Hidrološki odnosi susjednih krških izvora

Kadić, Ana

Doctoral thesis / Disertacija

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:

University of Split, Faculty of Civil Engineering, Architecture and Geodesy / Sveučilište u Splitu, Fakultet građevinarstva, arhitekture i geodezije

<https://doi.org/10.31534/DocT.043.KadA>

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:123:001186>

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

Download date / Datum preuzimanja: **2023-04-26**

Repository / Repozitorij:

[FCEAG Repository - Repository of the Faculty of Civil Engineering, Architecture and Geodesy, University of Split](#)

UNIVERSITY OF SPLIT

SVEUČILIŠTE U SPLITU

**FAKULTET GRAĐEVINARSTVA, ARHITEKTURE I
GEODEZIJE**

Ana Kadić, dipl.ing.grad.

**HIDROLOŠKI ODNOSI SUSJEDNIH
KRŠKIH IZVORA**

Disertacija

Split, 2017.

Ana Kadić, dipl. ing. građ.
Redni broj: 043

**Ova disertacija predana je na ocjenu
Fakultetu građevinarstva, arhitekture i
geodezije Sveučilišta u Splitu u svrhu
stjecanja akademskog stupnja doktora
tehničkih znanosti u znanstvenom polju
građevinarstvo.**

Mentor: Prof. dr. sc. Vesna Denić-Jukić, dipl. ing. građ.

Povjerenstvo za ocjenu:

Prof. dr. sc. Vesna Denić-Jukić, dipl. ing. građ.

Doc. dr. sc. Davor Bojanić, dipl. ing. građ.

Izv. prof. dr. sc. Marija Šperac, dipl. ing. građ.

Povjerenstvo za obranu:

Prof. dr. sc. Vesna Denić-Jukić, dipl. ing. građ.

Doc. dr. sc. Davor Bojanić, dipl. ing. građ.

Izv. prof. dr. sc. Marija Šperac, dipl. ing. građ.

Rad je obranjen dana: 10. studenog, 2017.

Tajnica:

Saša Delić, dipl.iur.

Rad sadrži:

109 stranica teksta

54 crteža

8 tablica

162 citirane reference

Za Lauru

Zahvala

Ovom prigodom izražavam iskrenu zahvalnost:

mentorici prof. dr. sc. Vesni Denić-Jukić i prof. dr. sc. Damiru Jukiću za pomoć i strpljenje koje su mi pružili tijekom izrade ovog rada,

članovima povjerenstva doc. dr. sc. Davoru Bojaniću i izv. prof. dr. sc. Mariji Šperac za pregled rada i korisne savjete,

prijateljima i kolegama dr. sc. Ivani Uzelac Glavinić i doc. dr. sc. Vladimiru Diviću za kontinuirani angažman i pomoć pri izradi numeričkih algoritama i rješavanju software-skih problema,

suprugu na podršci i ohrabrenju

braći koji su se pokazali kao najbolji ujac na svijetu

najboljoj baki Đulici

i na kraju najveću i neizrecivu zahvalnost dugujem svojim roditeljima.

Ana Kadić, dipl.ing.grad.

HIDROLOŠKI ODNOSI SUSJEDNIH KRŠKIH IZVORA

Sažetak

Cilj ovog rada je proučavanje hidroloških odnosa dvaju susjednih krških izvora Jadro i Žrnovnica u Hrvatskoj. Rad se fokusira na utvrđivanju utjecaja temperature, relativne vlažnosti, oborina i protoka na ponašanje i odnose dvaju izvora. Parcijalna korelacijska analiza vremenskih serija implicira da utjecaj kontrolne vremenske serije na kros-korelacijsku funkciju između ulazne i izlazne vremenske serije može biti detektiran pomoću korelacijskog koeficijenta između ulazne i kontrolne vremenske serije, i kros-korelacijske funkcije između kontrolne i izlazne vremenske serije. Napajanje podzemnih voda ovisi o procesu evapotranspiracije i oborinama, dakle temperatura zraka, relativna vlažnost i oborine kontroliraju prostornu i vremensku distribuciju ovih procesa. Najveći doprinos ovog rada leži u korištenju obične korelacije i parcijalne korelacijske analize prvog reda za karakterizaciju funkcioniranja i odnosa dvaju susjednih krških izvora u sušnoj i kišnoj hidrološkoj godini koristeći satne podatke. Dokazano je da je u slučaju susjednih krških izvora protok svakog pojedinog izvora ima utjecaj na korelaciju oborine-protok drugog izvora. Demonstrirani pristup predstavlja poboljšanje u analizi odnosa susjednih krških izvora u sušnim i kišnim periodima, i može se primijeniti na bilo koje susjedne krške izvore.

Ključne riječi: hidrologija krša, korelacija, parcijalna korelacija, izvor Jadro, izvor Žrnovnica

Ana Kadić, dipl.ing.grad.

HYDROLOGICAL RELATIONS OF ADJACENT KARST SPRINGS

Summary

The objective of this work is the study of two adjacent karst springs Jadro and Žrnovnica in Croatia. This work focuses on the effects of temperature, relative humidity, rainfall and discharges on the behaviour and relations of two adjacent karst springs. Partial correlation analysis implies that the impact of the control signal on the cross-correlation function between the input and output signal can be detected from the correlation coefficient between the input signal and control signal and from the cross-correlation function between the control signal and output signal. The groundwater recharge depends on the process of evapotranspiration and rainfall, so air temperature, relative humidity and rainfall control the spatial and temporal distribution of this process. The major contribution of the paper relies on the utilization of simple correlation and first-order partial correlation analysis to characterize the functioning and relations of two adjacent karst springs in a dry and wet hydrological year by using hourly data. It has been confirmed that in the case of adjacent karst springs the discharge of each spring has effect on the rainfall-discharge correlation of the other spring. The demonstrated approach represents an improvement in investigating the relations of adjacent karst springs in dry and wet periods, and can be applied on any adjacent karst springs.

Keywords: karst hydrology, simple correlation, partial correlation, Jadro Spring, Žrnovnica Spring

SADRŽAJ

1. UVOD	3
1.1 OPĆENITO	3
1.2 MOTIVACIJA, METODOLOGIJA I CILJEVI RADA	8
1.3 PREGLED DOSADAŠNJIH ISTRAŽIVANJA	12
2. METODE ANALIZE	15
2.1 UVOD	15
2.2 KORELACIJSKA ANALIZA	17
2.3 PARCIJALNA KORELACIJSKA ANALIZA	19
2.4 OSNOVE PRAKTIČNE PRIMJENE PARCIJALNE KORELACIJSKE ANALIZE	22
2.5 FUNKCIJSKE OZNAKE I OBJAŠNJENJE ODNOSA KORELACIJA- PARCIJALNA KORELACIJA	25

3. HIDROGEOLOŠKE KARAKTERISTIKE SLIVA IZVORA JADRA I ŽRNOVNICE	26
3.1 HIDROLOŠKE KARAKTERISTIKE JADRA I ŽRNOVNICE	26
3.2 HIDROGEOLOŠKA I GEOLOŠKA OBILJEŽJA SLIVA	34
3.3 OSNOVNI STATISTIČKI PODACI ANALIZIRNOG RAZDOBLJA	37
4. REZULTATI ANALIZA I DISKUSIJA	41
4.1 KORELACIJSKA ANALIZA	41
4.1.1 Auto-korelacijska analiza	41
4.1.2 Kros-korelacijska analiza	53
4.2 PARCIJALNA KORELACIJSKA ANALIZA	60
4.2.1 Parcijalna auto-korelacijska analiza	60
4.2.2 Parcijalna kros-korelacijska analiza	67
4.3 ANALIZA PROTOKA U MODULNIM KOEFICIJENTIMA	83
5. ZAKLJUČAK	89
POPIS SLIKA	92
POPIS TABELA	97
LITERATURA	98
ŽIVOTOPIS	110

1 UVOD

1.1 OPĆENITO

Pojam krša označava specifični reljef, s pretežno podzemnim tečenjem, koji se uglavnom javlja u karbonatnim stijenama i vapnencima. Karbonatne stijene predstavljaju većinu krških terena te zauzimaju oko 20% ukupne svjetske kopnene površine (Ford i Williams, 2007) (slika 1.1).

Slika 1.1 Prostorna skica krških područja u svijetu (Krška područja označena su crvenom bojom. Izvor: COST 65, 1995 + 620, 2003; Europ. Comm., Luxembourg. *Encycl. caves + karst science*, N.Y., 2004.)

Slike 1.1 i 1.2 pokazuju da je Mediteran izuzetno bogat krškim područjima, dok su zemlje Južne Amerike i skandinavske zemlje siromašne krškim područjima.

Slika 1.2 Prostorna skica krških područja u Hrvatskoj (Biondić i Biondić, 2014)

Krška područja zauzimaju planinski i jadranski dio državnog teritorija Republike Hrvatske (Biondić i dr, 1997a). Hrvatska krška područja pretežito pripadaju geološkoj strukturi Dinarida (slika 1.2 i 1.3) (Milanović, 1979; Žugaj, 1995; Biondić i Biondić, 2014; Matas, 2009). Dinarsko gorje je tipski i klasični primjer krškog gorja. Ostali krški lanci u Europi su uglavnom manje ili izolirane vapnenačke planine, npr. niži rubni vrhovi sjevernih i južnih Alpa, dio Tatra, Kantabrijsko gorje u Španjolskoj, Pinda u Grčkoj, itd. Više od polovice teritorija Republike Hrvatske pripada području Dinarida. To je područje bogato oborinama i podzemnim vodonosnicima iz kojih se pitkom vodom opskrbljuju brojni gradovi, a disolucijom vode stvoreni su vizualno atraktivni prostori čiji su dijelovi proglašeni nacionalnim parkovima (slika 1.4) i otvoreni za posjetitelje (Biondić i Biondić, 2014).

Slika 1.3 Prostorna skica krških područja u Hrvatskoj (Biondić i Biondić, 2014)

Slika 1.4 Nacionalni park Plitvička jezera

Milijuni ljudi diljem svijeta žive u krškim područjima, i koriste pitku vodu iz krških vodonosnika. Ovi vodonosnici su vrijedni resursi pitke vode, ali su ponekad teško iskoristivi i gotovo su uvijek osjetljivi na onečišćenja, zbog njihovih specifičnih hidrogeoloških svojstava. Stoga krški vodonosnici zahtijevaju povećanu zaštitu i primjenu specifičnih hidrogeoloških metoda za njihovo ispitivanje. Ostali problemi koji se često susreću u kršu su erozija tla i dezertifikacija stijena, curenje kanala i rezervoara, slom podzemnih šupljina i formiranje vrtača, te poplave.

Krški vodonosnici formiraju se tečenjem vode koja sadrži ugljični dioksid koji otapa karbonatne stijene. Kemijski proces karstifikacije prikazan je i opisan na slici 1.5.

Slika 1.5 Voda obogaćena s CO_2 (ugljikov-dioksid) iz tla i vegetacije povećava pukotine i prodire sve dublje. Kada voda koja sadrži otopljene ione dosegne jamu, kalcitne naslage istalože se u raznim oblicima.
(prema Zupan Hajna i dr., 2015)

Postoji bliska veza između evolucije vodonosnika, formiranja špilje (speleogeneza) i toka podzemnih voda. Iako postoje mnoge sličnosti između različitih krških sustava, svaki krški sustav je poseban slučaj i nije ih moguće generalizirati. Krške vodonosnike karakterizira heterogenost (Bonacci, 1987) i anizotropija. Svojstva krških vodonosnika uvelike se razlikuju u prostoru te hidraulička svojstva vodonosnika ovise o orijentaciji geoloških elemenata; na primjer, hidraulička provodljivost je obično visoka u smjeru velikih pukotina i kanala, ali može biti niska u drugim smjerovima. Kao bitnu karakteristiku treba navesti i vremensku varijabilnost. Krški vodonosnici pokazuju brz odgovor na hidrološke pojave kao što su kiša, otapanje snijega i dr., stoga razina vode u krškim vodonosnicima ponekad može varirati i po 100 m u svega nekoliko sati (Goldscheider i dr., 2007). Kao posljedica takvog ponašanja izvora su brze varijacije protoka i kvalitete vode.

Zbog prethodno opisanih karakteristika, konvencionalne hidrološke i hidrogeološke metode zahtijevaju prilagodbe i modifikaciju kada su krški vodonosnici u pitanju. Goldscheider i dr. (2007) dali su sljedeći pregled metoda za istraživanje krških vodonosnika:

1) Geološke metode:

Litologija i stratigrafija su ključne za razumijevanje podzemnog toka u krškim vodonosnicima.

2) Speleološke metode:

Provodnici i podzemni kanali su važni za podzemno tečenje, dok špilje omogućavaju ulazak u vodonosnik te izravno promatranje i analizu dijelova mreže provodnik-kanal.

3) Hidrološke metode:

Zbog visoke varijabilnosti brzine protoka, kontinuirano praćenje količine i kakvoće vode je presudno.

4) Hidrauličke metode:

Hidraulička ispitivanja u bušotinama i bunarima imaju široku primjenu u analizama krških vodonosnika.

5) Izotopne tehnike:

Stabilni i radioaktivni izotopi mogu pomoći u identifikaciji porijekla vode i utvrđivanju vremena prijenosa.

6) Traserski testovi:

Vrlo korisna metoda za delineaciju sliva krških izvora, karakterizaciju toka i transporta vode u mreži provodnika.

7) Geofizičke metode:

Korisne su za određivanje lokacija istražnih bušenja, istraživanje podzemnih površina šupljina i dobivanje drugih podataka o strukturi vodonosnika.

8) Modeliranje:

Matematički modeli su vrlo korisni alati za kvantitativnu prezentaciju hidrauličkog ponašanja sustava vodonosnika, odnosno, identifikaciji fenomena tečenja i transporta u krškim vodonosnicima. Rekonstrukcija polja strujanja podzemnih voda, odnosno simulacija otjecanja, gotovo uvijek zahtijeva matematičke modele (Kiraly 2002).

Pregled, motivacija i ciljevi korištenja određenih metoda za ovaj rad dani su sljedećem poglavlju 1.2.

1.2 MOTIVACIJA, METODOLOGIJA I CILJEVI RADA

Hidrogeološke i hidrološke karakteristike krških vodonosnika su kompleksne i značajno se razlikuju od karakteristika granuliranih vodonosnika (Bonacci, 1987; White, 1988; Ford i Williams, 1989, 2007; Dreybrodt, 1988; Klimchouk i dr., 2000; Bakalowicz, 2005; Goldscheider i dr., 2007; Jukić i Denić-Jukić, 2009; Hartman i dr., 2012; Sanchez i dr., 2015; Željковиć i Kadić, 2015). Postojanje nepravilne mreže pora, pukotina, rascjepa, podzemnih kanala i špilja različitih veličina i oblika u slabo propusnom mediju topivih stijena, osnovna je karakteristika krša (Denić-Jukić i Jukić, 2003, 2009; Labat i dr., 2001; Labat i dr., 2016). Takva struktura uvjetuje složene hidrauličke uvjete tečenja kroz podzemlje jer postoji izražena vremenska promjenjivost, te prostorna heterogenost i diskontinuiranost hidrauličkih parametra (White, 2002; Željковиć i Kadić, 2015). Direktna posljedica ovakve strukture je dualnost vodonosnika (slika 1.6). Prema Kiraly-u (1995) dualnost se odnosi na: a) dualnost procesa infiltracije, b) dualnost polja strujanja podzemnih voda i c) dualnost uvjeta otjecanja.

Slika 1.6 Blok-dijagram heterogenog krškog vodonosnika (prema Goldscheider i dr., 2007)

Nehomogena struktura krša uzrokuje također vremenski i prostorno promjenjivu dinamiku tečenja. Fluktuacije razine podzemne vode izrazito su brze pri čemu se naglo mijenjaju smjerovi i brzine tečenja u krškim provodnicima (Bonacci, 1987; Bonacci i Andrić, 2015; Hartmann i dr., 2014). Krški provodnici unutar zasićene zone mogu transportirati vodu na velike udaljenosti i na taj način u pojedinim slučajevima povezati dva ili više susjednih krških izvora. Kod visokih razina podzemnih voda mogu se aktivirati i provodnici unutar nezasićene zone što može uzrokovati prelijevanje iz sliva u sliv (Bonacci i Andrić, 2015). Ovakvi krški izvori s naizgled preklapajućim slivovima su uobičajena pojava u mnogim krškim područjima diljem svijeta. Pojam "preklapanje" podrazumijeva postojanje slivnog područja koje gravitira privremeno ili trajno na dva ili više susjednih krških izvora (Kadić i dr., 2015). Zbog prethodno navedenih specifičnih uvjeta tečenja u krškom podzemlju, mehanizam razmjene podzemnih voda između krških izvora je najčešće vrlo složen i vremenski promjenljiv, što u znatnoj mjeri smanjuje pouzdanost određivanja hidrogeološke razvodnice između slivnih područja i otežava optimalno gospodarenje vodnim resursima.

Općenito, za simulaciju otjecanja iz krških vodonosnika mogu se koristiti tri tipa matematičkih hidroloških modela: teoretski modeli, konceptualni modeli i black-box (empirijski) modeli (Denić-Jukić i Jukić, 2003; Fleury i dr., 2007; Le Moine i dr., 2008; He i dr., 2011). Teoretski modeli se zasnivaju na hidrauličkim zakonima za različite procese tečenja u poroznim

sredinama (Eisenlohr i dr., 1997 a i b). Za primjenu teoretskih modela potrebna su opsežna hidrološka, geološka i hidrogeološka istraživanja. Kod konceptualnih modela, sustav se aproksimira s nekoliko zasebnih podsustava unutar kojih se smatra da su unutarnja struktura i funkcioniranje konstantni (Halihan i Wicks, 1998; Fleury i dr., 2007; Le Moine i dr., 2008; Padilla i Pulido-Bosch, 2008; Jukić i Denić-Jukić, 2009; Charlier i dr., 2012; Hartman i dr., 2012). Black-box modeli se temelje se na pronalaženju matematičkih relacija koje na najbolji način uspostavljaju veze između ulaza i izlaza iz sustava: analiza vremenskih serija (Mangin, 1984; Padilla i Pulido-Bosch, 1995), neuralne mreže (Johannet i dr., 1994; Kurtulus i Razack, 2006), linearne i ne linearne funkcije (Pinault i dr., 2001; Jukić i Denić-Jukić, 2011).

Metode analize vremenskih serija su se pokazale u hidrologiji krša kao koristan alat za utvrđivanje osnovnih karakteristika pojedinog izvora i njihovu usporedbu (Mangin, 1984; Labat, 2000). Auto-korelacija i kros-korelacija su segment analize vremenskih serija koji omogućuje uvid u krški sustav na temelju ulaznih (oborine) i izlaznih (protok) vremenskih serija. Pomoću ovih metoda moguće je odrediti: linearnu ovisnost između vremenskih serija tijekom promatranog perioda, te neke opće karakteristike krškog sustava kao što su npr. pamćenje sustava i vrijeme odgovora sustava. Međutim, šira praktična primjena je ograničena, posebno ako se radi o većim slivovima s prostorno promjenjivim hidrogeološkim karakteristikama i nejednolikom raspodjelom oborina. Tako npr. prostornu i vremensku karakterizaciju krškog sustava ili hidrološke odnose među izvorima nije moguće utvrditi na ovaj način. Naime, budući da su vremenske serije oborina i protoka kao ulazno-izlazne vremenske serije promatranog sustava pod utjecajem raznih prostorno-vremenski promjenjivih procesa uključenih u transfer vode u hidrološkom ciklusu (Jukić i Denić-Jukić, 2011, 2015) efekti ovakvih procesa mogu biti obuhvaćeni auto-korelacijskim i kros-korelacijskim funkcijama. Osim toga, problem predstavlja i prividna korelacija koja uvijek postoji između oborina opaženih na susjednim mjernim postajama.

