Primjena tehnologija temeljenih na hidroakustici, radaru i tlačnim senzorima kod praćenja i analize kretanja vode u kršu

Andrić, Ivo

Doctoral thesis / Disertacija

2014

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.032.AndI

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:123:737340

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

FCEAG Repository - Repository of the Faculty of Civil Engineering, Architecture and Geodesy, University of Split

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Splitu
FAKULTET GRAĐEVINARSTVA, ARHITEKTURE I GEODEZIJE

Ivo Andrić, dipl. ing.građ.

PRIMJENA TEHNOLOGIJA TEMELJENIH NA HIDROAKUSTICI, RADARU I TLAČNIM SENZORIMA KOD PRAĆENJA I ANALIZE KRETANJA VODE U KRŠU

Disertacija

Split, 2014.

Ivo Andrić, dipl. ing. građ.
Redni broj: 032

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. emer. dr. sc. Ognjen Bonacci, dipl. ing. građ

Povjerenstvo za ocjenu:

Prof. emer.dr. sc. Ognjen Bonacci, dipl. ing. građ.
Izv. prof. dr. sc. Hrvoje Gotovac, dipl. ing. građ.
Izv. prof. dr. sc. Nenad Buzjak. prof. geogr. i pov.

Povjerenstvo za obranu:

Prof. emer.dr. sc. Ognjen Bonacci, dipl. ing. građ.

Izv. prof. dr. sc. Hrvoje Gotovac, dipl. ing. građ.

Izv. prof. dr. sc. Nenad Buzjak. prof. geogr. i pov.

Rad je obranjen dana: 12. svibnja, 2014.

Tajnica:

Saša Delić Matas, dipl.iur.

Rad sadrži:

143 stranice teksta

102 crteža

14 tablica

108 referenci

Posvećeno mojoj voljenoj Toniji

"Tijek događaja u životu ne zavisi od nas,

nikako ili vrlo malo,

ali način na koji ćemo te događaje podnijet,

u dobroj mjeri zavisi od nas."

(*Ivo Andrić*)

Zahvala:
Iako ne želim pretvoriti ove retke u nabrajanja meni dragih ljudi u životu, nekako se to ne može izbjeći. Zahvalnost koju želim iskazati na prvom mjestu ide Prof. emer .dr. sc. Ognjenu Bonacciju što mi je pružio priliku prije šest godina i imao strpljenja i volje provesti me do kraja ovog procesa. Zahvalan sam mu na iskazanom povjerenju, svesrdnoj podršci i velikoj pomoći. Od njega sam učio mnogo i ne samo vezane stvari za naš znanstveni rad nego i puno šire. Iskreno tvrdim kako bez njega ne bi bio to što sada jesam. Moja zahvala ide i prof. dr. sc. Vesni Denić-Jukić i prof. dr. sc. Damiru Jukić, divnim ljudima koji su svojim angažmanom uvelike utjecali na moj znanstveni pristup u hidrologiji. Iako službeno nisu moji komentori, ja ih time smatram jer bez njihove pomoći mnogi moji problemi bi neriješeni ostali. Osoba koja mi je u svemu bila potpora, kako u najljepšim trenutcima tako i u najtežim životnim iskušenjima je moja supruga Tonija. Trpila me je u mojim najslabijim i ranjivim trenutcima kao i u momentima euforije. Na tome sam joj neizmjerno zahvalan kao i na njenoj podršci i ljubavi koja me progura kroz svaki dan. Koristim također priliku da se zahvalim i svojoj obitelji, roditeljima i sestri na pomoći i strpljenju. Moram spomenuti prijatelja i kolegu Veljka Srzića s kojim sam proveo sate u korisnim diskusijama vezanim za naša istraživanja te dramsku i glazbenu umjetnost. Nismo se uvijek slagali, ali uzajamno uvažavanje, njegova pomoć i podrška mi je puno značila i još uvijek znači. Na kraju moram spomenuti Mira Kronju i ostale prijatelje koji su vjerovali u mene i bili mi uvijek od pomoći.

UDK [556.08:551.435.8](043.3)

Ivo Andrić, dipl. ing. građ.

PRIMJENA TEHNOLOGIJA TEMELJENIH NA HIDROAKUSTICI, RADARU I TLAČNIM SENZORIMA KOD PRAĆENJA I ANALIZE KRETANJA VODE U KRŠU

Sažetak

Zbog svoje iznimne ranjivosti, krški vodonosnik predstavlja izazov u pogledu zaštite, praćenja, održavanja kvalitete vode i eksploatacije. Hidrološki i hidrogeološki procesi kod krša su ekstremno nepredvidivi zbog anizotropnosti i heterogenosti samog vodonosnika. Procjena regionalne hidrodinamike podzemlja krških terena je često iznimno teška zadaća. Svaki krški vodonosnik ima specifična hidrogeološka i hidrološka svojstva što u konačnici zahtjeva regionalna mjerenja i inkorporaciju prikupljenih saznanja u daljnje modeliranje i upravljanje istim. Razvoj novih tehnologija mjerenja i praćenja vodonosnika u poljima hidroakustike, radara, mjernih senzora i računalne tehnologije, nastaje potreba za implementacijom iste i generiranja novih protokola i metoda mjerenja. Nadalje, nova tehnologija pruža daleko veće mogućnosti te samim time otvara prostor za nove spoznaje vezane za krški vodonosnik te preispituje stare. Vremenska i prostorna rezolucija mjerenja se povećavaju, a računalna tehnologija nudi izvrstan alat za analizu i uspostavljanje modela procesa u prirodi koji vode do boljeg razumijevanja. Glavni pokretač pri izradi ovog rada je stjecanje novih i poboljšavanje starih saznanja o dinamici vode unutar krškog vodonosnika i na površini proučavajući podzemnu dinamiku vode u špiljama i jamama kao i površinsku na primjeru krških jezera i otvorenih vodotoka. Nove spoznaje vezane za prirodu kretanja vode u krškom terenu rezultiraju upravo eksperimentalnim pristupom i mjerenju različitih hidroloških epizoda unutar izrazito heterogenog sustava. U ovom radu se prikazuju kontinuirana hidrološka mjerenja izvedena u dubokoj krškoj jami te se uspostavljaju modeli mjerenih parametara. Nadalje, primjenjuje se probabilistički koncept mjerenja protoka na otvorenom vodotoku kod nepravilnih profila te se pritom uvode novi protokoli mjerenja. Po prvi puta detaljno su snimljena morfometrijska mjerenja Crvenog i Modrog jezera kod Imotskog s najnovijim dostupnim tehnologijama te kontinuirana hidrološka mjerenja Modrog jezera. Prezentiran je također i uspostavljeni hidrološki model za Modro jezero.

Ključne riječi: Crveno jezero, Modro jezero, Hidrologija krša, hidroakustika, radar, tlačni senzori

UDC [556.08:551.435.8](043.3)

Ivo Andrić, dipl. ing. građ.

