Elaborat zaštitnih zona vodocrpilišta Velika Gorica. 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

DAVIS, J. C. (2002): Statistics and Data Analysis in Geology, Third Edition. John Wiley & Sons Inc., New York.

KAPURALIĆ, J. (2013): Identifikacija utjecaja temperaturnih oscilacija rijeke Save i geotermalnih anomalija na temperaturne oscilacije podzemne vode zagrebačkog i samoborskog vodonosnika. Diplomski rad, RGN fakultet, Sveučilište u Zagrebu.

POSAVEC, K. (2006): Identifikacija i prognoza minimalnih razina podzemne vode zagrebačkoga aluvijalnog vodonosnika modelima recesijskih krivulja. Doktorska disertacija, RGN fakultet, 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 Excel Spreadsheet Application. DOI - 10.17794/rgn.2017.1.4. (*rad prihvaćen za tisak u RGN zborniku broj 35, 1/2017*).

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

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

ŠKUDAR, S. (2016.): Hidraulička povezanost aluvijalnih i proluvijalnih naslaga zagrebačkog vodonosnika. Diplomski rad, RGN fakultet, Sveučilište u Zagrebu.

URUMOVIĆ, K. I MIHELČIĆ, D. (2000): *Podzemne vode savskoga vodonosnika*. Hidrologija i vodni resursi Save u novim uvjetima, zbornik radova, okrugli stol, Slavonski Brod.

VELIĆ, J. I DURN, G. (1993): Alternating Lacustrine-Marsh Sedimentation and Subaerial Exposure Phases during Quaternary: Prečko, Zagreb, Croatia. Geologia Croatica, 46, 1, str. 71–90.

VELIĆ, J., SAFTIĆ, B. I MALVIĆ, T. (1999): Lithologic Composition and Stratigraphy of Quaternary Sediments in the Area of the "Jakuševec" Waste Depository (Zagreb, Northern Croatia). Geologia Croatica, 52, 2, str. 119–13.

VUKOJEVIĆ, P. (2010): Identifikacija utjecaja vodostaja Dunava i Drave na vodostaj jezera Sakadaš. Diplomski rad, RGN fakultet, Sveučilište u Zagrebu.

https://hr.wikipedia.org/wiki/Odra_(Hrvatska), 15.12.2016.

Kronike Velike Gorice, 26.5.2015., URL: http://www.kronikevg.com/rijeka-odra/, 15.12.2016

DUMBOVIĆ – RUŽIĆ, V., Hrvatsko društvo za zaštitu ptica i prirode: poplavna dolina rijeke Drave., URL: http://www.ptice.hr/index_projekti_drustva_iba_podrucja_011.htm (15.12.2016.