Kao nova metoda za rješavanje ove problematike predložena je parcijalna korelacijska analiza (Jukić i Denić-Jukić, 2015). Parcijalna korelacijska analiza vremenskih serija implicira da utjecaj kontrolne vremenske serije na kros-korelacijsku funkciju između ulazne i izlazne vremenske serije može biti detektiran pomoću korelacijskog koeficijenta između ulazne i kontrolne vremenske serije, i kros-korelacijske funkcije između kontrolne i izlazne vremenske serije. Parcijalnom auto-korelacijskom i parcijalnom kros-korelacijskom funkcijom je moguće npr.: identificirati utjecaje raznih kontrolnih vremenskih serija na brzu, srednju i baznu komponentu otjecanja, detektirati sezonske utjecaje prihranjivanja na otjecanje, te procijeniti stvarno pamćenje krškog sustava.

Glavna motivacija za izradu ove disertacije je daljnji razvoj ove nove metode te dolazak do novih saznanja o hidrološkim odnosima između krških izvora Jadro i Žrnovnica. Naime, parcijalne korelacijske funkcije do sada nisu korištene u istraživanju međusobnih odnosa krških izvora.

U disertaciji će se rezultati metode analize vremenskih serija usporediti sa rezultatima dobivenima pomoću klasične hidrološke metode modulnih koeficijenata (Yevjevich i Jeng, 1969; Salas i dr., 1980; Bonacci 1987; Žugaj i dr., 2011; Kadić i dr., 2015).

Cilj ovih analiza je dopuna dosadašnjih rezultata istraživanja s novim rezultatima koji su neophodni za razumijevanje hidroloških odnosa između dva susjedna krška izvora, te eventualno dolazak do nekih novih saznanja o funkcioniranju izvora Jadra i Žrnovnice s obzirom da ovakav oblik hidrološke analize do sada nije napravljen.

Metode analize vremenskih serija se zasnivaju na utvrđivanju, analizi i usporedbi oblika parcijalnih korelacijskih funkcija. Parcijalne korelacijske funkcije će se koristiti za utvrđivanje utjecaja temperature zraka, relativne vlažnosti zraka, oborina i protoka na funkcioniranje pojedinog izvora u sušnoj i vlažnoj hidrološkoj godini, te za određivanje odnosa između dva susjedna krška izvora. Vremenske serije oborina s raspoloživih meteoroloških stanica će se koristiti kao ulazne serije, a vremenske serije protoka s dva izvora će se koristiti kao izlazne vremenske serije. Kontrolne vremenske serije će biti: srednja temperatura zraka, srednja relativna vlažnost zraka, oborine te protoci. Prvi put će se u parcijalnoj korelacijskoj analizi kao kontrolna vremenska serija koristiti protok. U sklopu ovih istraživanja će se odrediti parcijalne auto-korelacijske funkcije za oba izvora u sušnoj i vlažnoj hidrološkoj godini. Utvrdit će se koja od kontrolnih vremenskih serija najviše utječe na pražnjenje pojedinog akvifera. Utvrdit će se trajanje brzog, srednjeg i sporog tečenja te stvarno pamćenje pojedinog sustava. Nakon toga će se izvršiti parcijalna kros-korelacijska analiza za sušnu i vlažnu hidrološku godinu, koja će se temeljiti na usporedbi kros-korelacijskih funkcija i parcijalnih kros-korelacijskih funkcija. Na taj način će se utvrditi:

- koja kontrolna vremenska serija ima djelomičan utjecaj na vezu oborina-protok,
- koja kontrolna vremenska serija nema utjecaj na vezu oborina-protok,
- koja kontrolna vremenska serija *kvari*, tj., ima utjecaj supresije na odnos oborina-protok,
- koja kontrolna vremenska serija u potpunosti opisuje relaciju oborina-protok.

Na kraju će se rezultati parcijalne korelacijske analize usporediti sa rezultatima dobivenima pomoću klasične metode modulnih koeficijenata s ciljem pravilne interpretacije dobivenih rezultata te utvrđivanja odnosa i načina funkcioniranja krških izvora Jadra i Žrnovnice.

1.3 PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Analiza vremenskih serija uspješno se primjenjuje u područjima poput hidrologije, klimatologije, geologije, oceanografije, seizmologije, itd.

Analize vremenskih serija u hidrologiji su korištene za analizu povijesnih podataka o oborinama (Henderson, 1989; De Michele i dr., 1998; Mirza i dr., 1998; Pagliara i dr., 1998; Astel i dr., 2004), podataka o poplavama (Grew i Werrity, 1995; Changnon i Kunkel, 1995; Westmacott i Burn, 1997; Robson i dr., 1998; Reed i dr., 1999; Loukas i Quick, 1996; Jain i Lall, 2001; Douglas i dr., 2000; Adamowski i Bocci, 2001; Zhang i dr., 2001), podataka o kvaliteti površinske vode (Jayawardena i Lai, 1989; Higashino i dr., 1999), kao i za generiranje podataka o sintetičkim oborinama u polusušnim područjima (Janos i dr., 1988), određivanje trendova evapotranspiracije i brzine vjetra (Raghuwanshi i Wallender, 1997), itd.

U preliminarnim istraživanjima (Pulido-Bosch i dr., 1995; Angelini, 1997; Larocque i dr., 1998; Bouchaou i dr., 2002; Mathevet i dr., 2004; Rahnemaei i dr., 2005; Panagopoulos i Lambrakis, 2006; Bailly-Comte i dr., 2008; Mayaud i dr., 2014) pokazano je kako metode analize vremenskih serija u hidrologiji krša daju kvalitativne informacije vezane uz bazično razumijevanje krškog sustava. One su nezaobilazan postupak svih preliminarnih istraživanja posebno za hidrogeološki nedovoljno istražene slivove. Tako npr. auto-korelacijska i kros-korelacijska funkcija su pronašle primjenu pri: istraživanju transportnih svojstava i dinamike mutnoće vode (Bouchaou i dr., 2002; Massei i dr., 2006), karakterizaciji provodnih sustava u špiljama (Tam i dr., 2004), analizi interakcije rijeka i krških akvifera tijekom poplava (Bailly-Comte i dr., 2008), istraživanju procesa na krškoj površini (Jemcov i Petrič, 2009; Jukić i Denić-Jukić, 2008), analizi utjecaja pljuskova (Herman i dr., 2009), analizi varijabilnosti vremena zadržavanja vode i vremena odgovora krških akvifera (Bailly-Comte i dr., 2011; Delbart i dr., 2014), istraživanju hidrogeoloških veza u krškim mrežama (Gill i dr., 2013), te analizu dotoka (Mayaud i dr., 2014).

Metode analize vremenskih serija su se koristile u hidrološkim istraživanjima dva ili više krških izvora s različitom svrhom i ciljem, npr.: analiza vremenskih serija dvaju krških izvora u Francuskoj i dvaju krških izvora u Španjolskoj u cilju uspoređivanja izvora (Padilla i Pulido-

Bosch, 1995), određivanje varijabilnosti protoka za tri krška izvora u Bugarskoj (Pulido-Bosch i dr., 1995), analiza karakteristika dva krška izvora u centralnoj Italiji (Angelini, 1997), analiza odgovora dvaju krških izvora na oborine i evaporaciju (Samani, 2001), određivanje hidrodinamičkih karakteristika dvaju krških izvora u Grčkoj (Panagopoulos i Lambrakis, 2006), procjena parametara modela podzemnog otjecanja dvaju krških izvora (Jukić i Denić-Jukić, 2008).

Tehnike analize vremenskih serija u hidrologiji krša na dva ili više izvora u cilju utvrđivanja hidroloških odnosa izvora nisu primijenjene budući da običnom analizom vremenskih serija to nije moguće.

Općenito, koeficijent korelacije kvantificira linearnu vezu između dvije vremenske serije (Mangin, 1982; Sun i dr., 2013; Zhou i dr., 2014), međutim, ovaj koeficijent ne sadrži informaciju koja ukazuje na uzrok linearne veze (Barnard, 1982; Liang, 2014). Dakle, korelacija dviju vremenskih serija može biti rezultat neke treće vremenske serije koja kontrolira ili generira obje analizirane serije (Jukić i Denić-Jukić, 2011; 2015). Ovaj problem se rješava korištenjem koeficijenta parcijalne korelacije. Koeficijent parcijalne korelacije, mjeri linearnu vezu između dvije vremenske serije ovisno o linearnom utjecaju drugih (kontrolnih) vremenskih serija i kao takav sadrži novu informaciju koja može ukazati na odnose promatranih veličina. Broj kontrolnih vremenskih serija definira red parcijalne korelacije, tako da se pomoću ovih koeficijenata mogu odrediti parcijalne auto-korelacijske i kros-korelacijske funkcije prvog ili viših redova.

Parcijalna auto-korelacijska funkcija se koristi za identifikaciju reda auto-regresivnih procesa. Primjenjuje se u analizama hidroloških vremenskih serija i modeliranju za: procjenu utjecaja klime i ljudske intervencije na podzemne vode i njihove ekosustave (Gemitzi i Stefanopoulos, 2011), modeliranje transformacija oborina-protok (Wu i Chau, 2011), usporedbu neuralnih mreža i auto-regresijskih tehnika (Lohani i dr., 2012), predviđanje mjesečnog dotoka pomoću auto-regresivnih umjetnih neuralnih mreža (Valipour i dr., 2012; 2013), dugoročne prognoze suše (Belayneh i dr., 2014), razvijanje teorije entropije za predviđanje mjesečnih tokova (Cui i Sinhg, 2015), itd.

Koeficijenti parcijalne korelacije prvog reda i viših redova u hidrologiji i drugim poljima znanosti vezanim za vodne resurse su korišteni za: pronalaženje analitičkih rješenja transporta otopljenih tvari u heterogenim sustavima (Bellin i Rinaldo, 1995), utvrđivanje točke izvora strujanja nitrata i fosfata (Vervier i dr., 1999), ispitivanje kovarijance između sastava izotopa kisika i količine kiše ili temperature (Treble i dr., 2005), utvrđivanje veza između trenda kod vremena otjecanja i trenda kod meteoroloških varijabli (oborina i temperatura) (Burn, 2008), selekciju ulaznih serija kod predviđanja kvantitete i kvalitete otjecanja oborinskih voda (He i dr.,

2001), određivanje odnosa parametara osjetljivosti u simulacijama prijenosa topline (Vandenbohede i dr., 2011), utvrđivanje odgovora baznog otjecanja u odnosu na klimatske promjene (Fan i dr., 2013).

Parcijalna korelacijska funkcija višeg reda može imati dva ili više argumenta koji predstavljaju vremenske korake između analiziranih vremenskih serija. Vrijednosti ove funkcije mogu se u nekim slučajevima prikazati u formi matrice. Parcijalna korelacijska matrica korištena je u raznim znanstvenim poljima, npr. (Ehrentreich, 1997; Enquist i dr., 2008; Stark, 2006; Tkach i dr., 2007). U području hidrologije krša, parcijalne korelacijske funkcije višeg reda su tek nedavno analizirane i primijenjene (Jukić i Denić-Jukić, 2015). Rezultati su pokazali napredak u: (1) identifikaciji utjecaja različitih vremenskih serija na brzo, srednje i bazno otjecanje, (2) detekciji sezonskih utjecaja međuslivnih tokova na otjecanje i (3) procjeni pamćenja sustava. Kompleksnije forme parcijalnih korelacijskih funkcija (s tri ili više argumenata) do sada nisu primijenjene u hidrologiji, budući da je često teško pronaći odgovarajuće kontrolne vremenske serije i dodijeliti fizičko značenje vrijednostima takvih funkcija.

Parcijalna analiza vremenskih serija u hidrologiji krša na dva ili više izvora u cilju utvrđivanja funkcioniranja pojedinog izvora i hidroloških odnosa izvora, do sada nije provedena kao ni primjena protoka kao kontrolne vremenske serije.

2 METODE ANALIZE

2.1 UVOD

Karakterizacija vodonosnika temelji se na znanju unutarnjih parametara, propusnosti, transmisivnosti i geometrije, te njihovim graničnim uvjetima (Mangin, 1994). Međutim, mehanizmi geneze i razvoja krških sustava (karstifikacija) dovode do vrlo diskontinuiranog i heterogenog medija, ne samo u njegovoj prostornoj strukturi, već i u njegovom vremenskom funkcioniranju (Mangin, 1975; Labat, 2000). Na takvim slivnim područjima tumačenja hidroloških, geoloških i hidrogeoloških istraživačkih metoda su ograničena zbog ograničenog opsega istraživanja takvih metoda. Pokazalo se, međutim, da se mogu provesti preliminarne studije temeljene na tehnikama analize vremenskih serija kako bi se postiglo osnovno razumijevanje funkcioniranja krškog sustava.

Walliser (1977) je dao definiciju krškog sustava kao crne kutije, čije bi se funkcioniranje moglo proučavati kroz odnose ulaznih i izlaznih vremenskih serija sustava. Analiza vremenskih serija (Box i Jenkins, 1974) ima široku primjenu u području hidrologije krša. Prvotno ju je primjenio Mangin (1971, 1975, 1981, 1984), a zatim je uslijedila daljnja primjena i razvoj ove metode od strane mnogobrojnih autora (npr. Benavente i dr., 1985; Grasso i Jeannin, 1994; Padilla i Pulido-Bosch, 1995; Angelini, 1997; Eisenlohr i dr., 1997; Larocque i dr., 1998; Labat i dr., 2000; Samani, 2001; Amraoui i dr., 2003; Jukić i Denić-Jukić, 2004; Mathevet i dr., 2004;

Rahnemaei i dr., 2005; Valdes i dr., 2005, 2006; Massei i dr., 2006; Panagopoulos i Lambrakis, 2006; Novel i dr., 2007; Bailly-Comte i dr., 2008; Covington i dr., 2009; Herman i dr., 2009; Jemcov i Petrič, 2009; Fiorillo i Doglioni, 2010; Jemcov i Petrič, 2010; Kovačić, 2010b; Terzić i dr., 2012; Delbart i dr., 2014; Mayaud i dr., 2014; Katsanou i dr., 2015). Sve ove studije, koristeći različite hidrološke podatke (protok, oborine, električnu provodljivost, temperaturu, mutnoću), dokazale su korisnost analize vremenskih serija kao samostalne ili komplementarne metode u analizama funkcioniranja, hidrodinamičkog ponašanja i dinamike krških izvora i pripadajućih vodonosnika.

U ovoj disertaciji korištene su klasične metode analize vremenskih serija (auto-korelacija i kros-korelacija) te metode parcijalne korelacijske analize (parcijalna auto-korelacija i parcijalna kros-korelacija). Budući da su vremenske serije oborina i protoka kao ulazno-izlazne vremenske serije promatranog sustava pod utjecajem raznih prostorno-vremenski promjenjivih procesa uključenih u transfer vode u hidrološkom ciklusu (Jukić i Denić-Jukić, 2011; Jukić i Denić-Jukić, 2015), efekti ovakvih procesa mogu biti obuhvaćeni auto-korelacijskim i kros-korelacijskim funkcijama. Primjenom parcijalne korelacijske analize pokazano je (Jukić i Denić-Jukić, 2011; Jukić i Denić-Jukić, 2015) da se efekti prostorno-vremenski promjenjivih procesa mogu odvojiti od funkcija korelacije. Parcijalna korelacijska analiza vremenskih serija implicira da utjecaj kontrolne vremenske serije na kros-korelacijsku funkciju između ulazne i izlazne vremenske serije može biti detektiran pomoću korelacijskog koeficijenta između ulazne i kontrolne vremenske serije, i kros-korelacijske funkcije između kontrolne i izlazne vremenske serije.

Parcijalna korelacijska analiza vremenskih serija ima dva značajna ograničenja u kvantitativnim analizama. Prvo ograničenje je pouzdanost koja se povećava proporcionalno veličini uzorka. Druga ograničenje je linearnost. Izračun parcijalnog korelacijskog koeficijenta temelji se na običnom koeficijentu korelacije, koji pretpostavlja linearni odnos. Međutim, ovo ograničenje nije toliko važno u kvalitativnim analizama, gdje je cilj utvrditi ponašanje sustava i razloge koji upravljaju takvim ponašanjem, gdje točne kvantitativne vrijednosti nisu prioritet (Jukić i Denić-Jukić, 2015).

2.2 KORELACIJSKA ANALIZA

Primjena obične korelacijske analiza na krškim vodonosnicima (npr. Mangin, 1984; Padilla i Pulido-Bosch, 1995; Larocque i dr., 1998; Bouchaou i dr., 2002; Panagopoulos i Lambrakis, 2006) kvantificira linearnu ovisnost sukcesivnih vrijednosti tijekom određenog vremenskog razdoblja.

Kovarianca između dviju vremenskih serija x_t i y_{t+k} , duljine uzorka n , gdje je $t = 1, 2, \dots, n$, dana je prema izrazu (Jukić i Denić-Jukić, 2015):

$$c_{xy_k} = \frac{1}{n} \sum_{t=1}^{n-k} (x_t - \mu_x)(y_{t+k} - \mu_y) , \quad (1)$$

gdje je k vremenski korak μ_x i μ_y , a μ_x i μ_y predstavljaju srednje vrijednosti serija x_t i y_t . Koeficijent korelacije između x_t i y_{t+k} dobiva se prema izrazu:

$$r_{xy_k} = \frac{c_{xy_k}}{\sigma_x \sigma_y} , \quad (2)$$

gdje su σ_x i σ_y standardne devijacije serija x_t i y_t .

Za vremenske korake $k = 0, \pm 1, \pm 2, \dots, \pm m$, koristeći jednadžbu (1), može se izračunati slijed koeficijenata c_{xy_k} , koji predstavljaju vrijednosti diskretne funkcije s argumentum k , koja se naziva funkcija kovarijance $c_{xy}(k)$ (Jenkins i Watts, 1968; Shumway i Stoffer, 2000; Box i dr., 2008). Točka skraćanja m (eng. truncation point) određuje veličinu intervala na kojem se vrši analiza, čime se zaobilaze mogući problemi kao efekt memorije godišnjih ili više-godišnjih ponavljanja (Larocque i dr., 1998). Koristeći funkciju kovarijance, kros-korelacijska funkcija između serija x_t i y_t se definira izrazom:

$$r_{xy}(k) = \begin{cases} \frac{c_{xy}(k)}{\sigma_x \sigma_y}; & k \geq 0 \\ \frac{c_{xy}(-k)}{\sigma_x \sigma_y}; & k < 0 \end{cases} , \quad (3)$$

gdje za $k = 0$, $r_{xy} = r_{xy}(0)$ predstavlja koeficijent korelacije između serija x_t i y_t .

Prema istim načelima, mogu se definirati funkcije auto-kovarijance $c_{xx}(k)$ i $c_{yy}(k)$ i auto-korelacijske funkcije:

$$r_{xx}(k) = \frac{c_{xx}(k)}{\sigma_x^2}, \quad r_{yy}(k) = \frac{c_{yy}(k)}{\sigma_y^2}, \quad (4)$$

U hidrologiji krša, analiza hidroloških vremenskih serija zahtijeva matematičku analizu odgovora krškog sustava na punjenje (oborine, koncentrirana infiltracija preko ponora) i posredno pruža informacije o strukturi i funkcioniranju krških vodonosnika (Box i Jenkins, 1970; Mangin, 1984; Box i dr., 1994).