APPLICATION OF TECHNOLOGIES BASED ON HYDROACOUSTICS, RADAR AND PRESSURE SENSORS IN MONITORING AND ANALYSIS OF WATER MOVEMENT IN KARST

Summary

Because of its extreme vulnerability karst aquifer is a challenge in terms of protection, monitoring, maintenance of water quality and exploitation. Hydrologic and hydrogeological processes in karst are extremely unpredictable because of anisotropy and heterogeneity of the aquifer. Assessment of regional hydrodynamics of underground karst terrain is often extremely difficult task. Each karst aquifer has specific hydrogeological and hydrologic properties, which ultimately require a regional measurement and incorporation of gathered data in further modelling and management. The development of new technology based measurement and monitoring of aquifers in the fields of hydro acoustics, radar measurement, sensors and computer technology creates a need to implement the existing and generate the new protocols and methods of measurement. Furthermore, the new technology provides far greater opportunities and thus they open up new insights related to karst aquifer and revise the old ones. Temporal and spatial resolution of measurements increase whereas computer technology offers an excellent tool for analyzing and establishing a models of processes in nature that lead to a better understanding. The main motivation for this dissertation is the gaining of new knowledge in the dynamics of water within the karst aquifer and on the karst surface, as well as improvement and validation of old findings by studying the dynamics of underground water in the caves and in the case of surface karst lakes and open streams taking into account Experimental approach and measurement of hydrological episodes within a highly heterogeneous system result with a new insight in the nature of water movement in the karst terrain. The continuous hydrological measurements in a deep karst cave and established models of the measured parameters are presented in this work. Furthermore, the probabilistic concept of discharge measurement in open water course with irregular profile was carried out which led to introduction of new measurement protocols. For the first time, the detailed morphometric measurements using available emerging technologies were conducted for Red Lake and Blue Lake near Imotski. Continuous hydrological measurements of Blue Lake resulted with a hydrological model which is also presented in this work.

Keywords: Red Lake, Blue Lake, Karst hydrology, Hydroacoustics, Radar, Pressure sensors

SADRŽAJ

1. UVOD 1

1.1 ZNAČENJE MJERENJA U HIDROLOGIJI KRŠA 1

1.3 KONCEPTUALNI MODEL KRŠKOG VODONOSNIKA 5

1.3 PREGLED OSNOVNIH ALATA KORIŠTENIH U SVRHU PRIKUPLJANJA PODATAKA U KRŠKOM VODONOSNIKU 7

1.3.1 Speleološka istraživanja 7

1.3.2 Hidrološka i hidrometrijska mjerenja 9

1.3.3 Postprocesiranje prikupljenih podataka 13

1.3 SADRŽAJ RADA 18

2. POSTOJEĆA SAZNANJA I CILJEVI DISERTACIJE 21

2.1 KRŠKI VODONOSNICI 22

2.2 OČEKIVANI DOPRINOSI DISERTACIJE 31

3. METODOLOGIJA 33

3.1 TERENSKA OPREMA 34

3.1.1 Tlačni senzori (CTD sonde) 34

3.1.2 Hidroakustika 38

3.1.3 Radar 45

3.1.4 LiDAR tehnologija i digitalna fotogrametrija 46

3.2 HIDROMETRIJSKE METODE MJERENJA 49

3.3 METODE ANALIZE PODATAKA I MODELIRANJE 57

3.3.1 Višestruki linearni regresijski modeli 57

3.3.2 Neuralne mreže 60

3.3.3 Probabilistički pristup određivanja protoka 66

3.3.4 Linearni i nelinearni rezervoar 69

3.3.5 Model vlage u tlu 73

4. PODRUČJE ISTRAŽIVANJA 78

4.1 GEOLOŠKE I GEOGRAFSKE ZNAČAJKE PODRUČJA ISTRAŽIVANJA 79

4.1.1 Jama Nevidna voda 80

4.1.2 Sliv rijeke Cetine 84

4.1.3 Modro i Crveno jezero 86

4.2 HIDROGEOLOŠKE I HIDROLOŠKE ZNAČAJKE PODRUČJA ISTRAŽIVANJA 89

5. LOKALNA I REGIONALNA PREZENZACIJA REZULTATA 93

5.1 HIDRODINAMIKA DUBOKE JAME NEVIDNA VODA 94

5.2 PROBABILISTIČKI PRISTUP MJERENJA PROTOKA NA CETINI 104

5.3 HIDROLOŠKA I GEOMORFOLOŠKA MJERENJA NA MODROM I CRVENOM JEZERU KOD IMOTSKOG 111

5.4 DISKUSIJA 125

6. ZAKLJUČCI I PRAVCI DALJNJIH ISTRAŽIVANJA 130

6.1 ZAKLJUČCI 130

6.2 MOGUĆI PRAVCI DALJNJIH ISTRAŽIVANJA 133

7. LITERATURA 135

1. UVOD

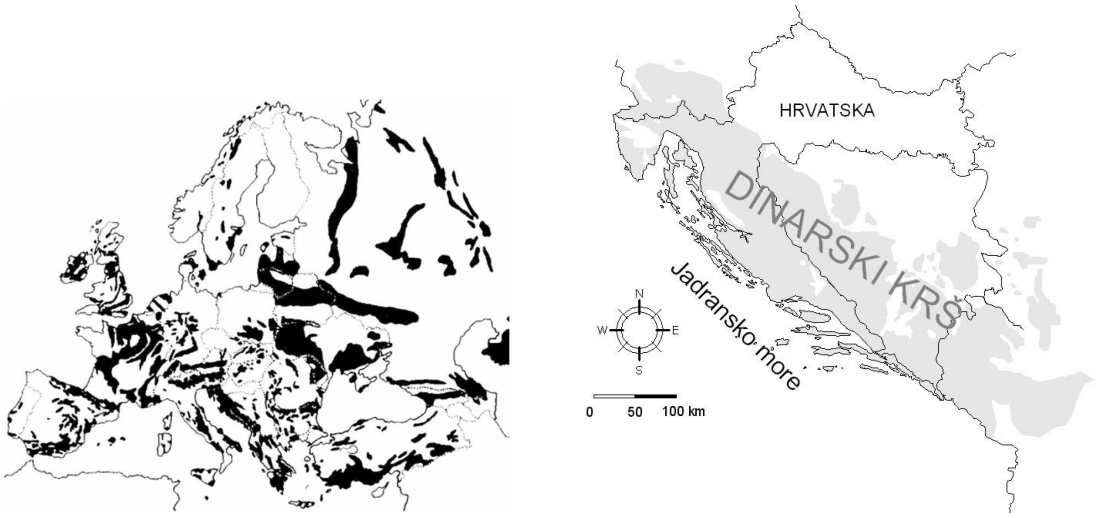
1.1 ZNAČENJE MJERENJA U HIDROLOGIJI KRŠA

Između pojmova voda i život može se staviti znak jednakosti. Osnovni preduvjet za život kroz cjelokupnu povijest našeg planeta je bila dostupnost vode. Potraga za vanzemaljskim oblikom života se također temelji na potrazi za vodom. U svakodnevnom životu se možda i zanemaruje značaj vode i njena dostupnost no svakako i najmanja oskudica prouzročena ograničenjima dragocjenog resursa, tehničkim razlozima vezanim za opskrbu ili pak kemijskom i mikrobiološkom neispravnosti, mogu prouzročiti snažne odjeke u društvu i prirodi te se brzo voda ponovno nađe u žarištu moderne svakodnevnice. Hidrološki ciklus je permanentni proces cirkulacije vode na Zemlji kojem je glavni pokretač sunčeva energija. Pri tom se procesu voda dobrim dijelom zadržava i u vodonosnicima koji uz površinske tokove predstavljaju najčešće količine pitke vode dostupne čovjeku. Vodonosnik se ukratko može opisati kao sloj pijeska, šljunka ili frakturirane stijene koji iznad nepropusne barijere ima funkciju spremnika vode prilikom njene cirkulacije u prirodi. Pjeskovita i šljunkovita tla su vodonosnici aluvijalnog porijekla, a najčešći vodonosnik načinjen od frakturiranih stijena je upravo krški vodonosnik. S obzirom na dostupnost pitke vode na svijetu uslijed njene distribucije (slika 1.1), postavlja se pitanje zastupljenosti krškog vodonosnika i količina vode.