Ako postoji predvidljivost temeljena na prošlim vrijednostima vremenske serije prema njenim sadašnjim vrijednostima, vremenska serija je autokorelirana (Krešić i Stevanović, 2010). Funkcija autokorelacije, predstavljena auto-korelogramom, kvantificira pamćenje sustava, definiranog kao vrijeme u kojem funkcija autokorelacije postiže unaprijed određenu vrijednost, obično 0.2 (Mangin, 1984; Benavente i dr., 1985). Pamćenje sustava odražava inerciju sustava. Nagib korelograma određen je odgovorom sustava na događaj i daje neizravne podatke o retencijskim sposobnostima sustava i njegovom stupnju karstifikacije. Općenito, visoka vrijednost pamćenja sustava ukazuje na dugotrajni utjecaj određenog događaja na sustav, što se često odnosi na velike retencijske sposobnosti samog sustava (Mangin, 1984). Suprotno tome, niska vrijednost pamćenja sustava ukazuje na dobro razvijenu kršku mrežu sa niskim retencijskim sposobnostima. Nagib korelograma takvih krških vodonosnika polagano opada. Takve sustave karakterizira mreža manjih pukotina kroz koje voda teče pri mnogo nižim brzinama. Dobro razvijeni krški vodonosnik bez značajnih retencijskih sposobnosti odgovara niskom pamćenju sustava (Larocque i dr., 1998; Panagopoulos i Lambrakis, 2006).

Kros-korelacijska funkcija koristi se za određivanje odnosa između ulaznih serija x_t i izlaznih serija y_t (Mangin, 1981, 1982, 1984; Grasso, 1998; Grasso i Jeannin, 1998; Jukić, 2005). Ako je ulazna serija slučajna, kros-korelacijska funkcija predstavlja impulsni odgovor sustava. U drugim slučajevima, kros-korelacijska funkcija daje informacije o transformaciji signala unutar sustava. Valja napomenuti da nelinearna i vremenska varijanta ponašanja sustava i vremenske varijacije ulaznog signala mogu značajno utjecati na oblik kros-korelacijske funkcije. Vrijednosti koje izlaze van granica intervala povjerenja, obično se uzima vrijednost $\pm 2/\sqrt{n}$ (Diggle, 1990;

Chatfield, 2004; Lee i dr., 2006), nazivaju se statistički značajne vrijednosti. Općenito, statistički značajne vrijednosti za $k > 0$ popraćene statistički beznačajnim vrijednostima za $k < 0$, potvrđuju da je izlazna serija y_t fizikalna posljedica ulazne serije x_t (Jukić i Denić-Jukić, 2015). Statistički značajne vrijednosti za $k < 0$, označavaju da sustav naizgled može predvidjeti utjecaj ulazne serije x_t , ili da je serija periodična. Odnosno, može postojati i treći signal koji upravlja ulaznim signalom ili procesom transformacije.

2.3 PARCIJALNA KORELACIJSKA ANALIZA

Koeficijent parcijalne korelacije, mjeri linearnu vezu između dvije vremenske serije ovisno o linearnom utjecaju drugih (kontrolnih) vremenskih serija i kao takav sadrži novu informaciju koja može ukazati na odnose promatranih veličina.

Za ulaznu vremensku seriju x_t , izlaznu vremensku seriju y_t te kontrolnu vremensku seriju z_t , koja kontrolira proces transformacije ulazne u izlaznu vremensku seriju ($t=1,2,\dots,n$), linearni efekt kontrolne serije z_t može se isključiti iz kros-korelacijskog koeficijenta r_{xy} koristeći sljedeću jednadžbu za parcijalni koeficijent korelacije (Jukić i Denić-Jukić, 2015):

$$r_{xy|z} = \frac{r_{xy} - r_{xz} \cdot r_{zy}}{\sqrt{(1 - r_{xz}^2)} \sqrt{(1 - r_{zy}^2)}}, \quad (5)$$

gdje je r_{xz} koeficijent korelacije između serija x_t i z_t , a r_{yz} koeficijent korelacije između serija y_t i z_t . Linearni odnosi između x_t i z_t i između y_t i z_t uklanjaju se iz koeficijenta korelacije r_{xy} oduzimanjem i razlika se normalizira. Rezultirajući koeficijent $r_{xy|z}$ kreće se od -1 do +1. Treba naglasiti da je koeficijent parcijalne korelacije $r_{xy|z}$ ekvivalentan koeficijentima korelacije između reziduala vremenskih serija x_t i y_t nakon regresije na kontrolnoj seriji z_t .

Jednadžbe parcijalnih korelacijskih koeficijenata višeg reda mogu se dobiti kao izravna proširenja parcijalnih korelacijskih koeficijenata prvog reda (jed. (5)). Ako je potrebno protumačiti utjecaj dviju kontrolnih serija, npr. z_t^1 i z_t^2 , sumarni utjecaj može se ukloniti iz koeficijenta korelacije koristeći:

$$r_{xy|z^1z^2} = \frac{r_{xy|z^1} - r_{xz^2|z^1} \cdot r_{z^2y|z^1}}{\sqrt{(1 - r_{xz^2|z^1}^2)} \sqrt{(1 - r_{z^2y|z^1}^2)}}, \quad (6)$$

gdje je $r_{xy|z^1z^2}$ parcijalni koeficijent korelacije drugog reda izračunat pomoću parcijalnih koeficijenata prvog reda $r_{xy|z^1}$, $r_{xz^2|z^1}$ i $r_{z^2y|z^1}$. U jednadžbi (6) prvo se uzima u obzir utjecaj kontrolne serije z_t^1 procjenom $r_{xy|z^1}$ a zatim utjecaj kontrolne serije z_t^2 procjenom $r_{xz^2|z^1}$ i $r_{z^2y|z^1}$. Kontrolne serije su komutativne. Isti rezultat se dobiva ako je redoslijed obrnut, uzimajući prvo u obzir utjecaj od z_t^2 , a zatim od z_t^1 .

Daljnijim proširenjem, ukoliko se trebaju objasniti utjecaji tri kontrolne serije, postoje tri koeficijenta parcijalne korelacije drugog reda za procjenu. Na isti način, za N kontrolnih serija $z_t^1, z_t^2, \dots, z_t^N$, parcijalni korelacijski koeficijent N -tog reda dobiva se prema izrazu:

$$r_{xy|z^1 \dots z^N} = \frac{r_{xy|z^1 \dots z^{N-1}} - r_{xz^N|z^1 \dots z^{N-1}} \cdot r_{z^N y|z^1 \dots z^{N-1}}}{\sqrt{(1 - r_{xz^N|z^1 \dots z^{N-1}}^2)} \sqrt{(1 - r_{z^N y|z^1 \dots z^{N-1}}^2)}}, \quad (7)$$

Ako je serija x_t korelirana sa y_{t+k} , a z_t korelira sa x_t i sa y_{t+k} , parcijalni koeficijent korelacije poprima oblik:

$$r_{xy_k|z} = \frac{r_{xy_k} - r_{xz} \cdot r_{zy_k}}{\sqrt{(1 - r_{xz}^2)} \sqrt{(1 - r_{zy_k}^2)}}, \quad (8)$$

gdje je r_{xy_k} koeficijent korelacije između x_t i y_{t+k} (jed. (2)), dok je r_{zy_k} koeficijent korelacije između z_t i y_{t+k} .

Za $k = 0, \pm 1, \pm 2, \dots, \pm m$, jednadžba (8) poprima sljedeći oblik:

$$r_{xy|z}(k) = \frac{r_{xy}(k) - r_{xz} \cdot r_{zy}(k)}{\sqrt{(1 - r_{xz}^2)} \sqrt{(1 - r_{zy}^2(k))}}, \quad (9)$$

gdje su $r_{xy}(k)$ i $r_{zy}(k)$ kros-korelacijske funkcije za korak k . Jednadžba (9) daje diskretnu funkciju parcijalne korelacije s jednim argumentom, vremenskim korakom k . Pomoću ovog postupka linearni efekt kontrolne serije z_t uklanja se iz kros-korelacijske funkcije $r_{xy}(k)$.

Korištenjem kontrolne serije koja nije korelirana s ulaznom i izlaznom serijom (npr. bijeli šum), u jednadžbi (9) vidljiv je prijelaz iz parcijalne kros-korelacijske funkcije u kros-korelacijsku funkciju: ako je $r_{xz} \rightarrow 0$ i $r_{zy}(k) \rightarrow 0$, onda $r_{xy/z}(k) \rightarrow r_{xy}(k)$.

Posebni oblici jednadžbe (7) mogu se dobiti ako se uklone linearni efekti kontrolnog signala z_t iz auto-korelacijskih funkcija $r_{xx}(k)$ i $r_{yy}(k)$. Rezultati su parcijalne auto-korelacijske funkcije:

$$r_{xx|z}(k) = \frac{r_{xx}(k) - r_{xz} \cdot r_{zx}(k)}{\sqrt{(1 - r_{xz}^2)} \sqrt{(1 - r_{zx}^2(k))}}, \quad (10)$$

$$r_{yy|z}(k) = \frac{r_{yy}(k) - r_{yz} \cdot r_{zy}(k)}{\sqrt{(1 - r_{yz}^2)} \sqrt{(1 - r_{zy}^2(k))}}. \quad (11)$$

Općenito, za set kontrolnih vremenskih serija $Z_t \equiv \{ z_t^1, z_t^2, \dots, z_t^N \}$, parcijalna kros-korelacijska funkcija se dobiva kao proširenje jednadžbe (7):

$$r_{xy|z^1 \dots z^N}(k) = \frac{r_{xy|z^1 \dots z^{N-1}}(k) - r_{xz^N|z^1 \dots z^{N-1}} \cdot r_{z^N y|z^1 \dots z^{N-1}}(k)}{\sqrt{(1 - r_{xz^N|z^1 \dots z^{N-1}}^2)} \sqrt{(1 - r_{z^N y|z^1 \dots z^{N-1}}^2(k))}}, \quad (12)$$

Slijedeći isti princip mogu se definirati parcijalne auto-korelacijske funkcije N -tog reda $r_{xx|Z}(k)$ i $r_{yy|Z}(k)$. Odgovarajuće parcijalne kovarijance i auto-kovarijance N -tog reda su:

$$c_{xy|Z}(k) = r_{xy|Z}(k) \sigma_x \sigma_y, \quad (13)$$

$$c_{xx|Z}(k) = r_{xx|Z}(k) \sigma_x^2, \quad (14)$$

$$c_{yy|z}(k) = r_{yy|z}(k)\sigma_y^2. \quad (15)$$

Vjerojatnost pogreške koeficijenta parcijalne korelacije je ista kao za ukupnu korelaciju izračunatu iz uzorka iste veličine, tj. za slučajnu vremensku seriju približna 95% granica pouzdanosti je $\pm 2/\sqrt{n}$. Uočene vrijednosti koeficijenata parcijalne korelacije, odnosno koeficijenti korelacije koji padaju izvan tih granica, značajno su različite od nule na razini od 5% (Chatfield 2004).

2.4 OSNOVE PRAKTIČNE PRIMJENE PARCIJALNE KORELACIJSKE ANALIZE

Osnove praktične primjene parcijalne korelacijske analize preuzete su iz rada Jukić i Denić-Jukić (2015).

Slivno područje krškog izvora podijeljeno je na dijelove ovisno o položaju meteoroloških stanica. Svaki dio se smatra vremenski promjenjivim sustavom gdje je ulazna vremenska serija x_t oborina mjerena na meteorološkoj stanici, a izlazna vremenska serija y_t predstavlja protok samog izvora. Na susjednim meteorološkim stanicama može postojati set kontrolnih signala Z_t , koji se sastoji od temperature zraka, relativne vlažnosti zraka i oborina. Ulazna vremenska serija x_t i set kontrolnih signala Z_t ovise o hipotetski neopaženoj seriji w_t koja predstavlja atmosferske procese na krškoj površini. Vremenska serija w_t se može smatrati neovisnom serijom koja generira x_t i Z_t , što podrazumijeva da vremenska promjenjivost x_t i Z_t ovise o w_t . Pretpostavlja se da vremensku promjenjivost sustava kontrolira Z_t , što znači da protok invarijantno ovisi o oborini (mjerenoj na odabranoj meteorološkoj stanici) i da druge vremenske serije (temperatura zraka, relativna vlažnost zraka, oborina na drugim stanicama) doprinose vremenskoj promjenjivosti ponašanja sustava.

Crtež 2.1 prikazuje shematsko objašnjenje odnosa između ulazne vremenske serije x_t , izlazne vremenske serije y_{t+k} , proizvoljne kontrolne vremenske serije z_t od seta Z_t i hipotetske neopažene serije w_t . Općenito, fizikalna objašnjenja korelacija $r_{xy}(k)$, r_{xz} i $r_{zy}(k)$ (Crtež 2.1) ovise o uzročnoj povezanosti između serija x_t , y_{t+k} i z_t . Postoje dvije osnovne vrste odnosa između vremenskih serija: kauzalni (uzročni) i ne-kauzalni (ne-uzročni). Kauzalni odnos označava da jedna vremenska serija ima izravan utjecaj na drugu. Na primjer, odnos između oborina i protoka je kauzalni jer je protok direktna fizikalna posljedica oborine, tj. protok nije moguć bez oborine. U ne-kauzalnim odnosima, odnos između dvije vremenske serije nije rezultat direktnog utjecaja jedne serije na drugu. Na primjer, temperatura zraka i relativna vlažnost zraka imaju indirektne utjecaje na protok jer je protok moguć i bez utjecaja temperature i relativne vlažnosti. U najekstremnijem slučaju ne-kauzalnog odnosa, dvije serije su međusobno povezane bez utjecaja jedne serije na drugu. Veza između serija može postojati iz razloga što su obje serije fizikalna posljedica istog procesa. Na primjer, postoji prividna veza između oborina i temperature zraka, između oborina i relativne vlažnosti i između oborina promatranih na dvije susjedne meteorološke stanice.

Crtež 2.1 Shematsko objašnjenje odnosa između vremenskih serija (prema Jukić i Denić-Jukić, 2015): x_t - ulazna vremenska serija, y_{t+k} - izlazna vremenska serija, z_t - kontrolna vremenska serija, w_t - hipotetska neopažena vremenska serija.

Na crtežu 2.1, ulazna serija x_t , i kontrolna serija z_t su fizikalne posljedice hipotetske neopažene serije w_t te je odnos između x_t i z_t prividan. Odnos između z_t i y_{t+k} je arbitraran, ovisno o odabranoj kontrolnoj seriji. Izlazna serija y_{t+k} je fizikalna posljedica ulazne serije x_t , što pretpostavlja da y_t ovisi o x_t , a jednosmjerna veza između x_t i y_{t+k} je teoretski kauzalna. Odnosno, veza između x_t i y_{t+k} je samo parcijalno kauzalna zbog postojećeg odnosa između z_t i y_{t+k} , što modificira y_{t+k} , tj. kros-korelacijska funkcija $r_{xy}(k)$ sadrži odnos između x_t i y_{t+k} i između z_t i y_{t+k} . Objašnjenje ovih utjecaja podrazumijeva određivanje parcijalne kros-korelacijske funkcije $r_{xy/z}$, koja opisuje kauzalni dio kros-korelacijske funkcije $r_{xy}(k)$.

2.5 FUNKCIJSKE OZNAKE I OBJAŠNJENJE ODNOSA KORELACIJA-PARCIJALNA KORELACIJA

U sljedećim analizama x označava ulaznu vremensku seriju, y označava izlaznu vremensku seriju i z označava kontrolnu vremensku seriju. Korištene se sljedeće kratice za funkcije:

- ACF- auto-korelacijska funkcija,
- CCF- kros-korelacijska funkcija,
- PACF- parcijalna auto-korelacijska funkcija,
- PCCF- parcijalna kros-korelacijska funkcija.

Primjenjeno je sljedeće pravilo pri uvođenju oznaka parcijalnih funkcija korelacije (preuzeto od Jukić i Denić-Jukić, 2015):

$$\text{NAZIV } (x-y/z) \quad (10)$$

Gdje je NAZIV kratica za funkciju. Primjerice, PCCF (D-J|Ž) označava parcijalnu kros-korelacijsku funkciju, pri čemu je ulazna vremenska serija oborina na meteorološkoj stanici Dugopolje (D), a izlazna vremenska serija je protok izvora Jadra (J). Kontrolna vremenska serija je protok izvora Žrnovnica (Ž).

Za bolje razumijevanje prezentiranih rezultata tumačenja mogućih odnosa (Garson, 2012) između kros-korelacijske funkcije CCF ($x-y$) i parcijalne kros-korelacijske funkcije PCCF ($x-y/z$) su:

- $\text{PCCF } (x-y/z) < \text{CCF } (x-y) \rightarrow$ kontrolna vremenska serija z ima parcijalan utjecaj na odnos između vremenskih serija x i y ,
- $\text{PCCF } (x-y/z) = \text{CCF } (x-y) \rightarrow$ kontrolna vremenska serija z nema utjecaj na relaciju između vremenskih serija x i y ,
- $\text{PCCF } (x-y/z) > \text{CCF } (x-y) \rightarrow$ kontrolna vremenska serija z *kvari*, tj., ima utjecaj supresije na odnos vremenskih serija x i y ,
- $\text{PCCF } (x-y/z) = 0 \rightarrow$ kontrolna vremenska serija z u potpunosti opisuje relaciju između vremenskih serija x i y .

Gore navedeno se može primijeniti na odnose između auto-korelacijskih i parcijalnih auto-korelacijskih funkcija, budući da je parcijalna auto-korelacijska funkcija posebn oblik parcijalne kros-korelacijske funkcije.

3 HIDROGEOLOŠKE KARAKTERISTIKE SLIVA IZVORA JADRA I ŽRNOVNICE

3.1 HIDROLOŠKE KARAKTERISTIKE JADRA I ŽRNOVNICE

Područje sliva izvora Jadra i Žrnovnice jedno je od većih vodonosnih sustava Dinarida, kao i dio vodonosnog sustava sliva rijeke Cetine (slike 3.1 i 3.2) (Kapelj i dr., 2012; Biondić i Biondić, 2014; Loborec i Đurin, 2016). Površina sliva Jadra i Žrnovnice prema dosadašnjim istraživanjima (Fritz, 1979; Fritz i dr., 1988; Bonacci i dr., 1995; Bonacci i Roje-Bonacci, 1996; Fritz i Kapelj, 1998; Kapelj i dr., 2008) zauzima površinu između 250 i 500 km².

Podaci o hidrološkim i hidrogeološkim obilježjima sliva izvora Jadra i Žrnovnice u narednom tekstu ovog poglavlja preuzeti su iz radova: Stepinac (1983), Bonacci (1987), Bonacci i Roje-Bonacci (1996), Denić-Jukić (2002), Kapelj i dr. (2006), Bojanić (2011) i Kapelj i dr. (2012).

Slika 3.1 Položaj sliva i prikaz izvora Jadra i Žrnovnice (Loborec i Đurin, 2016).

Slika 3.2 Hidrogeološka skica sliva rijeke Cetine (Biondić i Biondić, 2014).

Izgradnjom akumulacija na rijeci Cetini izmijenili su se prirodni uvjeti istjecanja na izvorima Jadro i Žrnovnica. Poseban utjecaj akumulacija (Peruća, Prančevići, Đale) vidljiv je u režimu istjecanja izvora Žrnovnice koji je prije izgradnje tijekom razdoblja hidroloških minimuma presušivao. Došlo je do povećanja minimalnih protoka u sušnom razdoblju.

Stepinac (1983) procjenjuje da se na potezu od Trilja do Blata na Cetini iz korita rijeke Cetine i pripadajućeg sliva gubi oko $5,1 \text{ m}^3/\text{s}$ vode, s tim da se dio tih voda od oko $2,8 \text{ m}^3/\text{s}$ ponovno vraća u Cetinu nizvodno, dok se preostali dio gubi. Prema Stepincu ta voda prihranjuje vrela i vrulje duž morske obale među kojima i izvore Jadra i Žrnovnice.

Bonacci (1987) navodi egzaktno podatke o promjenama hidrološkog režima izvora Jadra do kojih je došlo nakon izgradnje akumulacija Prančevići (1962), Buško Blato (1973) i Đale (1986). Navodi da je srednji protok na postaji Vidovića most prije izgradnje akumulacija iznosio $5,4 \text{ m}^3/\text{s}$, a nakon izgradnje $8,8 \text{ m}^3/\text{s}$.

Bonacci i Roje-Bonacci (1996) za razdoblje od 1950. do 1985. navode da je uočen blagi porast minimalnih, maksimalnih i srednjih vodostaja Jadra na mjernom profilu Vidovića most. Za isto razdoblje ne postoje opažanja na Žrnovnici.

Prema Denić-Jukić (2002) izvor Jadra je pod utjecajem stalnih pritjecanja izvan slivnog područja. Srednja višegodišnja pritjecanja su procijenjena u iznosu od oko $5 \text{ m}^3/\text{s}$, što je oko 50 % svih količina voda koje istječu iz tog izvora. Obzirom na količine pritjecanja i njihovu kontinuiranost, pretpostavlja se da ta pritjecanja dolaze iz rijeke Cetine, njenog slivnog područja, ili možda iz područja akumulacije Buško Blato.

Vodni potencijal rijeke Jadro formira se od podzemnog dotoka iz okršenog podzemlja i površinskog dotoka s direktnog sliva. Izvor Jadra smješten je u podnožju planine Mosor na visini oko 33,0 m n.m. Područjem grada Solina rijeka Jadro prolazi cijelim svojim tokom ukupne dužine 4,2 km, i ulazi u more na istočnom rubu Kaštelanskog zaljeva. Jadro prima bujične vode pet pritoka od kojih su najjače Rupotina i Poklinovac. Regulacijskim radovima dosada nije zaustavljena erozija zemljišta niti je smanjeno donošenje nanosa u Jadro.

Izvor Jadra kaptiran je za vodoopskrbu još od rimskog doba. Voda se do grada Splita doprema pomoću Dioklecijanovog kanala (danas se koristi samo dio kanala do crpne stanice Ravne njive) propusne moći 550 l/s, i novog betonskog (Splitskog) kanala propusne moći 1350 l/s. Najmanja izdašnost Jadra je u kolovozu i rujnu kada srednji mjesečni protok može pasti na $4,0 \text{ m}^3/\text{s}$ (Kapelj i dr., 2006).

Krški izvor Žrnovnica zračnom linijom je udaljen od izvora Jadra 4200 m (Bonacci i Andrić, 2015). Izvorište Žrnovnice se sastoji od nekoliko manjih izvora koji se javljaju na širem području u visinskom rasponu od 77,0 do 90,0 m n.m. Uočeno je šest povremenih i tri stalna krška vrela. Površina na kojoj se nalazi devet izvora iznosi oko 400 m². Izvorišne vode se djelomično koriste za vodoopskrbu naselja Žrnovnice i za navodnjavanje okolnog zemljišta. Rijeka Žrnovnica ima nekoliko bujičnih pritoka koji su uglavnom suhi veći dio godine. Ukupna dužina Žrnovnice od izvora do ušća u more iznosi oko 4,5 km. Protoci joj značajno i brzo variraju ovisno o količini oborina na slivu (Kapelj i dr., 2012).

Jadranski tip mediteranske klime s blagim kišnim zimama i sušnim ljetima vlada unutar pretpostavljenih granica sliva (Denić-Jukić, 2002). U tablici 3.1 dane su karakteristične vrijednosti oborina sa sedam mjernih postaja (Muć, Dugopolje, Sinj, Dicmo, Prančevići, Bisko i Lećevica), karakteristične vrijednosti temperature i relativne vlažnosti za stanicu Sinj za razdoblje 1995.-2015., koristeći dostupne dnevne podatke.

Prosječni srednji protok izvora Jadra u razdoblju 1995.-2005. iznosi 9.96 m³/s a izvora Žrnovnice 1.9 m³/s. Maksimalni izmjereni protok za izvor Jadra iznosio je 70.06 m³/s, a minimalni izmjereni protok iznosio je 3.72 m³/s. Za izvor Žrnovnice maksimalni izmjereni protok iznosio je 17.00 m³/s, a minimalni izmjereni protok iznosio je 0.31 m³/s. U tablici 3.2 dane su karakteristične vrijednosti za opažena otjecanja izvora Jadra i Žrnovnice za razdoblje 1995.-2015.

Tablica 3.1 Osnovne statističke karakteristike dnevnih vremenskih serija oborina, temperature i relativne vlažnosti, 1995.-2015. (minimum, maksimum, srednja višegodišnja vrijednost i standardna devijacija)

	Oborine (mm)							Temperatura zraka (°C)	Relativna vlažnost (%)
	Muč	Dugopolje	Sinj	Dicmo	Prančevići	Bisko	Lečevica	Sinj	Sinj
Min.	-	-	-	-	-	-	-	-7.2	22
Max.	139.7	154.3	153.4	185.1	175.0	198.7	145.0	30.4	100
Sred.	1319.1	1316.6	1182.5	1226.6	1585.2	1554.1	1315.4	13.10	68.89
St.dev.	9.8	10.5	8.7	9.4	12.8	12.4	10.5	7.63	14.72

Tablica 3.2 Osnovne statističke karakteristike dnevnih vremenskih serija protoka, 1995.-2015. (minimum, maksimum, srednja višegodišnja vrijednost i standardna devijacija)

	Protok (m ³ /s)			
	Min.	Max.	Sred.	St.dev.
Jadro	3.72	70.06	9.96	7.36
Žrnovnica	0.31	17.00	1.90	2.08

Na slikama 3.3.-3.9 prikazana je linearna regresija između srednjih godišnjih protoka izvora Jadra i Žrnovnice i ukupnih godišnjih oborina na postajama Muć, Dugopolje, Sinj, Dicmo, Prančevići, Bisko i Lečevica. Dobiveni rezultati pokazuju visoke vrijednosti korelacije ($R^2 \geq 0.8$) koja je pokazatelj izravnog utjecaja oborina sa navedenih postaja na protoke Jadra i Žrnovnice.

Slika 3.3 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Muć (1995.-2015.).

Slika 3.4 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Dugopolje (1995.-2015.).

Slika 3.5 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Sinj (1995.-2015.).

Slika 3.6 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Dicmo (1995.-2015.).

Slika 3.7 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Prančeviči (1995.-2015.).

Slika 3.8 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Bisko (1995.-2015.).

Slika 3.9 Linearna regresija između srednjih godišnjih protoka Q (m^3/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Lečevica (1995.-2015.).

3.2 HIDROGEOLOŠKA I GEOLOŠKA OBILJEŽJA SLIVA

Podaci o hidrogeološkim i geološkim obilježjima sliva su preuzeti od Kapelj i dr. (2012). Područje sliva izvora Jadra i Žrnovnice izgrađuje stijenska masa sastavljena od vapnenca, dolomita i laporovitih vapnenaca mezozojske, eocenske starosti te prostorno manje rasprostranjeni vapnenci perma. Klastične naslage u slivu su fliške naslage eocena, klastiti trijasa i paleocenski lapori. Stratigrafski najmlađe naslage su kvartarni deluvijalni sedimenti krških polja, pretežito siltozno-pjeskovitoga sastava s različitim udjelom ulomaka karbonatnih stijena. Izvori Jadra i Žrnovnice smješteni su u podnožju planina Mosor (1300 m nadmorske visine) i Kozjak (600 m nadmorske visine). Izvor Jadra nalazi se na 33 m nadmorske visine, a izvorište Žrnovnice s više mjesta istjecanja na 77 do 90 m nadmorske visine. U morfološkom smislu uočljiva je pojava izrazito raščlanjenog reljefa, posebno u području rasprostranjenja karbonatnih stijena. Između niza vrhova nadmorske visine od 550 do 680 m nalazi se više krških polja, uvala i zaravni na nadmorskim visinama od 300 do 350 m n.m.. Najveća krška polja su Mučko polje (cca 400 ha), Dicmansko polje (cca 300 ha), Dugopolje (cca 190 ha) i Konjsko polje (cca 150 ha). Nizovi

uzdignuća i depresija u sjeverozapadnom dijelu razmatranog područja imaju pravac pružanja sjeverozapad-jugoistok (tzv. pravac dinarskog pružanja), a idući prema istoku orijentacija morfoloških cjelina postupno prelazi u pravac istok-zapad (tzv. hvarsko pružanje). Morfološki uzdignute dijelove reljefa izgrađuju čvrste karbonatne stijene (vapnenci i dolomiti) u kojima su zastupljeni svi elementi krške morfologije, kao što su povremeni ponori, jame, spilje, vrtače, škrape, suhe doline, pojave strmo odsječenih padina itd. U morfološkim depresijama koje uglavnom izgrađuju klastične prašinasto glinovite naslage različite vrste i starosti mogu se uočiti manji terasni odsjeci, zatim pojave povremenih tokova i ponora, posebno u rubnim dijelovima polja. Karakteristična su i brojna sufozijska uleknuća u klastičnim naslagama krških polja. Vapnenci mezozoika i eocena su uglavnom dobro propusne stijene i imaju funkciju vodonosnika. Ovisno o zastupljenosti dolomitne i laporovite komponente smanjuje se propusnost vapnenaca u srednje propusne do slabo propusne stijene. Klastične naslage eocenskoga fliša, klastiti trijasa i paleocenski lapori su nepropusne stijene pa imaju funkciju potpunih ili relativnih hidrogeoloških barijera ovisno o njihovu prostornom položaju. Potpune hidrogeološke barijere usmjeravaju tokove podzemne vode, a ispod relativnih barijera podzemne vode nesmetano teku. Propusnost deluvijalnih sedimenata krških polja ovisi o njihovom pretežitom granulometrijskom sastavu, odnosno udjelu krupnozrnatih i sitnozrnatih čestica, fragmenata stijena i sadržaju glinovite komponente. Stoga zbog lateralne i vertikalne nehomogenosti sedimente krških polja u hidrogeološkom smislu smatramo propusnim naslagama (slika 3.10).

Područje sliva Jadra i Žrnovnice odlikuje se naglašenom razlomljenošću i tektonskom aktivnošću na što izravno upućuje stalno pojavljivanje potresa. Tektonska aktivnost rezultira i promjenama strukturnih odnosa, osobito sustava rasjeda i pukotina. Zbog važnosti određivanja recentnih geoloških strukturnih odnosa detaljno je razrađen strukturni sklop te prikazani podaci koji ukazuju na pomake struktura, aktivne rasjede i posebice sustave važne za moguću cirkulaciju podzemne vode. Tektonski su najaktivnije dionice rasjeda poprečnoga ili gotovo poprečnoga pružanja prema orijentaciji kompresijskoga stresa. Ovom prilikom na shematskom prikazu hidrogeološke karte sliva strukturni elementi su izostavljeni zbog bolje preglednosti područja i rezultata istraživanja.

Slika 3.10 Hidrogeološka karta sliva Jadra i Žrnovnice (prema Kadić i dr., 2015).

3.3 OSNOVNI STATISTIČKI PODACI ANALIZIRANOG RAZDOBLJA

Analiza vremenskih serija do sada se uglavnom primjenjivala za razdoblja od jedne hidrološke godine sa dnevnim ili satnim podacima (npr. Larocque i dr., 1998; Massei i dr., 2006; Herman i dr., 2009; Kovačić, 2010b; Terzić i dr., 2012), više uzastopnih hidroloških godina sa dnevnim podacima (npr. Benavente i dr., 1985; Padilla i Pulido-Bosch, 1995; Angelini, 1997; Eisenlohr i dr., 1997; Larocque i dr., 1998; Labat i dr., 2000; Samani, 2001; Amraoui i dr., 2003; Mathevet i dr., 2004; Rahnamaei i dr., 2005; Panagopoulos i Lambrakis, 2006; Novel i dr., 2007; Bailly-Comte i dr., 2008; Herman i dr., 2009; Jemcov i Petrič, 2009; Fiorillo i Doglioni, 2010; Jemcov i Petrič, 2010; Kovačić, 2010b; Delbart i dr., 2014; Katsanou i dr., 2015), a samo nekoliko studija primijenilo je metodu na vrlo kratko ili pojedinačno vremensko razdoblje sa satnim ili čak kraćim vremenskim nizom (npr. Valdes i dr., 2005, 2006; Bailly-Comte i dr., 2008; Covington i dr., 2009; Mayaud i dr., 2014).

U ovom radu analizirani period obuhvaća dvije uzastopne hidrološke godine:

- 1) sušnu hidrološku godinu od 20.10.2011. do 12.9.2012.
- 2) kišnu hidrološku godinu od 13.09.2012. do 09.09.2013.

Korišteni satni podaci su:

- vremenske serije oborina s meteoroloških stanica Vučevica (V), Dugopolje (D) i Tunel Konjsko (TK)
- srednja temperatura zraka (T) s meteoroloških stanica Vučevica, Dugopolje i Tunel Konjsko,
- srednja relativna vlažnost zraka (RH) s meteoroloških stanica Vučevica, Dugopolje i Tunel Konjsko,
- protok izvora Jadro (J),
- protok izvora Žrnovnica (Ž).

Na slikama 3.11. i 3.12 dani su prikazi satnih oborina na meteorološkim postajama Vučevica, Dugopolje i Tunel Konjsko, i satnih protoka izvora Jadro i Žrnovnica u sušnoj, odnosno, kišnoj hidrološkoj godini. Osnovne statističke karakteristike korištenih satnih podataka (oborine, temperatura, relativna vlažnost i protoci) dane su u tablici 3.3.

Slika 3.11 Satne oborine na postajama: a) Vučevica, b) Dugopolje i c) Tunel Konjsko, i satni protoci izvora d) Jadro i e) Žrnovnica u sušnoj hidrološkoj godini (20.10.2011.-12.9.2012.).

Slika 3.12 Satne oborine na postajama: a) Vučevica, b) Dugopolje i c) Tunel Konjsko, i satni protoci izvora d) Jadro i e) Žrnovnica u kišnoj hidrološkoj godini (13.09.2012. do 09.09.2013.).

Tablica 3.3 Osnovne statističke karakteristike korištenih satnih podataka

		20.10.2011. -12.09.2012. (<i>n</i> = 7873)				13.09.2012. - 09.09.2013. (<i>n</i> = 8689)			
		Min.	Max	Suma	St. dev.	Min.	Max	Suma	St. dev.
Oborine (mm)	Vučevica	-	13.8	549	0.6	-	57.1	1132	1
	Dugopolje	-	15.2	591	0.6	-	38.5	1576	1.2
	Tunel Konjsko	-	17.5	387	0.4	-	23.2	654	0.7
		Min.	Max	Sred.	St. dev.	Min.	Max	Sred.	St. dev.
Temperatura (°C)		-18.7	36.3	12.21	9.71	-8.9	36.9	13.59	8.18
Relativna valžnost (%)		11	96	51.8	21.81	13	100	63.24	21.4
Protok (m ³ /s)	Jadro	4.01	38.13	7.39	3.71	4.18	50.79	12.25	8.58
	Žrnovnica	0.36	13	1.28	1.31	0.36	16.1	2.26	2.57

4 REZULTATI ANALIZA I DISKUSIJA

4.1 KORELACIJSKA ANALIZA

4.1.1 Auto-korelacijska analiza

Auto-korelacijske funkcije (ACF) ulaznih vremenskih serija (oborina) i izlaznih vremenskih serija (protoci) u sušnoj hidrološkoj godini prezentirane su na slikama 4.1-4.5.

Funkcije auto-korelacije satnih oborina na sve tri meteorološke postaje naglo opadaju. Vremenske serije oborina nisu auto-korelirane nakon 15 sati na postaji Vučevica (slika 4.1), 13 sati na postaji Dugopolje (slika 4.2) i 9 sati na postaji Tunel Konjsko (slika 4.3).

Pamćenje sustava, definirano prema Manginu (1984) kao vremenski korak u kojem auto-korelacijska funkcija protoka izvora postaje manja od 0.2, iznosi 340 sati (oko 14 dana) za Jadro (slika 4.4) i 324 sata (oko 13 dana) za Žrnovnicu (slika 4.5) u sušnoj hidrološkoj godini. Za točku skraćanja m odabrano je 2000 sati, jer funkcije auto-korelacije i kros-korelacije za vremenske korake veće od 2000 sati sadrže samo informacije o sezonskoj periodičnosti (prema Jukić i Denić-Jukić, 2015).

Slika 4.1 Auto-korelacijska funkcija (ACF) vremenske serije oborina na postaji Vučevica (V) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.2 Auto-korelacijska funkcija (ACF) vremenske serije oborina na postaji Dugopolje (D) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.3 Auto-korelacijska funkcija (ACF) vremenske serije oborina na postaji Tunel Konjsko (TK) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.4 Auto-korelacijska funkcija (ACF) vremenske serije protoka Jadra (J) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.5 Auto-korelacijska funkcija (ACF) vremenske serije protoka Žrnovnice (Ž) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slike 4.6-4.10 prikazuju auto-korelacijske funkcije ulaznih i izlaznih vremenskih serija u kišnoj hidrološkoj godini. Auto-korelacijske funkcije ACF (V), ACF (D) i ACF (TK) vrlo brzo opadaju i pokazuju da vremenske serije oborina nisu auto-korelirane nakon vremenskog koraka od: 5 sati na postaji Vučevica (slika 4.6), 7 sati na postaji Dugopolje (slika 4.7) i 4 sata na postaji Tunel Konjsko (slika 4.8). Pamćenje sustava za izvor Jadra iznosi 1404 sata (oko 58 dana) (slika 4.9) te 1260 sati (oko 52 dana) za izvor Žrnovnice (slika 4.10). Za kišnu hidrološku godinu odabrana je točka skraćanja od 2000 sati kao i za sušnu hidrološku godinu.

Razlike između funkcija auto-korelacije vremenskih serija protoka prikazane na slikama 4.4 i 4.9, te 4.5 i 4.10, tj. razlike u rezultatima pamćenja sustava u sušnoj i kišnoj hidrološkoj godini, su uglavnom posljedica sezonske periodičke komponente u vremenskoj seriji protoka koja je uglavnom posljedica evapotranspiracije. Ta komponenta je puno izraženija u kišnoj hidrološkoj godini.

Rezultati pamćenja sustava Jadra pokazuju značajne razlike u odnosu na prethodne studije (Jukić i Denić-Jukić 2011, 2015) koje su primjenjivale auto-korelacijsku analizu na višegodišnje razdoblje dnevnih podataka bez uzimanja u obzir kišnih i suhih godišnjih doba. Korelacijska i parcijalna korelacijska analiza za višegodišnje razdoblje dnevnih podataka do sada nisu primijenjene za izvor Žrnovnice, stoga nije moguće dati usporedbu.