Slika 1.1 Distribucija vodnih resursa svijeta (www.unwater.org).

Ako se ima na umu da se karbonatne stijene, za koje su najčešće vezani krški prostori, prostiru na oko 30 milijuna km^2 ili na oko 20% ukupne svjetske kopnene površine [F4], a oko 30% svih količina slatke vode se nalazi u podzemlju, važnost krškog vodonosnika poprima značaj i zauzima mjesto kao jedna od centralnih disciplina u geoznanostima. Slika 1.2.a prikazuje rasprostranjenost karbonatnih stijena u Europi. Vidljivo je da su krški tereni značajno zastupljeni u cijeloj Europi, a u Hrvatskoj prekrivenost kopnenog dijela karbonatnim stijenama, prikazano na slici 1.2.b, iznosi nešto manje od polovice cjelokupnog teritorija.[B10, R6].



(a) (b)

Slika 1.2 Rasprostranjenost karbonatnih stijena a) u Europi (COST 65 1995, Goldscheider 2002) i b) na području Dinarskog krša

Krš se definira kao teren sastavljen od posebnog površinskog i podzemnog reljefa te površinske i podzemne hidrografske mreže koja je nastala kao rezultat cirkulacije vode te njenog agresivnog kemijskog i fizičkog djelovanja na prsline, pukotine i šupljine u slojevima topivih stijena kao što su vapnenac, kreda, dolomit, gips i sol [B10] te breče i konglomerati [T1]. Kako

krški teren prekriva oko 20 % Zemljine nezaleđene površine, četvrtina svjetske populacije se snabdijeva vodom iz krških vodonosnika [F4]. Uz aluvij, krš predstavlja najvažniju formaciju vodonosnika na svijetu. Zbog svoje iznimne ranjivosti, krški vodonosnik predstavlja izazov u pogledu zaštite, praćenja, održavanja kvalitete vode i eksploatacije.

Karbonatne stijene od kojih je krški teren sačinjen mnogo se brže otapaju od ostalih vrsta stijena. Uz to su izvrgnute brojnim geomorfološkim procesima, a osobito denudacijom [B8]. Različiti i vrlo često spektakularni površinski krški oblici praćeni su postojanjem nepredvidivih podzemnih krških oblika, prije svega velikih krških provodnika [B14]. Međutim, nerijetko se dešava da su površinski krški oblici rijetki, a da su podzemni brojni i složeni. Svaki krški sustav podložan je brzim promjenama kako onim prirodnim, a u današnje vrijeme sve više i onim antropogenim. Zbog toga izučavanje bilo kojeg krškog sustava traži individualan pristup zasnovan na brojnim pažljivo organiziranim mjerenjima različitih, prije svega hidroloških, hidrogeoloških i klimatoloških parametara.

Hidrološki i hidrogeološki procesi kod krša su ekstremno nepredvidivi zbog anizotropnosti i heterogenosti samog vodonosnika. Prostorna distribucija provodnika unutar krškog vodonosnika je visokim dijelom nepoznata. U ovisnosti o stupnju razvijenosti krša, može se govoriti o tri tipa poroznost krškog vodonosnika [B4, B5, B10, B13, B16, F4, J2-J4, P10, W2, W5], a to su:

- Međuzrnate šupljine ili krška matrica koja se sastoji i od mikro-prslina i pukotina (primarna poroznost),
- Pukotine i prsline (sekundarna poroznost),
- Krški provodnici (tercijarna poroznost).

Prema tome krški vodonosnik je sačinjen od topivih stijena koje svojim nepredvidivim trošenjem uslijed djelovanja vode, rezultiraju u anizotropnosti i heterogenosti te se pri tom razvijaju tri vrste poroznosti i propusnosti kroz kršku matricu, pukotine i prsline te provodnike. Zbog toga parametrizacija krškog vodonosnika predstavlja velik izazov jer je u kršu kroz provodnike moguć turbulentan tok za razliku od isključivo laminarnog toka unutar aluvijalnog vodonosnika.

Krški vodonosnici su izrazito složene strukture te ih je stoga teško definirati. Velika heterogenost krških vodonosnika otežava određivanje smjerova i brzina tečenja podzemne vode u kršu te je često i nemoguć zadatak za hidrologe i hidrogeologe. Hidraulička provodljivost unutar krškog vodonosnika je izrazito anizotropna, a činjenica da u kršu istovremeno postoji turbulentno tečenje kroz veće krške provodnike kao i sporo laminarnog tečenje kroz sitne pukotine krške

matrice [B13] predstavlja izazov kod izučavanja istog. Vodotoci u kršu pobuđuju veliki interes kod znanstvenika i zauzimaju značajan prostor u literaturi o kršu [A1, A2, B3-B6, B9-B22, C1, C7-C9, D2, D3, F4, G1-G3, G5-G7, J2-J5, K1, K2, M1, M3, M5, P1, P2, P8, P10, R2, R5, R6 W2-W4].

Procjena regionalne hidrodinamike podzemlja krških terena je često iznimno teška zadaća. Svaki krški vodonosnik ima specifična hidrogeološka i hidraulička svojstva što u konačnici zahtjeva regionalna mjerenja i inkorporaciju prikupljenih saznanja u daljnje modeliranje i upravljanje istim.

Krš posebno karakterizira međusobno snažno uvjetovana interakcija između površinskih i podzemnih voda [B13]. Podzemna i površinska voda hidrološki su povezane kroz velik broj krških oblika koji omogućavaju izmjenu podzemne i površinske vode. Brze i velike oscilacije razina podzemnih voda u kršu utječu izravno na hidrološki i hidrogeološki režim otvorenih vodotoka, ali i onih koji teku podzemljem krša. Prilikom njihovog izučavanja treba imati na umu da su podzemne vode kao i podzemni vodotoci u kršu izrazito heterogeni po svojim morfološkim oblicima, te kao posljedica toga i po hidrauličkim, hidrološkim i hidrogeološkim karakteristikama.