Slika 4.6 Auto-korelacijska funkcija (ACF) vremenske serije oborina na postaji Vučevica (V) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.7 Auto-korelacijska funkcija (ACF) vremenske serije oborina na postaji Dugopolje (D) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.8 Auto-korelacijska funkcija (ACF) vremenske serije oborina na postaji Tunel Konjsko (TK) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.9 Auto-korelacijska funkcija (ACF) vremenske serije protoka Jadra (J) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.10 Auto-korelacijska funkcija (ACF) vremenske serije protoka Žrnovnice (Ž) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

4.1.2 Kros-korelacijska analiza

U sušnoj hidrološkoj godini kros-korelacijske funkcije CCF (J-V), CCF (J-D) i CCF (J-TK) (slika 4.11) imaju oblik sličan kros-korelacijskim funkcijama CCF (Ž-V), CCF (Ž-D) i CCF (Ž-TK) (slika 4.12). Žrnovnica pokazuje bolju korelaciju sa oborinama sa svih postaja, što je najočitije u vrhovima kros-korelacijskih funkcija.

U slučaju kišne hidrološke godine, rezultati kros-korelacijskih funkcija (slike 4.13 i 4.14) pokazali su slično ponašanje izvora Jadra i Žrnovnice s boljom korelacijom izvora Jadra sa svim meteorološkim postajama isključujući prvi "vrh".

Za bolje razumijevanje rezultata kros-korelacije, vremenena odgovora sustava prikazana su u tablici 4.1. Vrijeme odgovora sustava je vrijeme koje odgovara maksimumu funkcije kros-korelacije (Delbart i dr., 2014; 2016). Prema Manginu (1984), vrijeme odgovora povezano s kros-korelacijom između oborine i protoka odgovara srednjem vremenu odgovora krškog vodonosnika na pojavu oborine.

Prema rezultatima vremena odgovora prikazanim u tablici 4.1, oba izvora pokazuju brz odgovor (manje od 24 sata) na pojavu kiše s gotovo jednakim vrijednostima u sušnoj i gotovo jednakim vrijednostima u kišnoj hidrološkoj godini. To je dokaz postojanja važne komponente brzog otjecanja (Lo Russo i dr., 2014) za oba izvora.

Statistički značajne vrijednosti u negativnim vremenskim periodima evidentne su u funkcijama kros-korelacije (slike 4.11-4.14). Budući da je veza oborine-protok jednosmjerna, ove vrijednosti ukazuju na to da su drugi procesi uključeni u prijenos vode (Jukić i Denić-Jukić, 2015).

Po prvi puta je napravljena kros-korelacija između protoka krških izvora Žrnovnice i Jadra u cilju proučavanja njihovih odnosa. Kros-korelacijska funkcija između protoka Žrnovnice i protoka Jadra (slika 4.15) rezultira visokim vrijednostima i uglavnom je simetrična oko vertikalne osi u sušnoj i kišnoj hidrološkoj godini, što pokazuje da su otjecanja na oba izvora generirana istim hidrološkim procesima (Mayaud i dr., 2014). Više vrijednosti na desnoj strani korelograma u sušnoj i kišnoj hidrološkoj godini ukazuju na postojanje uzročno-posljedične veze između Žrnovnice i Jadra. Kako bi se ova veza detaljnije analizirala napravljena je parcijalna korelacijska analiza.

Slika 4.11 Kros-korelcijske funkcije (CCF) između oborina V, D, i TK i protoka J u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.12 Kros-korelcijske funkcije (CCF) između oborina V, D, i TK i protoka Ž u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.13 Kros-korelcijske funkcije (CCF) između oborina V, D, i TK i protoka J u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.14 Kros-korelcijske funkcije (CCF) između oborina V, D, i TK i protoka Ž u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.15 Kros-korelacijske funkcije (CCF) protoka Jadra i Žrnovnice u sušnoj i kišnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Tablica 4.1 Kros-korelacija: Vrijeme odgovora sustava

Izvor	Razdoblje	CCF- Vrijeme odgovora (sati)		
		Meteorološka stanica		
		Vučevica	Dugopolje	Tunel Konjsko
Jadro	20.10.2011. -12.09.2012.	21	21	21
	13.09.2012. - 09.09.2013.	16	16	15
Žrnovnica	20.10.2011. -12.09.2012.	23	21	22
	13.09.2012. - 09.09.2013.	17	16	16

Uspoređujući rezultate sušne i kišne hidrološke godine, izvori Jadro i Žrnovnica su pokazali slično ponašanje. Rezultati dobiveni korelacijskom analizom oba izvora pokazali su karakteristike srednjeg okršenog vodonosnika (Padilla i Pulido-Bosch, 1995).

4.2 PARCIJALNA KORELACIJSKA ANALIZA

Vremenske serije oborina i protoka kao ulazno-izlazne vremenske serije promatranog sustava pod utjecajem su raznih prostorno-vremenski promjenjivih procesa uključenih u transfer vode u hidrološkom ciklusu (Jukić i Denić-Jukić, 2011; Jukić i Denić-Jukić, 2015). Efekti ovakvih procesa mogu biti obuhvaćeni auto-korelacijskim i kros-korelacijskim funkcijama. Primjenom parcijalne korelacijske analize efekti prostorno-vremenski promjenjivih procesa mogu se odvojiti od funkcija korelacije (Jukić i Denić-Jukić, 2011; Jukić i Denić-Jukić, 2015). Sljedeća analiza parcijalne korelacije prvog reda usmjerena je na određivanje utjecaja temperature zraka, relativne vlažnosti, oborina i protoka, pojedinačno, na hidrološko ponašanje i odnose izvora Jadr i Žrnovnice u sušnoj i kišnoj hidrološkoj godini, koristeći satne podatke vremenskih serija. Vremenske serije oborina s meteoroloških postaja Vučevica (V) i Dugopolje (D) zasebno se tretiraju kao ulazne serije. Vremenske serije protoka izvora Jadro (J) i Žrnovnica (Ž) zasebno se tretiraju kao izlazne serije. Kontrolne vremenske serije su sljedeće: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine (D i TK) (odabrano obzirom na lokacije meteoroloških stanica Dugopolje i Tunel Konjsko) i protoci izvora Jadro i Žrnovnica.

4.2.1 Parcijalna auto-korelacijska analiza

Slika 4.16 predstavlja usporedbu auto-korelacijske funkcije ACF (J) i parcijalnih auto-korelacijskih funkcija PACF (J|T), PACF (J|RH), PACF (J|D), PACF (J|TK) i PACF (J|Ž) u sušnoj hidrološkoj godini. Može se primijetiti da su postojeće razlike između ACF (J), PACF (J|RH), PACF (J|D) i PACF (J|TK) beznačajne, što znači da kontrolne serije RH, D i TK nemaju utjecaja na pražnjenje vodonosnika. Utjecaj temperature (T) na ACF (J) nešto je očitiji, ali još uvijek relativno nizak. Suprotno, PACF (J|Ž) bitno se razlikuje od ACF (J). Kontrolna serija Ž ima parcijalan utjecaj na ACF (J) u periodu do 1034 sata (približno 43 dana) te od 1034 do 1392 sata (58 dana) ona supresivno utječe na pražnjenje vodonosnika (slika 4.16, detalj A), odnosno umanjuje auto-korelacijsku funkciju Jadr.

Slični rezultati dobiveni su za izvor Žrnovnice (slika 4.17) u sušnoj hidrološkoj godini gdje su PACF (Ž|T) i PACF (Ž|J) pokazali odstupanje od ACF (Ž). Kontrolna serija J ima parcijalan utjecaj na ACF (Ž) u prvih 340 sati (slika 4.17, detalj A) i od 840 do 1400 sati (slika 4.17, detalj C), te ima utjecaj supresije na ACF (Ž) u periodu od 432 do 840 sati (slika 4.17, detalj B). Nakon 1400 sati kontrolna serija J nema značajan utjecaj na ACF (Ž).

Slika 4.16 Usporedba auto-korelacijske funkcije izvora Jadro (ACF (J)) sa parcijalnim autokorelacijskim funkcijama (PACF) u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.17 Usporedba auto-korelacijske funkcije izvora Žrnovnica ($ACF(\check{Z})$) sa parcijalnim autokorelacijskim funkcijama (PACF) u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Utjecaji temperature (T) na ACF (J) i ACF (Ž) u kišnoj godini (slike 4.18 i 4.19) su značajniji nego u sušnoj hidrološkoj godini zbog izraženije sezonske periodičke komponente otjecanja i jer su veće razlike u količini otjecanja tijekom ljetnih i zimskih mjeseci. Otjecanje u sušnoj godini je ujednačenije tijekom godine. Ovakav rezultat pokazuje da pritjecanja iz susjednog sliva rijeke Cetine više dolaze do izražaja tijekom sušnih godina, što je u skladu s prethodnim istraživanjima (Bonacci 1987; Stepinac 1983) koja su pokazala da su se izgradnjom akumulacija na rijeci Cetini izmjenili prirodni uvjeti istjecanja na izvorima Jadro i Žrnovnica. Poseban utjecaj akumulacija vidljiv je u režimu istjecanja izvora Žrnovnice koji bi prije toga tijekom hidroloških minimuma gotovo presušio. Može se primijetiti da kontrolni signali RH, D i TK nemaju utjecaja na ACF (J) i ACF (Ž) u kišnoj godini (slike 4.18 i 4.19).

Usporedbom funkcija PACF (J|Ž) i PACF (Ž|J), evidentno je da kontrolna serija J ima više utjecaja na ACF (Ž) nego obratno, u sušnoj i kišnoj godini (slike 4.16 – 4.19). Ovakvi rezultati se mogu objasniti činjenicom da je izvor Žrnovnica manji izvor koji se djelomično prihranjuje od izvora Jadro. Prema dosadašnjim saznanjima (Bonacci i Andrić, 2015), do prihranjivanja dolazi nakon obilnih kiša.

Prema Jukić i Denić-Jukić (2015) prvi prekid u nagibu krivulje funkcije parcijalne auto-korelacije označava kraj brzog tečenja, a drugi prekid označava kraj srednjeg toka i stvarno pamćenje sustava. Ne postoji egzaktna način za određivanje ovih točaka prekida. Točke prekida određuju se uočavanjem promjena u nagibu funkcije parcijalne korelacije. Na slikama 4.16 i 4.17 točke prekida u parcijalnim auto-korelacijskim funkcijama nije moguće precizno odrediti. U kišnoj godini uočavaju se prekidi u nagibu funkcija PACF (J|T) i PACF (Ž|T) na vremenskom koraku od 336 sati (14 dana) (slike 4.17 i 4.18), što se poklapa sa rezultatom od Jukić i Denić-Jukić (2015) za Jadro. Može se zaključiti da trajanje brzog tečenja za oba izvora iznosi 14 dana. Druge točke prekida u funkcijama PACF (J|T) i PACF (Ž|T) (slike 4.17 i 4.18) se ne mogu precizno odrediti. Parcijalna korelacijska analiza dosada nije primijenjena na izvor Žrnovnica, stoga nije moguće dati usporedbe s drugim radovima.

Sažetak rezultata parcijalne auto-korelacije u sušnoj i kišnoj hidrološkoj godini dan je u tablicama 4.2 i 4.3.

Slika 4.18 Usporedba auto-korelacijske funkcije izvora Jadro (ACF (J)) sa parcijalnim autokorelacijskim funkcijama (PACF) u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunnel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.19 Usporedba auto-korelacijske funkcije izvora Žrnovnica (ACF (Ž)) sa parcijalnim autokorelacijskim funkcijama (PACF) u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Tablica 4.2 Rezultati parcijalne auto-korelacijske analize u sušnoj hidrološkoj godini

Sušna hidrološka godina		
Kontrolna vremenska serija	Odnos PCCF-CCF	Utjecaj kontrolne vremenske serije
T	$PACF(J T) < ACF(J)$ $PACF(\check{Z} T) < ACF(\check{Z})$	Parcijalan utjecaj
RH	$PACF(J RH) \approx ACF(J)$ $PACF(\check{Z} RH) \approx ACF(\check{Z})$	Nema utjecaja
D	$PACF(J D) \approx ACF(J)$ $PACF(\check{Z} D) \approx ACF(\check{Z})$	Nema utjecaja
TK	$PACF(J TK) \approx ACF(J)$ $PACF(\check{Z} TK) \approx ACF(\check{Z})$	Nema utjecaja
J	$PACF(\check{Z} J) < ACF(\check{Z})$	Parcijalan utjecaj / Utjecaj supresije
$\check{Z}$	$PACF(J \check{Z}) < ACF(J)$	Parcijalan utjecaj / Utjecaj supresije

Tablica 4.3 Rezultati parcijalne auto-korelacijske analize u kišnoj hidrološkoj godini

Kišna hidrološka godina		
Kontrolna vremenska serija	Odnos PCCF-CCF	Utjecaj kontrolne vremenske serije
T	$PACF(J T) < ACF(J)$ $PACF(\check{Z} T) < ACF(\check{Z})$	Parcijalan utjecaj
RH	$PACF(J RH) \approx ACF(J)$ $PACF(\check{Z} RH) \approx ACF(\check{Z})$	Nema utjecaja
D	$PACF(J D) \approx ACF(J)$ $PACF(\check{Z} D) \approx ACF(\check{Z})$	Nema utjecaja
TK	$PACF(J TK) \approx ACF(J)$ $PACF(\check{Z} TK) \approx ACF(\check{Z})$	Nema utjecaja
J	$PACF(\check{Z} J) < ACF(\check{Z})$	Parcijalan utjecaj
$\check{Z}$	$PACF(J \check{Z}) < ACF(J)$	Parcijalan utjecaj

4.2.2 Parcijalna kros-korelacijska analiza

Općenito, parcijalna kros-korelacijska analiza usmjerena je na određivanje odnosa između kros-korelacijske funkcije CCF ($x-y$) i parcijalne kros-korelacijske funkcije PCCF ($x-y/z$), koja opisuje utjecaje kontrolne serije z na odnos serija x i y .

Usporedbe kros-korelacijskih funkcija CCF ($x-y$) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y/z$) prikazane su slikama 4.20-4.31. Interpretacija rezultata se odnosi na prvih 1000 sati budući da se značajni utjecaji kontrolnih signala javljaju u tom periodu. Nakon 1000 sati utjecaji kontrolnih signala su uglavnom statistički beznačajni, odnosno, nemaju nikakav fizikalni značaj (predstavljaju deformacije uslijed nestacionarnosti vremenske serije).

Utjecaji temperature (T) na kros-korelaciju oborine-protok na slikama 4.20-4.23 su vidljivi ali ipak relativno niski, tj., parcijalne korelacijske funkcije PCCF ($x-y/T$) ne odstupaju značajno od kros-korelacijskih funkcija CCF ($x-y$), neovisno o odabranoj ulaznoj x (Vučevica, Dugopolje) i izlaznoj y (Jadro, Žrnovnica) vremenskoj seriji. Međutim, parcijalan utjecaj kontrolne serije T na kros-korelaciju oborine-protok je izražen u slučaju ulazne serije Tunel Konjsko i izlanih serija Jadro i Žrnovnica (slike 4.24 i 4.25). Korištenje relativne vlažnosti RH kao kontrolne serije rezultiralo je parcijalnim kros-korelacijskim funkcijama PCCF ($x-y/RH$) koje se značajno razlikuju od kros-korelacijskih funkcija CCF ($x-y$) ($PCCF(x-y/RH) < CCF(x-y)$) gotovo tijekom cijelog promatranog perioda sušne godine za sve ulazne i izlazne vremenske serije (slike 4.20-4.31). Relativna vlažnost utječe na proces evapotranspiracije a time i na prostornu i vremensku distribuciju procesa prihranjivanja podzemnih voda u sušnoj godini (Jukić i Denić-Jukić 2011, 2015). Kontrolne serije oborina sa stanica Tunel Konjsko (TK) (slike 4.20-4.23) i Dugopolje (D) (slike 4.20., 4.21, 4.24, 4.25) imaju pretežito parcijalan utjecaj na kros-korelaciju oborine-protok u promatranom periodu od prvih 1000 sati.

Najznačajniji utjecaj supresije kros-korelacije oborine-protok u sušnoj hidrološkoj godini, koji traje prvih 48 sati, dobiven je koristeći kontrolne serije protoka Jadra (J) (slike 4.21, 4.23 i 4.25) i Žrnovnice (Ž) (slike 4.20, 4.22 i 4.25) ($PCCF(x-J|Ž) > CCF(x-J)$ i $PCCF(x-Ž|J) > CCF(x-Ž)$). Nakon 48 sati, kontrolne serije J i Ž imaju slab, gotovo nikakav utjecaj na kros-korelacije oborine-protok ($PCCF(x-J|Ž) \approx CCF(x-J)$ i $PCCF(x-Ž|J) \approx CCF(x-Ž)$) za sve ulazne vremenske serije. Sažetak rezultata parcijalne kros-korelacije u sušnoj hidrološkoj godini dan je u tablici 4.4.

Slika 4.20 Usporedba kros-korelacijske funkcije $CCF(x,y)$ i parcijalnih kros-korelacijskih funkcija $PCCF(x-y|z)$ u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunnel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.21 Usporedba kros-korelacijske funkcije CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.22 Usporedba kros-korelacijske funkcije CCF (x, y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.23 Usporedba kros-korelacijske funkcije CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.24 Usporedba kros-korelacijske funkcije CCF (x, y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Žrnovnica (Ž).

Slika 4.25 Usporedba kros-korelacijske funkcije CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Jadro (J).

Tablica 4.4 Rezultati parcijalne kros-korelacijske analize u sušnoj hidrološkoj godini

Sušna hidrološka godina		
Kontrolna vremenska serija	Odnos PCCF-CCF	Utjecaj kontrolne vremenske serije
T	$PCCF(V-J T) \approx CCF(V-J)$ $PCCF(V-\check{Z} T) \approx CCF(V-\check{Z})$ $PCCF(D-J T) \approx CCF(D-J)$ $PCCF(D-\check{Z} T) \approx CCF(D-\check{Z})$ $PCCF(TK-J T) < CCF(TK-J)$ $PCCF(TK-\check{Z} T) < CCF(TK-\check{Z})$	Nema utjecaja / Parcijalan utjecaj
RH	$PCCF(V-J RH) < CCF(V-J)$ $PCCF(V-\check{Z} RH) < CCF(V-\check{Z})$ $PCCF(D-J RH) < CCF(D-J)$ $PCCF(D-\check{Z} RH) < CCF(D-\check{Z})$ $PCCF(TK-\check{Z} RH) < CCF(TK-J)$ $PCCF(TK-\check{Z} RH) < CCF(TK-\check{Z})$	Parcijalan utjecaj
D	$PCCF(V-J D) < CCF(V-J)$ $PCCF(V-\check{Z} D) < CCF(V-\check{Z})$ $PCCF(TK-\check{Z} D) < CCF(TK-J)$ $PCCF(TK-\check{Z} D) < CCF(TK-\check{Z})$	Parcijalan utjecaj
TK	$PCCF(V-J TK) < CCF(V-J)$ $PCCF(V-\check{Z} TK) < CCF(V-\check{Z})$ $PCCF(D-J TK) < CCF(D-J)$ $PCCF(D-\check{Z} TK) < CCF(D-\check{Z})$	Parcijalan utjecaj
J	$PCCF(V-\check{Z} J) > / \approx CCF(V-\check{Z})$ $PCCF(D-\check{Z} J) > / \approx CCF(D-\check{Z})$ $PCCF(TK-\check{Z} J) > / \approx CCF(TK-\check{Z})$	Utjecaj supresije / Nema utjecaja
$\check{Z}$	$PCCF(V-J \check{Z}) > / \approx CCF(V-J)$ $PCCF(D-J \check{Z}) > / \approx CCF(D-J)$ $PCCF(TK-J \check{Z}) > / \approx CCF(TK-J)$	Utjecaj supresije / Nema utjecaja

Usporedbom funkcija $PCCF(x-J|\check{Z})$ i $PCCF(x-\check{Z}|J)$ u sušnoj hidrološkoj godini (slike 4.20-4.25), evidentno je da protok izvora Žrnovnica ($\check{Z}$) ima veći utjecaj na korelaciju oborine-protok nego protok izvora Jadro (J), za sve ulazne vremenske serije.