U krškim terenima podzemne i površinske vode tvore jedinstveni dinamički sustav. Posljedica toga je da većina otvorenih vodotoka povremeno ili stalno, u cijelosti ili djelomično gubi dio vode u krško podzemlje [B13, F4, W2]. Dinarski krš obiluje dubokim jamama koje se kao podzemni krški oblik učestalo pojavljuju na nadmorskim visinama većim od 1000 m n.m. Vertikalni kanali služe kao kolektori površinskih i podzemnih voda. Drugim riječima oni su privilegirani kanali u kojima se skuplja voda s površine i podzemlja autohtonog krškog sustava te se mogu smatrati svojevrsnim prirodnim pijezometrima. Dinamika hidrološkog sustava pojedine jame je izravno vezana za oborinu kao glavni izvor prehranjivanja vodonosnika kroz nezasićenu zonu istog. Nadalje, topljenje snijega je također mehanizam unosa tvari, kao i pronosa temperature kroz vodu nezasićene zone. Osciliranja razine zasićenog područja vodonosnika su podložne jakim oscilacijama. Razina podzemne vode se mijenja brzinom i do preko 1m/h, a oscilacije mogu biti i preko 100 m [B16].

Nadalje, krška jezera s ekstremnim sezonskim oscilacijama u vodostaju su ne tako čest fenomen u kršu, ipak, od iznimnog su značaja za proučavanje krškog vodonosnika, jer kao i duboke jame predstavljaju svojevrsne pijezometre u terenu [B11, B21], te velikim dijelom preslikavaju kretanja podzemne vode. Vodostaji se mijenjaju sezonski te u jednoj hidrološkoj godini mogu ići od svog maksimuma do presušivanja. Iako takva postoje na centralnoj Floridi (SAD), pa i u krškom terenu južne Kine, najpoznatija su zasigurno jezera kod Imotskog.

Crveno i Modro jezero kod Imotskog predstavljaju jedne od najfascinantnijih, vrlo rijetkih ali i sa stanovišta znanosti nedovoljno objašnjenih fenomena Dinarskog krša Hrvatske [B15]. Nalaze se u neposrednoj blizini (udaljena jedno od drugog tek oko 500 m). Crveno jezero je nešto poznatije i u literaturi češće opisivano. Iako se radi o svjetski poznatim krškim geomorfološkim vodnim objektima činjenica je da su oni u biti znanstveno neistraženi. U malobrojnoj stručno-znanstvenoj literaturi uglavnom su iznesene njihove geološke, geografske i geomorfološke karakteristike [C8, D1, G5, P8, R5, R6]. Hidrološki i hidrogeološki aspekti funkcioniranja ovih jezera slabo su izučeni. Osnovni razlog leži u nedostatku mjerenja, prije svega razine vode u samim jezerima, a osobito razine podzemne vode u njihovoj široj i užoj okolici [B11].

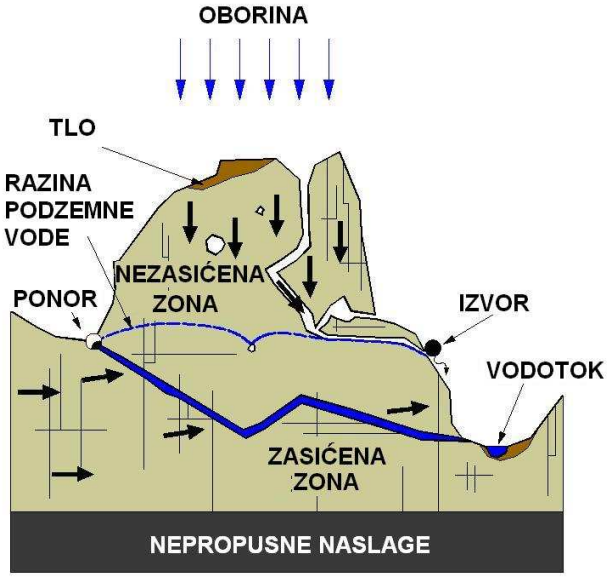
Razvoj novih tehnologija mjerenja i praćenja vodonosnika u poljima hidroakustike, radara, mjernih senzora i računalne tehnologije, nastaje potreba za implementacijom iste i generiranja novih protokola i metoda mjerenja. Nadalje, nova tehnologija pruža daleko veće mogućnosti te samim time otvara prostor za nove spoznaje vezane za krški vodonosnik te preispituje stare. Upravo iz ovih razmatranja proizlazi potreba i glavni pokretač za izradu ove disertacije koja za cilj ima stjecanje novih i poboljšavanje starih saznanja o dinamici vode unutar krškog vodonosnika kao i na površini proučavajući podzemnu dinamiku vode u špiljama i jamama kao i površinsku na primjeru krških jezera i otvorenih vodotoka uzimajući u obzir lokalnu i regionalnu skalu. Pri tom implementacija novih tehnologija u hidrologiji krša predstavlja poseban izazov i dodatnu motivaciju za usvajanje novih metoda i razvijanje postojećih.

1.2 KONCEPTUALNI MODEL KRŠKOG VODONOSNIKA

Konceptualni model hidrološkog krškog sustava i krškog vodonosnika je temeljen na razumijevanju geoloških karakteristika krškog vodonosnika, površine sliva, površine sliva na mjestima alogenog (točkastog) punjenja vodonosnika (ponori), količinama i režimu oborina, kao i geomorfologiji provodnika unutar krške matrice prikazano na slici 1.3.

Razvijanje konceptualnih modela je proizašlo iz potrebe boljeg razumijevanja i modeliranja prirodnih procesa unutar krškog vodonosnika [B9-B22, F4, G1, G2, G5, J2-J5, W2] što predstavlja nimalo laku zadaću. Iako model predstavlja grubo pojednostavljenje kompleksnih fizikalnih i kemijskih procesa u prirodi, njihovo uvođenje kao alat istraživanja i analize krškog vodonosnika je važan dio svakog znanstvenog rada. Pri tom treba biti jako oprezan sa zaključcima temeljenim na modelima jer često zanemarene važne komponente te nedovoljno uključene u

model rezultiraju oprečnim rezultatima s realnim stanjem u prirodi. Slika 1.3 prikazuje široko prihvaćeni model krškog sustava, tj. krškog vodonosnika za područje Dinarskog krša [G1].



Slika 1.3 Jednostavni konceptualni model hidrološkog krškog sustava sa svojim elementima i sustavom toka

Kod modeliranja u krškim vodonosnicima, nameću se dvije glavne kategorije, modeliranje evolucije krškog vodonosnika i modeliranja toka podzemnih voda kroz već formirani krški vodonosnik. Prva kategorija potražuje odgovore na pitanja o samoj genezi krša, procesima koji kroz vrijeme oblikuju kršku matricu, a druga kategorija pomaže kod razumijevanja mehanizama u kršu, tj. interakcije vode s okolinom u podzemlju.

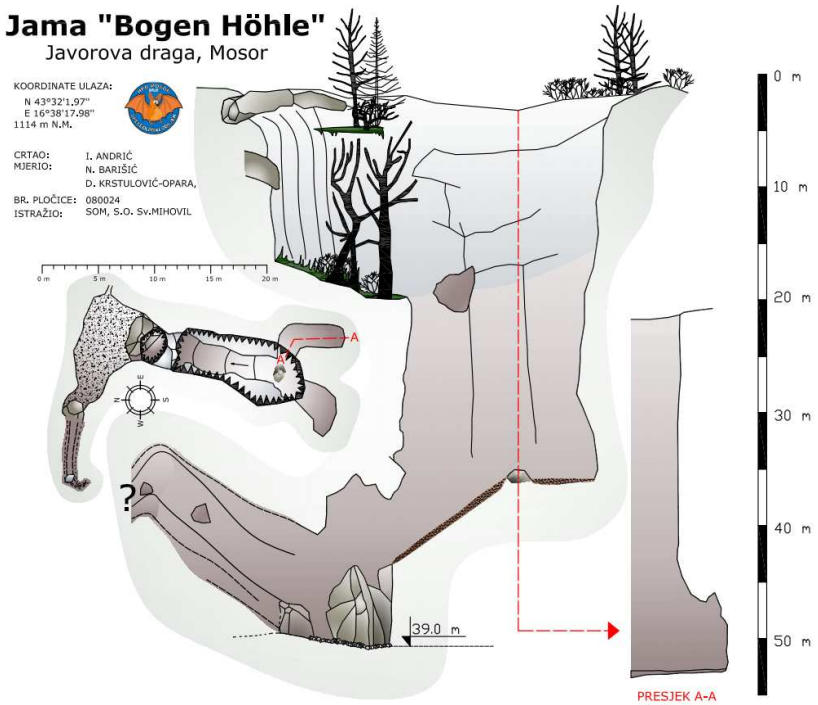
Modeliranje mora imati svoju svrhu, bilo to spoznavanje o pojavama i sustavu koji se proučava ili predviđanje posljedica uslijed predloženih djelovanja. Važno je naglasiti, da se svrha modela mora definirati na samom početku. Kada je svrha modela jasna i definirana, potrebno je osmisliti konceptualni model krškog vodonosnika, koji može pak biti konceptualno definiran ili prema području izučavanja.

Postoji više različitih pristupa kod matematičkog modeliranja sustava krškog vodonosnika koji će biti pobliže opisani u narednim poglavljima. Svaki matematički model u tom kontekstu može imati svoje prednosti, ali isto tako i nedostatke pri svojem korištenju [W4]. Mora se svakako još jednom naglasiti da kompleksnost sustava ni u kojem slučaju ne može biti reprezentirana modelom, ona može biti samo bolje ili lošije opisana.

1.3 PREGLED OSNOVNIH ALATA KORIŠTENIH U SVRHU PRIKUPLJANJA PODATAKA U KRŠKOM VODONOSNIKU

1.3.1 Speleološka istraživanja

Speleološko istraživanje se sastoji od više komponenti koje podrazumijevaju rekognosciranje krškog terena i samo lociranje speleoloških objekata (špilja i jama), prolaženje kroz njihove kanale, dvorane, vertikale i meandre, mjerenje njihovih dimenzija, topografsko snimanje i izradu nacrta. Praćenje klimatskih parametara u speleološkim objektima kao i fizikalno kemijskih parametara prisutne vode koja može poticati kroz aktivne kanale ili pak procjeđivanjem se nakupljati u vododrživim dijelovima objekta također spada u speleološka istraživanja, no karakteristike tih hidroloških i hidrogeoloških mjerenja nadilaze zadaće speleologa i postaju motivacija i jedna od osnovnih komponenti znanstveno – istraživačkog rada svakog znanstvenika involviranog u istraživanje krša. Izrada topografskog nacrta fizički posjećenih krških kanala osnovnim geodetskim tehnikama, kao što su uspostavljanje poligonalnog vlaka u odnosu na poznate mjere točke (što u speleologiji uobičajeno predstavljaju koordinate ulaza u speleološki objekt), može predstavljati osnovu daljnjeg istraživanja krških provodnika i njihove hidrološke funkcije.



Slika 1.4 Tipični topografski nacrt krške jama (crtao: I. Andrić, mjerili: N. Barišić i D. Krstulović-Opara)

Slika 1.4 predstavlja primjer topografskog nacrta speleološkog objekta. Poznavanje geometrije speleoloških objekta na lokalnoj skali kao i njihova prostorna distribucija na regionalnoj skali su vrlo važne za daljnje analize i praćenja krškog vodonosnika. Snimanje speleoloških objekata tradicionalno sačinjava proces zapažanja pravaca kroz špiljske kanale, njihovog azimuta, duljine i inklinacije. Klasično topografsko snimanje špiljskog objekta ili jame vrši se sa šumarskim kompasom (tandem) što istovremeno nudi informacije o inklinaciji pravca i azimutu (kutu što ga čini sjever i opaženi pravac u smjeru kazaljke na satu). Duljina se mjeri metarskim vrpcama ili laserskim daljinomjerom. Svaki snimatelj speleološkog objekta ima prostora za subjektivni doživljaj prostora kojeg obrađuje te se mnogi detalji skrivaju ili nalaze u izostanku ili izobilju istog. Tehnike napredovanja kroz jamske kanale su vezane za SRT tehniku (Single Rope Technique) koja uz pomoć sustava temeljenim na konopima i osiguravajućim napravama omogućuje vertikalno spuštanje i penjanje.

Istraživanje krškog vodonosnika je nezamislivo bez speleologije, stoga tehnike i zadaće speleologije čine osnovu kod kompleksnijih istražni radova koji mogu sadržavati i korištenje visoko sofisticirane mjerne opreme. Upravo speleološka istraživanja omogućuju direktna opažanja, uzorkovanja i mjerenja. Tako se prilikom istraživanja speleoloških objekata mjere kvaliteta vode kao i neki njeni osnovni fizikalno kemijski parametri (pH i T), a kod praćenja istih kroz duže vremensko razdoblje, instaliraju se uređaji s autonomijom napajanja i memorijom koji mjerenja vrše periodično ili orijentirano ekstremnim događajem. Istraživanja podzemlja krša se znatno unaprjeđuju osiguravanjem telemetrijskog praćenja parametara tako da se memorija svakog mjernog uređaja veže za lokalni GPRS ili 3G modem na ulazu u objekta. Izravnom poveznicom s udaljenim serverom se na taj način uspostavlja konstantan pristup prikupljenim podacima kao i trenutnom mjerenju.

Prostorni raspored speleoloških objekata se dobije stvaranjem katastra istraženih špilja i jama koji sadržava topografske nacrte kao i koordinate ulaza svakog registriranog objekta. Uz pomoć današnje računalne tehnologije i metoda prikupljanja geografskih informacija, GIS (Geografski Informacijski Sustav) baze podataka su moćan alat koji nudi brz uvid u prostornu distribuciju speleoloških objekata unutar promatranog krškog terena kao i detaljne informacije o svakom objektu posebice na dodatni zahtjev korisnika. Nažalost, u Hrvatskoj ne postoji objedinjena baza podataka speleoloških objekata kao u nekim drugim zemljama zbog organizacijskih razloga i prijepora oko nadležnosti na nacionalnoj razini od strane zaduženih institucija i speleoloških društava. Ipak katastri postoje parcijalno i nalaze se u speleološkim

društvima koja marljivo prikupljaju i sistematiziraju podatke o istraženim objektima te ih čuvaju u vlastitim arhivama.