U kišnoj hidrološkoj godini utjecaji kontrolnih vremenskih serija temperature (T) i relativne vlažnosti (RH) dominantni su tijekom cijelog promatranog razdoblja (slike 4.26-4.31) za sve ulazne i izlazne vremenske serije. Kontrolne serije T i RH uklanjanju sezonsku periodičku komponentu (Jukić i Denić-Jukić, 2015) koja je više izražena u kišnim razdobljima, što znači da proces evapotranspiracije značajno utječe na prihranjivanje podzemnih voda.

Osim vrlo kratkih perioda (posebno prva 72 sata), kontrolna serija oborina sa stanice Tunel Konjsko (TK) uglavnom ima utjecaj supresije na korelaciju oborine-protok ($PCCF(x-y/TK) > CCF(x-y)$) (slike 4.26-4.29), odnosno, reducira kros-korelaciju između serija x i y . Kontrolna serija oborina sa stanice Dugopolje (D) ima parcijalan utjecaj na korelaciju oborine-protok $CCF(V-J)$ i $CCF(V-Ž)$ u period do 653 sata (slike 4.26 i 4.27) nakon čega taj utjecaj slabi, tj., utjecaj je neznatan. U slučaju korelacija $CCF(TK-J)$ i $CCF(TK-Ž)$ oborine sa stanice Dugopolje (D) imaju parcijalan utjecaj u periodu od 800 sati te nakon toga nemaju utjecaja (slike 4.30 i 4.31).

Supresija korelacije oborine-protok u kišnoj godini uzrokovana kontrolnim serijama protoka Jadra (J) (slike 4.27, 4.29 i 4.31, detalj A) i Žrnovnice (Ž) (slike 4.26, 4.28 i 4.30, detalj A) traje prva 24 sata. Nakon 24 sata kontrolne serije J i Ž imaju parcijalan utjecaj na korelaciju oborine-protok, tj., $PCCF(x-J|Ž) < CCF(x-J)$ i $PCCF(x-Ž|J) < CCF(x-Ž)$ za sve ulazne serije.

Usporedbom parcijalnih kros-korelacijskih funkcija $PCCF(x-J|Ž)$ i $PCCF(x-Ž|J)$ u kišnoj godini (slike 4.26-4.31) vidljivo je da Jadro i Žrnovnica imaju gotovo jednak utjecaj na korelaciju oborine-protok, za sve ulazne vremenske serije.

Sažetak rezultata parcijane kros-korelacijske analize dan je u tablici 4.5.

Slika 4.26 Usporedba kros-korelacijske funkcije $CCF(x,y)$ i parcijalnih kros-korelacijskih funkcija $PCCF(x-y|z)$ u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunnel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.27 Usporedba kros-korelacijske funkcije CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.28 Usporedba kros-korelacijske funkcije $CCF(x,y)$ i parcijalnih kros-korelacijskih funkcija $PCCF(x-y|z)$ u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.29 Usporedba kros-korelacijske funkcije CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.30 Usporedba kros-korelacijske funkcije CCF (x, y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Jadro (J).

Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Žrnovnica (Ž).

Slika 4.31 Usporedba kros-korelacijske funkcije $CCF(x,y)$ i parcijalnih kros-korelacijskih funkcija $PCCF(x-y|z)$ u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Jadro (J).

Tablica 4.5 Rezultati parcijalne kros-korelacijske analize u kišnoj hidrološkoj godini

Kišna hidrološka godina		
Kontrolna vremenska serija	Odnos PCCF-CCF	Utjecaj kontrolne vremenske serije
T	$PCCF(V-J T) < CCF(V-J)$ $PCCF(V-Ž T) < CCF(V-Ž)$ $PCCF(D-J T) < CCF(D-J)$ $PCCF(D-Ž T) < CCF(D-Ž)$ $PCCF(TK-J T) < CCF(TK-J)$ $PCCF(TK-Ž T) < CCF(TK-Ž)$	Parcijalan utjecaj
RH	$PCCF(V-J RH) < CCF(V-J)$ $PCCF(V-Ž RH) < CCF(V-Ž)$ $PCCF(D-J RH) < CCF(D-J)$ $PCCF(D-Ž RH) < CCF(D-Ž)$ $PCCF(TK-Ž RH) < CCF(TK-J)$ $PCCF(TK-Ž RH) < CCF(TK-Ž)$	Parcijalan utjecaj
D	$PCCF(V-J D) < / \approx CCF(V-J)$ $PCCF(V-Ž D) < / \approx CCF(V-Ž)$ $PCCF(TK-Ž D) < / \approx CCF(TK-J)$ $PCCF(TK-Ž D) < / \approx CCF(TK-Ž)$	Parcijalan utjecaj / Nema utjecaja
TK	$PCCF(V-J TK) < / > CCF(V-J)$ $PCCF(V-Ž TK) < / > CCF(V-Ž)$ $PCCF(D-J TK) < / > CCF(D-J)$ $PCCF(D-Ž TK) < / > CCF(D-Ž)$	Parcijalan utjecaj / Utjecaj supresije
J	$PCCF(V-Ž J) > / < CCF(V-Ž)$ $PCCF(D-Ž J) > / < CCF(D-Ž)$ $PCCF(TK-Ž J) > / < CCF(TK-Ž)$	Utjecaj supresije / Parcijalan utjecaj
Ž	$PCCF(V-J Ž) > / < CCF(V-J)$ $PCCF(D-J Ž) > / < CCF(D-J)$ $PCCF(TK-J Ž) > / < CCF(TK-J)$	Utjecaj supresije / Parcijalan utjecaj

Prema Jukić i Denić-Jukić (2015) prva točka prekida u parcijalnoj kros-korelacijskoj funkciji označava trajanje brzog tečenja, a druga točka prekida označava trajanje srednjeg tečenja te početak baznog tečenja. Ovi rezultati trebaju biti u skladu s rezultatima parcijalne auto-korelacijske analize. Međutim, točke prekida u nagibima parcijalnih kros-korelacijskih funkcija na

slikama 4.20-4.31 se ne mogu precizno odrediti te stoga nije moguće usporediti rezultate za izvor Jadra sa rezultatima Jukić i Denić-Jukić iz 2015. godine.

Rezultati parcijalne korelacijske analize (slike 4.20-4.31) pokazuju da korištenje protoka kao kontrolne vremenske serije pokazuju da postoji mehanizam razmjene podzemnih voda između krških sustava izvora Jadro i Žrnovnica, što je u skladu s postojećim hipotezama o funkcioniranju ovih dvaju izvora, tj. to su izvori s preklapajućim slivovima koji dijelom dijele isti vodonosnik.

4.3 ANALIZA PROTOKA U MODULNIM KOEFICIJENTIMA

Protoke susjednih izvora moguće je međusobno uspoređivati ako se protoci svedu na modulne koeficijente (Morozov, 1954; Chow, 1964; Gupta, 1989; Žugaj, 1984; Fernandez i Salas, 1999; Partal i Kahya, 2006). Protoci se pretvaraju u modulne koeficijente tako da se njihove vrijednosti (Q_t) podijele s prosjekom razdoblja (Q_{sred}).

Na slikama 4.32-4.35 prikazana je distribucija vode za izvore Žrnovnica i Jadro u sušnoj i kišnoj hidrološkoj godini. U sušnoj hidrološkoj godini vidljiv je priliv vode izvoru Žrnovnica (grupiranje točaka iznad pravca dugoročnog prosjeka, slika 4.32) pri vrijednosti modulnog koeficijenta 4.69 ($Q_{\check{z}}/Q_{\check{z},sred}$), te otjecanja iz izvora Jadro (grupiranje točaka ispod pravca dugoročnog prosjeka slika 4.33) pri vrijednosti modulnog koeficijenta 2.75 ($Q_J/Q_{J,sred}$). Ukupni protok oba izvora ($Q_J+Q_{\check{z}}$) u trenutku priliva, odnosno otjecanja, iznosi 26.68 m³/s. U kišnoj godini priliv vode izvoru Žrnovnice (slika 4.34) se događa pri iznosu modulnog koeficijenta 3.4, a otjecanja iz izvora Jadro (slika 4.35) pri vrijednosti modulnog koeficijenta 2.5. Ukupni protok oba izvora za slučaj kišne godine iznosi u trenutku priliva/otjecanja 38.5 m³/s.

Ovakvi rezultati mehanizma razmjene podzemnih voda upućuju na preklapanje slivova izvora Jadra i Žrnovnice, odnosno, pokazuju da susjedni krški izvori Jadro i Žrnovnica djelomično dijele isti vodonosnik u sušnoj i u kišnoj hidrološkoj godini. Rezultati su u skladu s rezultatima prethodnih studija (Bonacci 1987, Jukić i Denić-Jukić 2008, Bonacci i Roje-Bonacci, 1996; Bonacci i Andrić 2015) koje ukazuju na mogućnost da se dio voda iz sliva Jadra prelijeva u sliv Žrnovnice tijekom razdoblja viših razina podzemnih voda preko neke geološke barijere koja zbog nedostatka hidrogeoloških istraživanja do sada nije utvrđena, odnosno do prihranjivanja dolazi nakon pojava obilnih kiša.

Rezultati modulnih koeficijenata potvrđuju rezultate dobivene parcijalnom auto-korelacijskom analizom. Naime, usporedbom parcijalnih korelacijskih funkcija (slike 4.16–4.19)

korištenjem protoka kao kontrolne serije, utvrđeno je da otjecanje izvora Jadro ima više utjecaja na otjecanje izvora Žrnovnica nego obratno, u sušnoj i kišnoj godini, što se može objasniti činjenicom da se izvor Žrnovnica, kao manji izvor, djelomično prihranjuje od izvora Jadro.

Rezultati modulnih koeficijenata također potvrđuju rezultate dobivene parcijalnom kros-korelacijskom analizom. Primjena protoka susjednog izvora kao kontrolne serije u parcijalnoj kros-korelacijskoj analizi dokazala je utjecaj protoka izvora Jadro na korelacije izvora Žrnovnica i oborina sa svih promatranih meteoroloških stanica, u sušnoj i u kišnoj hidrološkoj godini.

Slika 4.32 Izvor Žrnovnica: distribucija vode u sušnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

Slika 4.33 Izvor Jadro: distribucija vode u sušnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

Slika 4.34 Izvor Žrnovnica: distribucija vode u kišnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

Slika 4.35 Izvor Jadro: distribucija vode u kišnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

5 ZAKLJUČAK

Cilj ovog rada bio je istražiti odnose dvaju susjednih krških izvora Jadro i Žrnovnica i njihovo funkcioniranje tijekom sušne i kišne hidrološke godine primjenom jednostavne korelacije i parcijalne korelacijske analize prvog reda koristeći se satnim podacima.

Korelacijska analiza krških izvora Jadro i Žrnovnica pokazala je slično ponašanje oba izvora. Oba izvora pokazala su karakteristike srednje okršenog vodonosnika (Padilla i Pulido-Bosch, 1995) s duljim pamćenjem sustava u kišnoj hidrološkoj godini. Dulje pamćenje sustava u kišnoj hidrološkoj godini je posljedica sezonske periodičke komponente u vremenskoj seriji protoka koja je uglavnom posljedica evapotranspiracije. Ta komponenta je puno izraženija u kišnoj hidrološkoj godini. Rezultati dobiveni kros-korelacijskom analizom pokazali su da izvor Žrnovnica ima bolju korelaciju sa svim meteorološkim postajama u sušnoj godini, a izvor Jadro u kišnoj godini. Brz odgovor oba izvora (manje od 24 sata) na pojavu kiše s gotovo jednakim vrijednostima u sušnoj i gotovo jednakim vrijednostima u kišnoj hidrološkoj godini, ukazuje na postojanje važne komponente brzog otjecanja oba izvora. Kros-korelacijska analiza između protoka izvora Žrnovnica i Jadro rezultirala je ekstremnim visokim vrijednostima u sušnoj i kišnoj hidrološkoj godini, što ukazuje na postojanje kauzalne povezanosti između izvora Žrnovnica i Jadro.

Rezultati parcijalne auto-korelacijske analize pokazali su da relativna vlažnost i oborine ne utječu na auto-korelacijske funkcije izvora Jadrta i Źrnovnice u sušnoj i u kišnoj hidrološkoj godini. Utjecaji temperature na funkcije auto-korelacije u sušnoj godini su niski, ali očigledni za oba izvora. U kišnoj godini utjecaji temperature su značajniji u slučaju oba izvora. Korištenje protoka kao kontrolne vremenske serije pokazalo je da, iako oba protoka imaju veliki utjecaj, protok Jadrta ima veći utjecaj na funkciju auto-korelacije izvora Źrnovnica, nego obrnuto, u sušnoj i u kišnoj godini. Pomoću parcijalnih auto-korelacijskih funkcija PACF (J|T) i PACF (Ź|T) određeno je trajanje brzog otjecanja za oba izvora u kišnoj godini. Rezultat za izvor Jadro (14 dana) podudara se s rezultatom Jukić i Denić-Jukić (2015). Analiza parcijalne korelacije nije do sada primijenjena na izvor Źrnovnica, stoga nije moguće dati usporedbu.

Rezultati parcijalne kros-korelacijske analize pokazali su da prosječna relativna vlažnost utječe na korelaciju oborine-protok u sušnoj i u kišnoj hidrološkoj godini za razliku od prosječne temperature koja značajno utječe samo u kišnoj godini. Stoga se može zaključiti da prosječna relativna vlažnost utječe na proces evapotranspiracije u sušnoj godini. U kišnoj godini prosječna relativna vlažnost i temperatura utječu na proces evapotranspiracije. Rezultati parcijalne korelacijske analize u kišnoj godini pokazali su da kiša sa susjedne postaje može supresijski utjecati na korelaciju između oborina i protoka. Primjena protoka susjednog izvora kao kontrolne serije u parcijalnoj korelacijskoj analizi dokazala je da, u slučaju izvora Jadro i Źrnovnica, protok svakog izvora utječe na korelaciju oborina i protoka, a također supresijski utječe na korelaciju u prvih 48 sati u sušnoj i 24 sata u kišnoj hidrološkoj godini.

Rezultati dobiveni pomoću modulnih koeficijenata potvrđuju rezultate parcijalne analize, tj. pokazali su da postoji mehanizam razmjene podzemnih voda koji upućuje na preklapanje slivova izvora Jadrta i Źrnovnice, odnosno, pokazuju da susjedni krški izvori Jadro i Źrnovnica djelomično dijele isti vodonosnik u sušnoj i u kišnoj hidrološkoj godini.

Općenito, dobiveni rezultati korelacijske i parcijalne korelacijske analize, kao i rezultati analize protoka u modulnim koeficijentima, pokazuju da susjedni krški izvori Jadro i Źrnovnica djelomično dijele isti vodonosnik, što je u skladu s prethodnim studijama (Bonacci 1987, Bonacci i Roje-Bonacci, 1996; Jukić i Denić-Jukić 2008, Bonacci i Andrić 2015).

Parcijalna korelacijska analiza predstavlja poboljšanje korelacijske analize, jer rješava nejasnoće uzrokovane utjecajem prostorno-vremenski varijantnih procesa prisutnih u vremenskim serijama. Na primjer, parcijalna korelacijska analiza može se koristiti za prepoznavanje procesa koji utječu na pamćenje sustava, određivanje važnosti i doprinosa svakog procesa itd. Međutim, parcijalna korelacijska analiza ima dva ograničenja u kvantitativnim analizama: pouzdanost i

linearnost. Pouzdanost se povećava proporcionalno veličini uzorka. Budući da se izračun koeficijenta parcijalne korelacije temelji na običnom korelacijskom koeficijentu, pretpostavlja se linearni odnos. Ovo ograničenje nije toliko važno u kvalitativnim analizama. Cilj kvalitativnih analiza je odrediti ponašanje sustava i razloge koji uzrokuju takvo ponašanje. Egzaktne kvantitativne vrijednosti nisu prioritet u ovoj vrsti analize (Jukić i Denić-Jukić 2015).

Očekivani znanstveni doprinos ove disertacije je u razvoju novog, dosad nekorištenog pristupa za analizu hidroloških odnosa susjednih krških izvora koji je temeljen na primjeni parcijalnih korelacijskih funkcija. Jedinstvenost ovog rada je i u tome što se u njemu po prvi put provela parcijalna korelacijska analiza sušne i kišne hidrološke godine korištenjem satnih podataka. Po prvi put se kao kontrolna vremenska serija u parcijalnoj korelacijskoj analizi koristilo otjecanje opaženo na susjednom krškom izvoru. Implementacija otjecanja iz izvora kao kontrolne vremenske serije pokazala se kao dobar pokazatelj hidroloških odnosa dvaju krških izvora.

Predloženi novi pristup bi se mogao koristiti kao sastavni dio hidroloških i hidrogeoloških istraživanja slivova susjednih krških izvora, s obzirom da se do potrebnih podataka može doći na relativno jednostavan i jeftin način.

U daljnja istraživanja uključit će se konceptualni modeli linearnih rezervoara koji će se koristiti u teoretskim razmatranjima hidrološkog funkcioniranja dva susjedna krška izvora s ciljem određivanja načina na koji se različiti oblici hidrološkog funkcioniranja manifestiraju u obliku parcijalnih korelacijskih funkcija.

POPIS SLIKA:

Slika 1.1 Prostorna skica krških područja u svijetu (Krška područja označena su crvenom bojom. Izvor: COST 65, 1995 + 620, 2003; Europ. Comm., Luxembourg. *Encycl. caves + karst science*, N.Y., 2004.).

Slika 1.2 Prostorna skica krških područja u Hrvatskoj (Biondić i Biondić, 2014).

Slika 1.3 Prostorna skica krških područja u Hrvatskoj (Biondić i Biondić, 2014).

Slika 1.4 Nacionalni park Plitvička jezera.

Slika 1.5 Voda obogaćena s CO₂ (ugljikov-dioksid) iz tla i vegetacije povećava pukotine i prodire sve dublje. Kada voda koja sadrži otopljene ione dosegne jamu, kalcitne naslage istalože se u raznim oblicima (prema Zupan Hajna i dr., 2015).

Slika 1.6 Blok-dijagram heterogenog krškog vodonosnika (prema Goldscheider i dr., 2007).

Crtež 2.1 Shematsko objašnjenje odnosa između vremenskih serija (prema Jukić i Denić-Jukić, 2015): x_t - ulazna vremenska serija, y_{t+k} - izlazna vremenska serija, z_t – kontrolna vremenska serija, w_t – hipotetska neopažena vremenska serija.

Slika 3.1 Položaj sliva i prikaz izvora Jadra i Žrnovnice (Loborec i Đurin, 2016).

Slika 3.2 Hidrogeološka skica sliva rijeke Cetine (Biondić i Biondić, 2014).

Slika 3.3 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Muć (1995.-2015.).

Slika 3.4 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Dugopolje (1995.-2015.).

Slika 3.5 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Sinj (1995.-2015.).

Slika 3.6 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Dicmo (1995.-2015.).

Slika 3.7 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Prančevići (1995.-2015.).

Slika 3.8 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Bisko (1995.-2015.).

Slika 3.9 Linearna regresija između srednjih godišnjih protoka Q (m³/s) izvora Jadra i Žrnovnice i ukupnih godišnjih oborina P (mm) na postaji Lećevica (1995.-2015.).

Slika 3.10 Hidrogeološka karta (Kadić i dr., 2015).