1.3.2 Hidrološka i hidrometrijska mjerenja

Hidrometrija se smatra širim dijelom hidrološke znanosti iako sadrži mnoge elemente hidraulike [H2]. Evidentno je kako se hidrologija, a i mnoga druga vezana područja izravno naslanjaju na podloge i prikupljene podatke s terena koji su rezultat hidrometrijskih mjerenja. Teoretskim i aplikativnim razvijanjem hidrometrije bavi se sve više znanstvenika u svijetu kao i profesionalne javnosti što u konačnici teži ka određivanju hidrometrije kao samostalne znanstvene discipline. Pri definiranju hidrometrije može se upravo smatrati istu kao samostalnu znanost ili pak kao dio hidrologije. U svakom slučaju, može se reći da je hidrometrija znanost o mjerenju vodnog toka u otvorenim kanalima koja sadržava metode, tehnike i instrumentarij hidrologije. Mjerenja su osnova razvoja hidrološke znanosti [B7, B6].

Kako se hidrologija dijeli prema oblicima pojave vode u prirodi, tako i hidrometrija poprima specijalizirana područja kao što su: hidrometrija mora (oceanometrija), hidrometrija atmosferskih voda, hidrometrija površinskih tokova (potamometrija), hidrometrija leda (glaciometrija) te hidrometrija jezera i akumulacija (limnometrija).

Ova disertacija se jednim dijelom bavi hidrometrijom površinskog toka, hidrometrijom jezera kao i hidrometrijom podzemnih voda. Hidrološka mjerena se odnose na proširena istraživanja površinske i podzemne vode s obzirom na njenu fizikalnu i kemijsku kvalitetu.



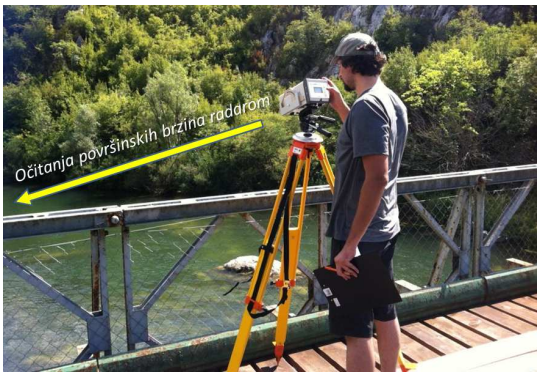
(a) (b)

Slika 1.5 Mjerenje protoka ADCPom a) i ADVom b) na otvorenom vodotoku

Ogromni napredak u hidrometriji se dogodio uporabom hidroakustike sredinom osamdesetih godina prošlog stoljeća. Tada se po prvi put rabi Akustični Dopplerov uređaj za mjerenja profila strujanja (ADCP) kao i Akustični Dopplerov mjerač brzine (ADV).

Slike 1.5.a i 1.5.b prikazuju oba instrumenta pri mjerenju. Za mjerenje brzine toka, 1992. godine se po prvi puta komercijalno stavlja na tržište široko pojasni ADCP uređaj. Ono što je kod oba uređaja zajedničko, to je princip mjerenja brzine, a on se oslanja na osnovne fizikalne principe propagacije zvučnog vala kroz određeni medij (u slučaju hidroakustike to je voda) i Dopplerovog efekta. Dopplerov efekt se može opisati kao relativna promjena frekvencije zvuka koja je rezultat uslijed relativnog gibanja izvora i prijemnika. Kada se izvor vala i prijemnik gibaju relativno jedan u odnosu na drugi prijemnik će opažati drukčiju frekvenciju od one koju odašilje izvor. Ilustrativni primjer Dopplerovog efekta je opažanje zvuka nadolazećeg motornog vozila od strane mirujućeg prijemnika. Frekvencija zvuka koja se opaža prije mimoilaženja izvora i prijemnika je veća od one koja se registrira pri udaljavanju izvora. Opisana razlika u frekvenciji, koja se naziva Dopplerovim pomakom, izravno je proporcionalna brzini izvora zvuka, te ako se ona može izmjeriti, može se i brzina izvora zvuka izračunati. U slučaju hidroakustičnih mjerenja protoka izvor zvuka i prijemnik se nalaze u uređaju,a frekvencija odaslanog zvuka je fiksna vrijednost. Odaslani zvuk se odbija u vodi o suspendirane čestice te mala frakcija odaslanog signala se vraća u prijemnik. Oba uređaja. ADCP i ADV rade na principu Dopplerovog efekta no ADV daje brzinu vode u određenom volumenu uzorkovanja, dakle točkastu vrijednost, dok ADCP sklapa integralni prikaz polja brzina unutar promatranog profila.

Za mjerenje površinskih brzina dostupna tehnologija se razvija u smjeru radarskog praćenja i mjerenja. Princip tehnike je analogan principima hidroakustičnih opažanja brzine unutar vodotoka, no kako medij kroz koji se propagiraju valovi je zrak, a ne voda, izvor signala koristi radio valove umjesto zvučnih. Radarska mjerenja brzine su u primjeni sve češće, posebno pri ekstremnim hidrološkim prilikama zbog jednostavnosti mjerenja i neovisnosti o plovilu na vodotoku za razliku od ADCP uređaja. Slika 1.6 prikazuje mjerenje površinske brzine vodotoka pomoću radarskog uređaja.



Slika 1.6 Mjerenje površinske brzine vodotoka radarskim uređajem

Hidrometriju zastupa dobrim dijelom i zapažanje razine vode. Kroz povijest se bilježe prva zapažanja razine vode još za vrijeme drevnog Egipta. Građevine pod nazivom „Nilometar“ prikazane na slici 1.7.a, služile su za bilježenje razine rijeke Nil i predviđanja ciklusa plavljenja. Danas kod praćenja razine vode i dalje je neizostavna vodomjerna letva no s razvojem mjerne tehnologije pojavljuju se uređaji s laserskim i zvučnim daljinometrima te različiti tlačni senzori koji se koriste za mjerenja razine vode. Tlačni senzor u metalnom ili keramičkom kućištu s internom memorijom se naziva se „data logger“ (uređaj za pohranu podataka). Takav uređaj mjeri ukupan hidrostatski i atmosferski tlak što djeluje na njega te se na osnovu tog očitanja lako može doći do razine vode. Uobičajeno se tlačni senzori kombiniraju s temperaturnim senzorima i elektrodama tako da uz razinu vode mogu mjeriti temperaturu i električnu vodljivost (EC). Takvi uređaj se naziva „CTD data logger“ (Conductivity, Temperature and Depth) te je opremljen autonomnim izvorom napajanja i kapacitiran računalnom memorijom za pohranjivanje mjerenih podataka. Slika 1.7.b prikazuje CTD data logger koji se optičkim sučeljem spaja na računalo zbog programiranja vremenskog intervala mjerenja i očitanja memorije.



(a)



(b)

Slika 1.7 „Nilometar” – preteča vodomjerne letve a) i CTD data logger b)

CTD diver je komercijalni naziv data loggera od proizvođača Schlumberger. On je praktičan zbog svojih dimenzija te ga je moguće koristiti ne samo u otvorenim vodotocima nego i u jezerima, pijezometrima, bunarima i speleološkim objektima.

Vrijednost električne vodljivosti mjereno u μS/cm za krške vode predstavlja važnu informaciju koja se lako može dovesti u korelaciju s ukupno otopljenim krutim tvarima (TDS – Total Dissolved Solids). Nadalje mjerenje daje koncentraciju iona ili informaciju o tvrdoći vode. Informacija o raspodjeli električne vodljivosti za vodeno tijelo na ili u krškom terenu nudi odgovore o vremenu zadržavanja vode unutar vodonosnika kao i o hidrodinamičkim svojstvima toka. Električna vodljivost je mjera koncentracije iona u vodi. Voda koja za zadržava duže unutar krškog vodonosnika otapa više minerala što vodi ka većim vrijednostima električne vodljivosti, a voda koja kraće boravi u podzemlju otapa manje minerala uspoređujući vrijednosti za isti sliv. Analiza promjene električne vodljivosti može doprinijeti boljem razumijevanju krškog vodonosnika iz kojeg voda dospijeva do promatranog krškog fenomena (izvor, estavela ili jezero) [F4].

Kako bi istraživanja vezana za krške fenomene ponudile odgovore vezane za hidrologiju, potrebno je poznavanje njihove morfologije. Zadaća hidrometrije se jednim dijelom sastoji i od morfometrije kao što su radovi snimanja profila riječnog korita ili batimetrije jezera. Klasične metode snimanja profila površinskog toka su evoluirale od mjerenje dubine baždarenim letvama ili utezima na užetu do hidroakustičnih mjerenja što postaju sve više pristupačna široj znanstvenoj i profesionalnoj zajednici.

Mora se naglasiti kako pojavom globalnih i lokalnih digitalnih elevacijskih modela (GDEM i DEM), analiza sliva ili morfologije se svodi na računalni problem iz linearne algebre. Mnoga gotova programska rješenja nude široku paletu alata za analizu morfologije na temelju DEMa. Ono što predstavlja problem je lokalna dostupnost DEM-a. U ovisnosti o traženoj rezoluciji i preciznosti, dostupni podaci za globalne i lokalne elevacijske modele se mogu naći na tržištu ili u sklopu nacionalnih i internacionalnih agencija što ih satelitski snimaju i besplatno nude. Za geografsku širinu na području Dinarskog krša postoje globalni elevacijski modeli rezolucije 100 x 100 m i 30 x 30 m (SRTM i ASTER) koje su satelitski snimile nacionalne svemirske agencije Sjedinjenih Američkih Država i Japana.

Ipak, precizniji modeli se mogu dobiti samo određenim terestrijalnim instrumentima, ako istraživanje se sužava na ograničene površine krškog terena. Tehnologije temeljene na LiDAR (Light Detection And Ranging) metodi mogu dati precizne morfološke modele. Kako bi se model geometrije istraživanog krškog fenomena dobio u većoj rezoluciji nego što globalni modeli to

nude, upotrebljava se terestrialni 3D laserski skener (TLS) s unaprijed zadanom rezolucijom koja može ići i do centimetarskog raspona.

Druga rasprostranjena metoda se zasniva na principima fotogrametrije i uporabe stereo parova digitalnih fotografija. Na osnovu parametara digitalne kamere kao što je fokalna duljina i kutne razlike između uparenih fotografija, geostatistikom se analizira svaki piksel te se njegove RGB vrijednosti i pozicija uspoređuje te pridružuje kako bi se točke od interesa uparile na snimkama. Taj proces vodi do stvaranja digitalnog modela u vektorskom prostoru. Dimenzije dobivenog modela nisu fiksne te se određuju na osnovu unaprijed zadanih definiranih pravaca duljinom i svojim položajem u prostoru, dakle ako predmet na fotografiji ima definiran pravac s definiranom duljinom, to ujedno definira dimenzije i skalu svakog drugog objekta u vektorskom prostoru. Slika 1.8.a prikazuje snimanje TLS uređajem, a slika 1.8.b primjer stereo snimka pri fotogrametrijskim mjerenjem.



(a) (b)

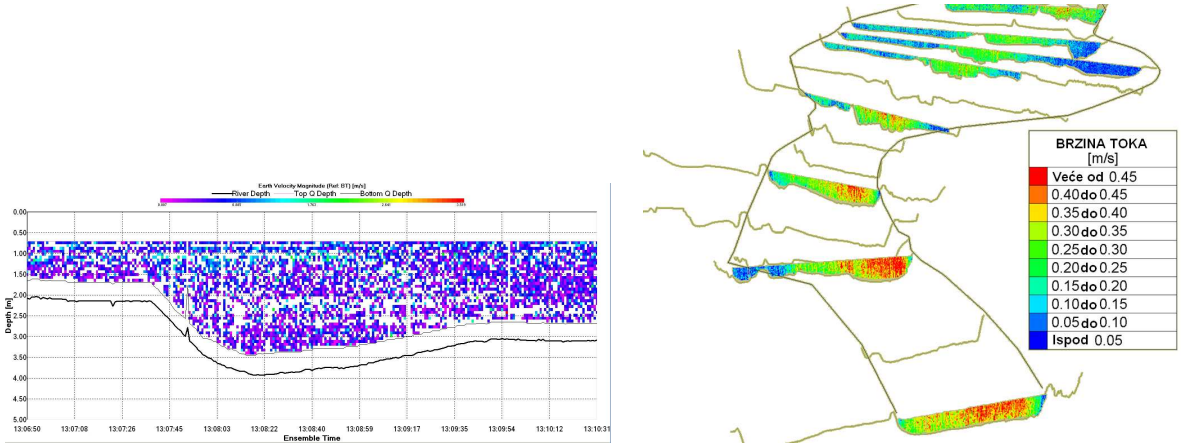
Slika 1.8 Terestrijalni 3D laserski skener (TLS) pri snimanju terena a) i primjer stereo para fotografija pri izradi fotogrametrijskih modela b)

Svaka metoda i tehnologija što se koristi kod morfometrije ima svoje prednosti i mane [H4]. Ipak, kombiniranje dostupnih tehnologija i metoda u pravilno odabranim omjerima može dati zadovoljavajući rezultat za predmetni problem s optimalnom točnošću.

1.3.3 Postprocesiranje prikupljenih podataka

Prikupljanje podataka može se obavljati trenutno tijekom mjerenja te u nekim slučajevima dobrim djelom i obraditi. No u pravilu svi podaci ipak moraju proći dodatnu obradu koja u konačnici smanjuje vjerojatnost pogrešaka koje su neizbježne kod svakog mjerenja. Pogreške mogu imati svoje razloge u raznim čimbenicima kao što su ljudska pogreška, neumjerenost instrumenta ili neispravnost instrumenta, a na onom tko obrađuje podatke leži odgovornost u njihovom detektiranju i uklanjanju.