Slika 3.11 Satne oborine na postajama: a) Vučevica, b) Dugopolje i c) Tunel Konjsko, i satni protoci izvora d) Jadro i e) Žrnovnica u sušnoj hidrološkoj godini (20.10.2011.-12.9.2012.).

Slika 3.12 Satne oborine na postajama: a) Vučevica, b) Dugopolje i c) Tunel Konjsko, i satni protoci izvora d) Jadro i e) Žrnovnica u kišnoj hidrološkoj godini (13.09.2012. do 09.09.2013.).

Slika 4.1 Auto-korelacijska funkcija (ACF) ulazne vremenske serije oborina na postaji Vučevica (V) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.2 Auto-korelacijska funkcija (ACF) ulazne vremenske serije oborina na postaji Dugopolje (D) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.3 Auto-korelacijska funkcija (ACF) ulazne vremenske serije oborina na postaji Tunel Konjsko (TK) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.4 Auto-korelacijska funkcija (ACF) izlazne vremenske serije protoka Jadra (J) i interval povjerenja (CI) u sušnoj hidrološkoj godini.

Slika 4.5 Auto-korelacijska funkcija (ACF) izlazne vremenske serije protoka Žrnovnice (Ž) i interval.

Slika 4.6 Auto-korelacijska funkcija (ACF) ulazne vremenske serije oborina na postaji Vučevica (V) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.7 Auto-korelacijska funkcija (ACF) ulazne vremenske serije oborina na postaji Dugopolje (D) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.8 Auto-korelacijska funkcija (ACF) ulazne vremenske serije oborina na postaji Tunel Konjsko (TK) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.9 Auto-korelacijska funkcija (ACF) izlazne vremenske serije protoka Jadra (J) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.10 Auto-korelacijska funkcija (ACF) izlazne vremenske serije protoka Žrnovnice (Ž) i interval povjerenja (CI) u kišnoj hidrološkoj godini.

Slika 4.11 Kros-korelacijske funkcije (CCF) između oborina V, D, i TK i protoka J u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.12 Kros-korelacijske funkcije (CCF) između oborina V, D, i TK i protoka Ž u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 5.13 Kros-korelacijske funkcije (CCF) između oborina V, D, i TK i protoka J u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.14 Kros-korelacijske funkcije (CCF) između oborina V, D, i TK i protoka Ž u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.15 Kros-korelacijske funkcije (CCF) protoka Jadra i Žrnovnice u sušnoj i kišnoj hidrološkoj godini, sa intervalom povjerenja (CI).

Slika 4.16 Usporedba auto-korelacijske funkcije izvora Jadro (ACF (J)) sa parcijalnim autokorelacijskim funkcijama (PACF) u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.17 Usporedba auto-korelacijske funkcije izvora Žrnovnica (ACF (Ž)) sa parcijalnim autokorelacijskim funkcijama (PACF) u sušnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.18 Usporedba auto-korelacijske funkcije izvora Jadro (ACF (J)) sa parcijalnim autokorelacijskim funkcijama (PACF) u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.19 Usporedba auto-korelacijske funkcije izvora Žrnovnica (ACF (Ž)) sa parcijalnim autokorelacijskim funkcijama (PACF) u kišnoj hidrološkoj godini, sa intervalom povjerenja (CI). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.20 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF (x-y|z) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.21 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF (x-y|z) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.22 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF (x-y|z) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.23 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF (x-y|z) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperatura zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.24 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF (x-y|z) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna

vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Žrnovnica (Ž).

Slika 4.25 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u sušnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Jadro (J).

Slika 4.26 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.27 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Vučevica (V) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.28 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Žrnovnica (Ž).

Slika 4.29 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Dugopolje (D) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Tunel Konjsko (TK) i protok izvora Jadro (J).

Slika 4.30 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Jadro (J). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Žrnovnica (Ž).

Slika 4.31 Usporedba kros-korelacijskih funkcija CCF (x,y) i parcijalnih kros-korelacijskih funkcija PCCF ($x-y|z$) u kišnoj hidrološkoj godini sa intervalom povjerenja (CI). Ulazna vremenska serija su oborine sa stanice Tunel Konjsko (TK) a izlazna vremenska serija protok izvora Žrnovnica (Ž). Kontrolne vremenske serije su: srednja temperature zraka (T), srednja relativna vlažnost (RH), oborine sa stanice Dugopolje (D) i protok izvora Jadro (J).

Slika 4.32 Izvor Žrnovnica: distribucija vode u sušnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

Slika 4.33 Izvor Jadro: distribucija vode u sušnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

Slika 4.34 Izvor Žrnovnica: distribucija vode u kišnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

Slika 4.35 Izvor Jadro: distribucija vode u kišnoj godini (modulni koeficijent u odnosu na ukupni protok oba izvora).

POPIS TABELA:

Tablica 3.1 Osnovne statističke karakteristike dnevnih vremenskih serija oborina, temperature i relativne vlažnosti, 1995.-2005. (minimum, maksimum, srednja višegodišnja vrijednost i standardna devijacija)

Tablica 3.2 Osnovne statističke karakteristike dnevnih vremenskih serija protoka, 1995.-2005. (minimum, maksimum, srednja višegodišnja vrijednost i standardna devijacija)

Tablica 3.3 Osnovne statističke karakteristike korištenih satnih podataka

Tablica 4.1 Kros-korelacija: Vrijeme odgovora sustava

Tablica 4.2 Rezultati parcijalne auto-korelacijske analize u sušnoj hidrološkoj godini

Tablica 4.3 Rezultati parcijalne auto-korelacijske analize u kišnoj hidrološkoj godini

Tablica 4.4 Rezultati parcijalne kros-korelacijske analize u sušnoj hidrološkoj godini

Tablica 4.5 Rezultati parcijalne kros-korelacijske analize u sušnoj hidrološkoj godini

LITERATURA

Adamowski K., Bocci C., *Geostatistical regional trend detection in river flow data*, Hydrological Processes, 15, pp 3331-3341, 2001.

Amraoui F., Razack M., Bouchaou L., *Turbidity dynamics in karstic systems. Example of Ribaa and Bittit springs in the Middle Atlas (Morocco)*, Hydrological Sciences Journal, 48(6), pp 971–984, 2003.

Angelini P., *Correlation and spectral analysis of two hydrogeological systems in central Italy*, Hydrological Sciences Journal, 42(3), pp 425-38, 1997.

Astel A., Mazerski J., Polkowska Z., Namiesnik J., *Application of PCA and time series analysis in studies of precipitation in Tricity (Poland)*, Advances in Environmental Research, 8(3-4), pp 337-349, 2004.

Bailly-Comte V., Jourde H., Roesch A., Pistre S., Batiot-Guilhe C., *Time series analysis for Karst/River interactions assessment: case of the Coulazou river (southern France)*, Journal of Hydrology, 349, 98-114, 2008.

Bailly-Comte V., Martin J. B., Sreaton E. J., *Time variant cross correlation to assess residence time of water and implication for hydraulics of a sink-rise karst system*, Water Resour. Res., 47 (5), pp 1-16, 2011.

Bakalowicz M., *Karst Groundwater: A challenge for new resources*, Hydrogeology Journal, 13(1), pp 148-60, 2005.

Barnard G.A., *Encyclopedia of Statistical Sciences*, Wiley, New York, 1, p.387, 1982.

- Biondić B., Biondić R., Dukarić F., *Protection of karst aquifers in the Dinarides in Croatia*, Environmental geology, 33(4), pp 309-319, 1997a.
- Biondić B., Biondić R., *Hidrogeologija dinarskog krša u Hrvatskoj*, Varaždin: Sveučilište u Zagrebu, Geotehnički fakultet, 2014.
- Bojanić D., *Hidrodinamičko modeliranje krških vodonosnika*, Disertacija, Fakultet građevinarstva, arhitekture i geodezije, Split, 2011.
- Bonacci O., *Karst Hydrology*, Springer Verlag: Berlin, Germany, 1987.
- Bonacci O., *Karst Springs Hydrographs as Indicators of Karst Aquifers*, Hydrological Sciences Journal, 38(1), pp 51–62, 1993.
- Bonacci O., Kerovec M., Roje-Bonacci T., Štambuk-Giljanović N., *Određivanje biološkog minimuma rijeke Jadrta, Studija III*, Sveučilište u Splitu, Građevinski fakultet, Fond stručne dokumentacije, Split, 1995.
- Bonacci O., Tanja Roje-Bonacci T., *Određivanje biološkog minimuma rijeke Jadrta, Studija IV*, Sveučilište u Splitu, Građevinski fakultet, Fond stručne dokumentacije, Split, 1996.
- Bonacci O., *Hidrološka Analiza Odvođenja Vode Iz Krškog Izvora Rijeke Jadro*, Hrvatske vode: časopis za vodno gospodarstvo, 20(79/80), pp 37–42, 2012.
- Bonacci O., Andrić I., *Hidrološka analiza krškog izvora Žrnovnice kod Splita*, Hrvatske vode: časopis za vodno gospodarstvo, 23 (94) , pp 311-320, 2015.
- Bonacci O., Andrić I., *Karst spring catchment: an example from Dinaric karst*, Environmental Earth Sciences, 74(7), pp 6211-23, 2015.
- Belayneh A., Adamowski J., Khalil B., Ozga-Zielinski B., *Long-term SPI drought forecasting the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models*, Journal of Hydrology, 508, pp 418– 429, 2014.
- Bellin A., Rinaldo A., *Analytical solutions for transport of linearly adsorbing solutes in heterogeneous formations*, Water Resources Research, 31 (6), pp 1505–1511, 1995.
- Benavente J., Pulido-Bosch A., Mangin A., *Application of correlation and spectral procedures to the study of the discharge in a karstic system (Eastern Spain)*, In: Gunay, G., Johnson A.I. (editors) Karst water resources – Proceedings of the Ankara-Antalya Symposium, July 1985, 67–75.
- Bouchaou L., Mangin A., Chauve P., *Turbidity mechanism of water from a karstic spring: example of the Ain Asserdoune Spring (Beni Mellal Atlas, Morocco)*, Journal of Hydrology 265(1-4), pp 34–42, 2002.
- Box G.E.P., Jenkins G.M., *Time series analysis: Forecasting and control*. Holden Day, San Francisco, 1970.

- Box G.E.P., Jenkins G.M., Reinsel C., *Time series analysis: forecasting and control*, 3rd ed. Prentice Hall, New Jersey, 1994.
- Box G.E.P., Jenkins G.M., *Time series analysis, forecasting and control*, Revised Edn., Holden Day, San Francisco, USA, pp 575, 1974.
- Box G. E. P., Jenkins G. M., Reinsel G. C., *Time Series Analysis, Forecasting and Control*, John Wiley & Sons, New Jersey, US, 2008.
- Burn D.H., *Climatic influences on streamflow timing in the headwaters of the Mackenzie River Basin*, Journal of Hydrology, 352(1-2), pp 225–38, 2008.
- Changnon S.A., Kunkel K.E., *Climate-related fluctuation in Midwestern floods during 1921–1985*, Journal of Water Resources Planning and Management, ASCE, 121(4), pp 326-334, 1995.
- Chatfield C., *The Analyses of Time Series: An Introduction*, 6th ed., Chapman&Hall/CRC, Boca Raton, Florida, 2004.
- COST 65, 1995 + 620, 2003; Europ. Comm., Luxembourg. *Encycl. caves + karst science*, N.Y., 2004
- Covington M.D., Wicks C.M., Saar M.O., *A dimensionless number describing the effects of recharge and geometry on discharge from simple karstic aquifers*, Water Resources 45(11), W11410, 2009.
- Cui H., Singh V.P., *Configurational entropy theory for streamflow forecasting*, Journal of Hydrology, 521, pp 1–17, 2015.
- Charlier J.B., Bertrand C., Mudry J., *Conceptual hydrogeological model of flow and transport of dissolved organic carbon in a small Jura karst system*, Journal of Hydrology, 460-461, pp 52-64, 2012.
- Chow V. T., *Handbook of Applied Hydrology*, 1st edn, McGraw-Hill, New York, 1964.
- De Michele C., Montanari A., Rosso R., *The effects of non-stationarity on the evaluation of critical design storms*, Water Science and Technology, 37(11), pp 187-193, 1998.
- Delbart C., Valdes D., Barbecot F., Tognelli A., Richon P., Couchoux L., *Temporal variability of karst aquifer response time established by the sliding-windows cross-correlation method*, Journal of Hydrology, 511, pp 580–588, 2014.
- Delbart C., Valdes D., Barbecot F., Tognelli A., Couchoux L., *Spatial organization of the impulse response in a karst aquifer*, Journal of Hydrology, 537, pp 18-26, 2016.
- Denić-Jukić V., *Hidrološko gledište otjecanja u kršu*, Disertacija, Građevinski fakultet, Split, 2002.
- Denić-Jukić V., Jukić D., *Composite transfer functions for karst aquifers*, Journal of Hydrology, 274, pp 80–94, 2003.

- Diggle P.D., *Times series: A biostatistical introduction*, Oxford Statistical Science Series. Oxford Science Publications, 1990.
- Douglas E.M., Vogel R.M., Kroll C.N., *Trends in floods and low flows in the United States: Impact of spatial correlation*. Journal of Hydrology, 240(1-2), pp 90-105, 2000.
- Dreybrodt W., *Processes in karst systems – physics, chemistry and geology*, Springer: Heidelberg, New York, 1988.
- Enqvist A., Flaska M., Pozzi S., *Measurement and simulation of neutron/gamma-ray cross-correlation functions from spontaneous fission*, Nuclear Instruments and Methods in Physics Research, Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 595(2), pp 426–30, 2008.
- Eisenlohr L., Kiraly L., Bouzelboudjen M., Rossier Y., *A numerical simulation as a tool for checking the interpretation of karst springs hydrographs*, Journal of Hydrology, 193, pp 306–315, 1997a.
- Eisenlohr L., Bouzelboudjen M., Kiraly L., Rossier Y., *Numerical versus statistical modelling of natural response of a karst hydrogeological system*, Journal of Hydrology, 202, pp 244–262, 1997b.
- Ehrentreich F., *Derivation of substructures from infrared band shapes by fuzzy logic and partial cross correlation functions*, Journal of Analytical Chemistry, 359(1), pp 56–60, 1997.
- Fan Y., Chen Y., Liu Y., Li W., *Variation of baseflows in the headstreams of the Tarim River Basin during 1960–2007*, Journal of Hydrology, 487, pp 98–108, 2013.
- Fiorillo F., Doglioni A., *The relation between karst spring discharge and rainfall by cross-correlation analysis (Campania, southern Italy)*, Hydrogeology Journal, 18, pp 1881–1895, 2010.
- Fernandez B., Salas J.D., *Return Period and Risk of Hydrologic Events. II: Applications*, Journal of Hydrologic Engineering, 4(4), 1999.
- Fleury P., Plagnes V., Bakalowicz M., *Modelling of the functioning of karst aquifers with a reservoir model: application to Fontaine de Vaucluse (south of France)*, Journal of Hydrology, 345, pp 38–49, 2007.
- Ford D. C., Williams P. W., *Karst hydrogeology and geomorphology*, London: Chapman & Hall, 1989.
- Ford D. C., Williams P. W., *Karst hydrogeology and geomorphology*, Wiley & Sons, 2007.
- Fritz F., *Općina Split. Hidrogeološka studija*, Hrvatski geološki institut, Fond stručne dokumentacije, Zagreb, br. 191, 1979.
- Fritz F., Pavičić A., Renić A., Kapelj J., *Izvori Jadro i Žrnovnica. Dio hidrogeoloških istražnih radova potrebnih za prijedlog zona sanitarne zaštite*, Hrvatski geološki institut, Fond stručne dokumentacije, Zagreb, br. 140, 1988.

- Fritz F., Kapelj J., *Osnovna hidrogeološka karta Republike Hrvatske M 1:100.000. Listovi Split i Primošten*, Hrvatski geološki institut, Fond stručne dokumentacije, Zagreb, 1998.
- Garson G. D., *Partial Correlation*, Statistical Associates Blue Book Series 29, Kindle Edition, 2012.
- Gemitzi A., Stefanopoulos K., *Evaluation of the effects of climate and man intervention on ground waters and their dependent ecosystems using time series analysis*, Journal of Hydrology, 403(1–2), pp 130–140, 2011.
- Gill L.W., Naughton O., Johnston P.M., Basu B., Ghosh B., *Characterization of hydrogeological connections in a lowland karst network using time series analysis of water levels in ephemeral groundwater-fed lakes (turloughs)*, Journal of Hydrology, 499, pp 289–302, 2013.
- Goldscheider N., Drew D., Worthington S., *Introduction*. In: Goldscheider, N., Drew, D. (Eds.), *Methods in Karst Hydrogeology*, Taylor & Francis, London. Int. Contrib.Hydrogeol., 26, pp 1-8, 2007.
- Grasso D.A., *Interpretation des responses hydrauliques et chimiques des sources karstiques*, PhD thesis, Centre of Hydrogeology (CHYN), University of Neuchatel, Switzerland, 1998.
- Grasso D.A., Jeannin P.-Y., *Etude critique des methodes d'analyse de la response globale des systemes karstiques. Application au site de bure (JU, Suisse)*, Bulletin d'Hydrogeologie, 13, pp 87-113, 1994.
- Grasso D.A., Jeannin P.-Y., *Statistical approach to the impact of climatic variations on karst spring chemical response*, Bulletin d'Hydrogeologie, 16, pp 59-74.
- Grew H., Werrity A., *Changes in flood frequency and magnitude in Scotland*. Proceedings of the BHS Fifth National Hydrology Symposium, Edinburgh, pp 3.1-3.9., 1995.
- Gupta R. S., *Hydrology and Hydraulic Systems*, 1st edn, Prentice Hall, New Jersey, 1989.
- Halihan T., Wicks C.M., *Modeling of storm responses in conduit flow aquifers with reservoirs*, Journal of Hydrology, 208, pp 82–91, 1998.
- Hartmann A., Kralik M., Humer F., Lange J., Weiler M., *Identification of a karst system's intrinsic hydrodynamic parameters: upscaling from single springs to the whole aquifer*, Environmental Earth Sciences, 65(8), pp 2377–89, 2012.
- Hartmann A., Goldscheider N., Wagener T., Lange J., Weiler M., *Karst water resources in a changing world: Review of hydrological modeling approaches*, Reviews of Geophysics, 52(April), 2014.
- He J., Valeo C., Chu A., Neumann N.F., *Prediction of event-based stormwater runoff quantity and quality by ANNs developed using PMI-based input selection*, Journal of Hydrology, 400, pp 10–23, 2011.
- Henderson R.J., *Rainfall time series for storm overflow assessment*, Water Science and Technology, 21, pp 1789-1791, 1989.

- Herman E.K., Toran L., White W.B., *Quantifying the place of karst aquifers in the groundwater to surface water continuum: a time series analysis study of storm behaviour in Pennsylvania water resources*, Journal of Hydrology, 376 (1–2), pp 307–317, 2009.
- Higashino M., Kanda T., Michioku K., *Time series analysis and transformation of water quality in an eutrophic reservoir*, Mizu Kankyo Gakkaishi, 22(8), pp 668–676, 1999.
- Jain S., Lall U., *Floods in a changing climate: Does the past represent the future*, Water Resources Research, 37(12), pp 3193–3205, 2001.
- Janos B., Lucien D., Omar H.R., *Practical generation of synthetic rainfall event time series in a semi-arid climatic zone*, Journal of Hydrology, 103, pp 357–373, 1988.
- Jayawardena A.W., Lai F., *Time series analysis of water quality data in Pearl River, China*, Journal of Environmental Engineering, ASCE, 115(3), pp 590–607, 1989.
- Jemcov I., Petrič M., *Measured precipitation vs. effective infiltration and their influence on the assessment of karst systems based on results of the time series analysis*, Journal of Hydrology, 379, pp 304–314, 2009.
- Jemcov I., Petrič M., *Time series analysis, modelling and assessment of optimal exploitation of the Nemanja karst springs, Serbia*, Acta Carsologica, 39(2), pp 187–200.
- Jenkins G. M., Watts D. G., *Spectral Analyses and Its Applications*, Holden-Day, San Francisco, pp 525, 1968.
- Johannet A., Mangin A., D'Hulst D., *Subterranean water infiltration modelling by neural networks: use of water source flow*, in ICANN '94 - Proceedings of the International Conference on artificial neural networks, Sorrento, Italy, 26–29 May 1994, pp.1033–1036, Springer-Verlag, London, 1994.
- Jukić D., Denić-Jukić V., *A frequency domain approach to groundwater recharge estimation in karst*, Journal of Hydrology, 289, pp 95–110, 2004.
- Jukić D., *Uloga transfer funkcija pri izradi balance i modeliranju otjecanja u kršu*, Disertacija, Građevinsko-arhitektonski fakultet, Split, 2005.
- Jukić D., Denić-Jukić V., *Estimating parameters of groundwater recharge model in frequency domain: karst springs Jadro and Žrnovnica*, Hydrological Processes, 22, pp 4532–4542, 2008.
- Jukić D., Denić-Jukić V., *Groundwater balance estimation in karst by using a conceptual rainfall-runoff model*, Journal of Hydrology, 373, pp 302–315, 2009.
- Jukić D., Denić-Jukić V., *Partial spectral analysis of hydrological time series*, Journal of Hydrology, 400(1–2), pp 223–233, 2011.
- Jukić D., Denić-Jukić V., *Investigating relationships between rainfall and karst-spring discharge by higher-order partial correlation functions*, Journal of Hydrology, 530, pp 24–36, 2015.

- Kadić A., Jukić D., Denić-Jukić V., *Study of hydrological relations between two adjacent karst springs by means of time series analysis*. Aqua 2015, Hydrogeology: Back to the Future!. Rome : The International Association of Hydrogeologists, 67-67, 2015.
- Kapelj S., Kapelj J., Prelogović E., Marjanac T., *Studija upravljanja vodama sliva Jadra i Žrnovnice. Prva faza studijsko-istraživačkih radova*, Geotehnički fakultet, Fond stručne dokumentacije, Varaždin, br. 637/02, 2006.
- Kapelj S., Kapelj J., Jukić D., Denić-Jukić V., *Studija upravljanja vodama sliva Jadra i Žrnovnice. Druga faza studijsko-istraživačkih radova*, Geotehnički fakultet, Fond stručne dokumentacije, Varaždin, br. 538/02, 2008.
- Kapelj S., Kapelj J., Švonja M., *Hidrogeološka obilježja sliva Jadra i Žrnovnice*, 5, pp. 205–216, 2012.
- Katsanou K., Lambrakis N., Tayfur G., Baba A., *Describing the Karst Evolution by the Exploitation of Hydrologic Time-Series Data*, Water Resources Management 29, pp 3131–3147, 2015.
- Kiraly L., Perrochet P., Rossier Y., *Effect of the epikarst on hydrograph of karst springs: a numerical approach*, Bull. Centre Hydrogeol. Neuchatel, 14, pp 199–220, 1995.
- Kiraly L., *Karstification and groundwater flow, in Evolution of Karst: from Prekarst to Cessation* (ed. F. Gabrovsek), Institut za raziskovanje krasa, ZRC SAZU, Postojna-Ljubljana, pp. 155–90, 2002.
- Klimchouk A. B., Ford D. C., Palmer A. N., Dreybrodt W., *Speleogenesis, evolution, of karst aquifers*, Huntsville, Alabama, USA: National Speleological Society, 2000.
- Kovačić G., *Hydrogeological study of the Malenščica karst spring (SW Slovenia) by means of a time series analysis*, Acta Carsologica 39(2), pp 201–215, 2010b.
- Kresic N., Stevanovic Z., *Groundwater hydrology of springs: engineering, theory, management, and sustainability*, Butterworth-Heinemann, Elsevier, Jordan Hill, Oxford, 2010
- Kurtulus B., Razack M., *Evaluation of the ability of an artificial neural network model to simulate the input-output responses of a large karstic aquifer: the La Rochefoucauld aquifer (Charente, France)*, Hydrogeology Journal, 15, pp 241–254, 2006.
- Labat D., Ababou R., Mangin A., *Rainfall-runoff relations for karstic springs. Part I: convolution and spectral analyses*, Journal of Hydrology, 238, pp 123–148, 2000.
- Labat D., Ababou R., Mangin A., *Introduction of wavelet analyses to rainfall/runoffs relationship for a karstic basin: The case of Licq-Atherey karstic system (France)*, Ground Water, 39(4), pp 605-615, 2001.
- Labat D., Sivakumar B., Mangin A., *Evidence for deterministic chaos in long-term high-resolution karstic streamflow time series*, Stochastic Environmental Research and Risk Assessment, 30(8), pp 2189–2196, 2016.

- Larocque M., Mangin A., Razack M., Banton O., *Contribution of correlation and spectral analyses to the regional study of a large karst aquifer (Charente, France)*, Journal of Hydrology, 205(3-4), pp 217–31, 1998.
- Lee L.J.E., Lawrence D.S.L., Price M., *Analysis of water-level response to rainfall and implications for recharge pathways in the Chalk aquifer, SE England*, J. Hydrol., 330(3–4), pp 604–620, 2006.
- Le Moine N., Andreassen V., Mathevet T., *Confronting surface- and groundwater balances on the La Rochefoucauld-Touvre karstic system (Charente, France)*, Water Resources Research 44, W03403, 2008.
- Liang X.S., *Unraveling the cause-effect relation between time series*, Physical Review E - Statistical, Nonlinear, and Soft Matter Physics, 90(5), 2014.
- Loborec J., Đurin B., *Primjena višekriterijske analize u svrhu odabira optimalne metode procjene prirodne ranjivosti krških vodonosnik*, Hrvatske vode, 24(97), pp 193–202, 2016.
- Lohani A.K., Kumar R., Singh R.D., *Hydrological time series modeling: a comparison between adaptive neurofuzzy, neural network and autoregressive techniques*, Journal of Hydrology, 442–443, pp 23–35, 2012.
- Lo Russo S., Amanzio G., Ghione R., De Maio M., *Recession hydrographs and time series analysis of springs monitoring data: application on porous and shallow aquifers in mountain areas (Aosta Valley)*, Environmental Earth Sciences, 73(11), pp 7415–7434, 2015.
- Loukas A., Quick M.C., *Effect of climate change on hydrologic regime of two climatically different watersheds*, Journal of Hydrologic Engineering, ASCE, 1(2), pp 77–87, 1996.
- Malík P., Vojtková S., *Use of Recession-Curve Analysis for Estimation of Karstification Degree and Its Application in Assessing Overflow/underflow Conditions in Closely Spaced Karstic Springs*, Environmental Earth Sciences, 65(8), pp 2245–57, 2012.
- Mangin A., *Etude des debits classes d'exutoires karstiques portant sur un cycle hydrologique*, Annales de speleologie, 28, pp 21–40, 1971.
- Mangin A., *Contribution a l'etude hydrodynamique des aquifers karstiques III*, These de doctorat en Sciences Naturelles, Dijon, Ann. Speleologie, 30, pp 21–24, 1975.
- Mangin A., *Utilisation des analyses correlatoire et spectrale dans l'approche des systemes hydrologiques*, Coptes Rendus de l'Academie des Sciences, Serie III, 293, pp 401–404, 1981.
- Mangin A., *L'approche systemique du karst, consequences conceptuelles et methodologiques*, Proc. Reunion monographica sobre el karst, Larra., pp 141–157, 1982.
- Mangin A., *Pour une meilleure connaissance des systemes hydrologiques a partir des analyses correlatoire et spectrale*, Journal of Hydrology, 67, pp 25–43, 1984.
- Mangin A., *Karst hydrogeology, Groundwater Ecology*, Academic Press, Orlando, Florida, USA, pp 43–67, 1994.

- Massei N., Dupont J.P., Mahler B.J., Laignel B., Fournier M., Valdes D., Ogier S., *Investigating transport properties and turbidity dynamics of a karst aquifer using correlation, spectral, and wavelet analyses*, Journal of Hydrology, 329, pp 244–257, 2006.
- Matas M., *Krš Hrvatske: geografski pregled i značenje*, Split: Hrvatsko geografsko društvo, 2009.
- Mathevet T., Lepiller M., Mangin A., *Application of time-series analyses to the hydrological functioning of an Alpine karstic system: the case of Bange-L'Eau-Morte*, Hydrology and Earth System Sciences, 8(6), pp 1051–64, 2004.
- Mayaud C., Wagner T., Benischke R., Birk S., *Single event time series analysis in a binary karst catchment evaluated using a groundwater model (Lurbach System, Austria)*, Journal of Hydrology, 511, pp 628–39, 2014.
- Milanović P., *Hidrogeologija karsta i metode istraživanja*, Trebinje: Institut za korišćenje i zaštitu voda na kršu, 1979.
- Mirza M.Q., Warrick R.A., Ericksen N.J., Kenny G.J., *Trends and persistence in precipitation in the Ganges, Brahmaputra and Meghna river basins*, Hydrological Sciences Journal, 43(6), pp 845-858, 1998.
- Morozov A. A., *Korišćenje vodnih snaga*, 1. izdanje, Udruženje studenata građevinske tehnike T. V. Š., Beograd, 1954.
- Novel, J.P., Dimadi A., Zervopoulou A., Bakalowicz M., *The Aggitis karst system, Eastern Macedonia, Greece: Hydrologic functioning and development of the karst structure*, Journal of Hydrology 334, pp 477–492, 2007.
- Padilla A., Pulido-Bosch A., *Study of hydrographs of karstic aquifers by means of correlation and cross-spectral analysis*, Journal of Hydrology, 168(1-4), pp 73–89, 1995.
- Padilla A., Pulido-Bosch A., *Simple procedure to simulate karstic aquifers*, Hydrol Process, 22(12), pp 1876–1884, 2008.
- Pagliara S., Viti C., Gozzini B., Meneguzzo F., Crisci A., *Uncertainties and trends in extreme rainfall series in Tuscany, Italy: Effects on urban drainage networks design*, Water Science and Technology, 37(11), pp 195-202, 1998.
- Panagopoulos G., Lambrakis N. *The contribution of time series analysis to the study of the Hydrodynamic characteristics of the karst systems: application on two typical karst aquifers of Greece (Trifilia, Almyros Crete)*, Journal of Hydrology, 329(3-4), pp368–76, 2006.
- Partal T., Kahya E., *Trend analysis in Turkish precipitation data*, Hydrological Processes, 20, pp 2011–2026, 2006.
- Pinault J.L., Plagnes V., Aquilina L., Bakalowicz M., *Inverse modelling of the hydrological and the hydrochemical behaviour of hydrosystems: characterization of karst system functioning*, Water Resources Research, 37(8), pp 2191–2204, 2001.

- Pulido-Bosch A., Padilla A., Dimitrov D., Machkova M., *The discharge variability of some karst springs in Bulgaria studied by time series analysis*, Hydrological Sciences Journal, 40(4), pp 517–32 1995.
- Raghuwanshi N.S., Wallender W.W., *Field measured evapotranspiration as a stochastic process*, Agricultural Water Management, 32, pp 111-129, 1997.
- Rahnemai M., Zare M., Nematollahi A.R., Sedghi H., *Application of spectral analysis of daily water level and spring discharge hydrographs data for comparing physical characteristics of karstic aquifers*, Journal of Hydrology, 311, pp 106–116, 2005.
- Reed D.W., Jakob D., Robson A.J., *Statistical procedures for flood frequency estimation*, In: A.J. Robson and D.W. Reed (editors), Flood Estimation Handbook, Vol. 3, Institute of Hydrology, pp 338, 1999.
- Robson A.J., Neal C., *Water quality trends at an upland site in Wales, UK, 1983-1993*, Hydrological Processes, 10(2), pp183-203, 1996.
- Salas J.D., Delleur J.W., Yevjevich V., Lane W.L., *Applied modeling of hydrologic time series*, Water Resources Publications, Colorado, USA, 1980.
- Samani N., *Response of karst aquifers to rainfall and evaporation, Maharlu Basin, Iran*, Journal of Cave and Karst Studies, 63(1), pp 33-40, 2001.
- Sánchez D., Barberá J., Mudarra M., Andreo B., *Hydrogeochemical tools applied to the study of carbonate aquifers: examples from some karst systems of Southern Spain*, Environmental Earth Sciences, 74(1), pp 199-215, 2015.
- Stark E., *Partial Cross-Correlation Analysis Resolves Ambiguity in the Encoding of Multiple Movement Features*, J. Neurophysiology., 95(3), pp 1966–1975, 2006.
- Stepinac A., *Režim gubitaka otjecanjem u krškim vodotocima u prirodnom stanju*, Građevinar, 35(7), pp 279-288, 1983.
- Sun S., Khu S.-T., Djordjević S., *Sampling rainfall events: a novel approach to generate large correlated sample*. Hydrology Research, 44 (2), pp 351-361, 2013.
- Shumway R.D., Stoffer D.S., *Time Series Analysis and its Applications*, Springer Verlag, New York, 2000.
- Tam V.T., De Smedt F., Batelaan O., Dassargues A., *Characterization of a cavern conduit system in Vietnam by time series correlation, cross-spectrum and wavelet analyses*, Hydrology Sciences Journal, 49 (5), pp 879–900, 2004.
- Terzić J., Stroj A., Frangen T., *Hydrogeological investigation of karst system properties by common use of diverse methods: a case study of Lic'ka Jesenica springs in Dinaric karst of Croatia*, Hydrological Processes, 26(21), pp 3302–3311, 2012.
- Tkach D., Reimer J., Hatsopoulos N.G., *Congruent activity during action and action observation in motor cortex.*, J. Neurosci., 27(48), pp 13241–13250, 2007.

- Treble P.C., Budd W.F., Hope P.K., Rustomji P.K., *Synoptic-scale climate patterns associated with rainfall $\delta^{18}O$ in southern Australia*, Journal of Hydrology, 302, pp 270–282, 2005.
- Valdes, D., Dupont, J.P., Massei, N., Laignel, B., Rodet, J., *Analysis of karst hydrodynamics through comparison of dissolved and suspended solids' transport*, C. R. Geoscience 337, pp 1365–1374, 2005.
- Valdes, D., Dupont, J.P., Massei, N., Laignel, B., Rodet, J., *Investigation of karst hydrodynamics and organization using autocorrelation and T-curves*, Journal of Hydrology 329, pp 432–443, 2006.
- Valipour M., Banihabib M.E., Behbahani S.M.R., *Monthly inflow forecasting using autoregressive artificial neural network*, J. Appl. Sci., 12(20), pp 2139–2147, 2012.
- Valipour M., Banihabib M.E., Behbahani S.M.R., *Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir*, Journal of Hydrology, 476, pp 433–441, 2013.
- Vandenbohede A., Hermans T., Nguyen F., Lebbe L., *Shallow heat injection and storage experiment: Heat transport simulation and sensitivity analysis*, Journal of Hydrology, 409(1–2), pp, 262–272, 2011.
- Vervier P., Pinheiro A., Fabrec A., Pinayd G., Fustec E., *Spatial changes in the modalities of N and P inputs in a rural river network*, Water Res., 33(1), pp 95–104, 1999.
- Walliser B., *Systemes et modeles*, Seuil, Paris, France, 1977.
- Westmacott J.R., Burn D.H., *Climate change effects on the hydrologic regime within the Churchill-Nelson River Basin*, Journal of Hydrology, 202(1–4), pp 263–279, 1997.
- White W. B., *Geomorphology and hydrology of karst terrains*, New York: Oxford University Press, 1988.
- White W.B., *Karst hydrology: recent developments and open questions*. Eng. Geol., 65, pp 85–105, 2002.
- Wu C.L., Chau K.W., *Rainfall-runoff modeling using artificial neural network coupled with singular spectrum analysis*, Journal of Hydrology, 399(3–4), pp 394–409, 2011.
- Yevjevich V., Jeng I. R., *Properties of non-homogeneous hydrologic series*, Hydrology Papers, Colorado State University, Fort Collins, Colorado, 32, 1969.
- Zhang X., Harvey K.D., Hogg W.D., Yuzyk, T.R., *Trends in Canadian streamflow*. Water Resources Research, 37(4), pp 987–998, 2001.
- Zhou Y., Zhang Q., Singh V.P., Xiao M., *General correlation analysis: a new algorithm and application*, Stochastic Environmental Research and Risk Assessment, 29(3), pp 665–677, 2014.
- Zupan Hajna N., Ravbar N., Rubinić J., Petrič M., *LIFE AND WATER ON KARST, Monitoring of transboundary water resources of Northern Istria*, 2015.

Željковиć I., Kadić A., *Groundwater balance estimation in karst by using simple conceptual rainfall-runoff model*, Environ. Earth Sci., 74(7), pp 6001–6015, 2015.

Žugaj R., *Hidrološke podloge za Katastar malih vodnih snaga*, Zbornik radova, IV jugoslavensko savjetovanje „Energetsko iskorišćavanje malih vodotoka i izgradnja malih hidroelektrana“, Arandelovac, pp 8-16, 1984.

Žugaj, R., *Regionalna hidrološka analiza u kršu Hrvatske*, Zagreb: Hrvatsko hidrološko društvo, 1995.

Žugaj R., Andreić Ž., Pavlić K., Fuštar L., *Krivulje Trajanja Protoka*, Građevinar, 63(12), pp 1061–68, 2011.

ŽIVOTOPIS:

Ana Kadić, dipl. ing. građ., rođena je 12. kolovoza 1983. u Männedorfu (Švicarska). Osnovnu i srednju školu završila je u Sinju. Akademske godine 2002./2003. upisuje Građevinski fakultet u Splitu na kojem je diplomirala u listopadu 2008. godine.

U veljači 2009. godine zapošljava se u tvrtci Projektno biro Split d.o.o. gdje kao projektant suradnik sudjeluje u izradi projekata izvedenog stanja, izradi troškovnika, te izradi pogonskih pravilnika upravljanja akumulacijskim bazenom hidroelektrane.

Od listopada 2010. zaposlena je na Fakultetu građevinarstva, arhitekture i geodezije Sveučilišta u Splitu u svojstvu znanstvenog novaka pri Katedri za hidrologiju u sklopu međunarodnog znanstvenog projekta "Croatian – Japanese Project for Risk Identification and Land Use Planning Aimed at Abating the Impact of Natural Disasters Caused by Landslides and Floods in the Republic of Croatia" ("Identifikacije rizika i planiranja korištenja zemljišta za ublažavanje nepogoda kod odrona zemlje i poplava u Hrvatskoj"), te kao asistent sudjeluje u izvođenju nastave na kolegijima Hidrologija i Navodnjavanje i odvodnjavanje.

Na 6. redovitoj sjednici Fakultetskog vijeća održanoj 5. travnja 2017. godine dobila je odobrenje za izradu disertacije pod naslovom "Hidrološki odnosi susjednih krških izvora", a kao mentorica je određena prof. dr. sc. Vesna Denić-Jukić.

Kao autor i koautor sudjelovala je u izradi dva znanstvena rada (indeksirani u Current Contents) te je sudjelovala na tri međunarodna znanstvena skupa.