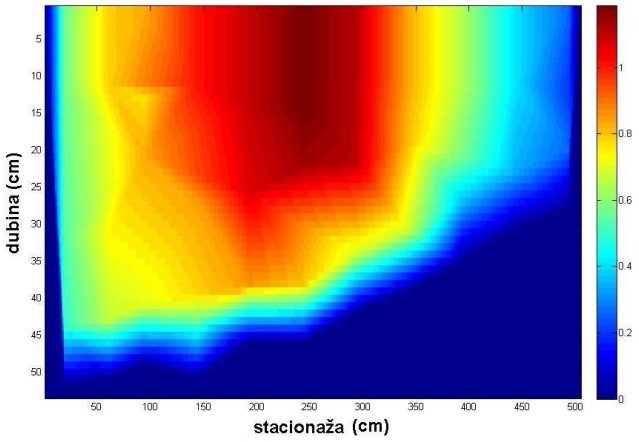
S razvijanjem računalne tehnologije, povećavaju se i mogućnosti kod obrade podataka. Sve više podataka može se obrađivati i uspoređivati sve brže. Kod ADCP snimanja podaci o geometriji korita i polju brzina se prikupljaju insitu te trenutno analiziraju na računalu. Posebna programerska rješenja se u tu svrhu nude od strane proizvođača opreme. Ona omogućuju trenutnu samodijagnostiku instrumenta, kalibraciju na terenu te prikupljanje višestrukih skupova podataka za isto mjerenje kako bi se na osnovu relativnih pogrešaka izbacila kriva mjerenja te jamčila određena pouzdanost prihvaćenih. Slika 1.9.a. prikazuje ADCP snimak poprečnog presjeka rijeke Cetine kod Omiša, a slika 1.9.b primjer vizualizacije više ADCP snimki [S6].



(a) (b)

Slika 1.9 ADCP snimak profila na Cetini kod Omiša a) i primjer vizualizacije više ADCP snimci prema poziciji profila i poznatoj morfometriji b)

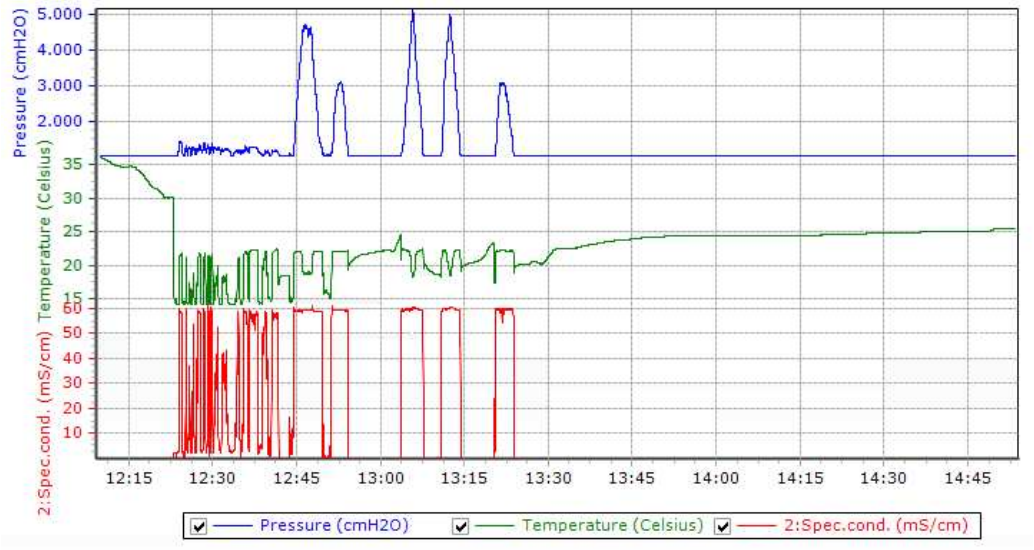
ADV nudi skup točkastih mjerenja unutar promatranog presjeka na odabranim lokacijama od strane korisnika. Na korisniku je da odluči koju metodu ili tip interpolacije će koristiti, kako bi dobio brzine na cjelokupnom presjeku. Slika 1.10 nudi prikaz rasporeda brzina unutar odabranog presjeka na temelju ADV mjerenja.



Slika 1.10 Prikaz brzina toka unutar profila na manjem vodotoku (Sutina kod Sinja) snimljenim ADV uređajem. Brzine su mjerene u m/s.

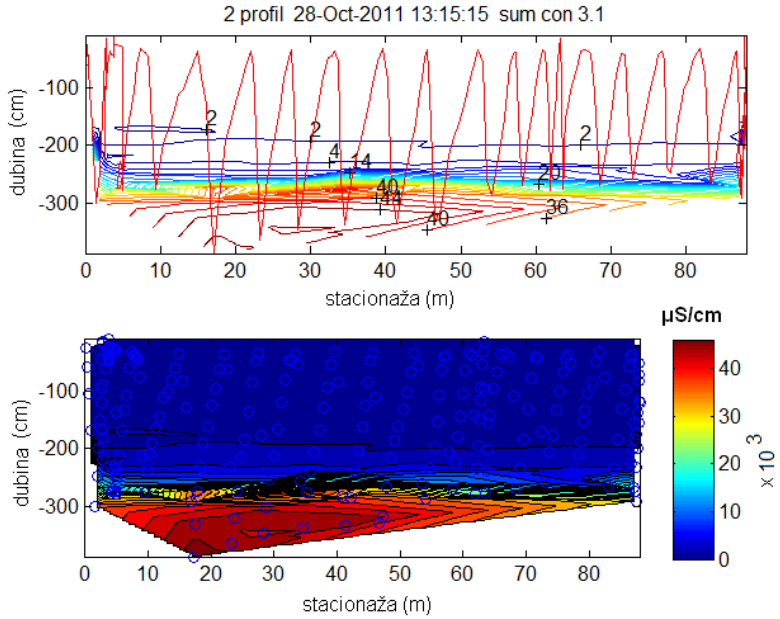
ADCP pri uporabi na većim vodotocima uobičajeno je instaliran sa strane broda ili na posebno izrađenom plovilu od polietilena s trimaranskim koritom. Pri snimanju je od velikog značaja i brzina plovila s kojim ADCP prelazi s jedne obale na drugu koja se kontrolira benzinskim ili električnim motorom, ako je uređaj montiran na brod ili pak s brzinom navlačenja konopa s jedne strane na drugu, ako je uređaj na posebno izrađenom plovilu.

Kod prikupljanja podataka s tlačnih senzora koji bilježe očitanja u internu memoriju, potrebno je prvo očitati podatke s uređaja. Da bi to bilo moguće, uređaj se mora spojiti optičkom ili USB poveznicom s računalom. Proizvođači nude različita rješenja no ono što je jako bitno kod postprocesiranja podataka i isto kod svakog proizvođača je poznavanje paralelnog vremenskog niza s atmosferskim tlakom radi utvrđivanja točne visine vodnog stupca iznad senzora te apsolutne visine na kojoj je uređaj instaliran. U slučaju analize više uređaja sa značajnom prostornom razdiobom, nužno je svakako poznavati koordinate svake pozicije.



Slika 1.11 Prikaz učitanih podataka s CTD divera prilikom uzužnog profiliranja rijeke cetine na ušću

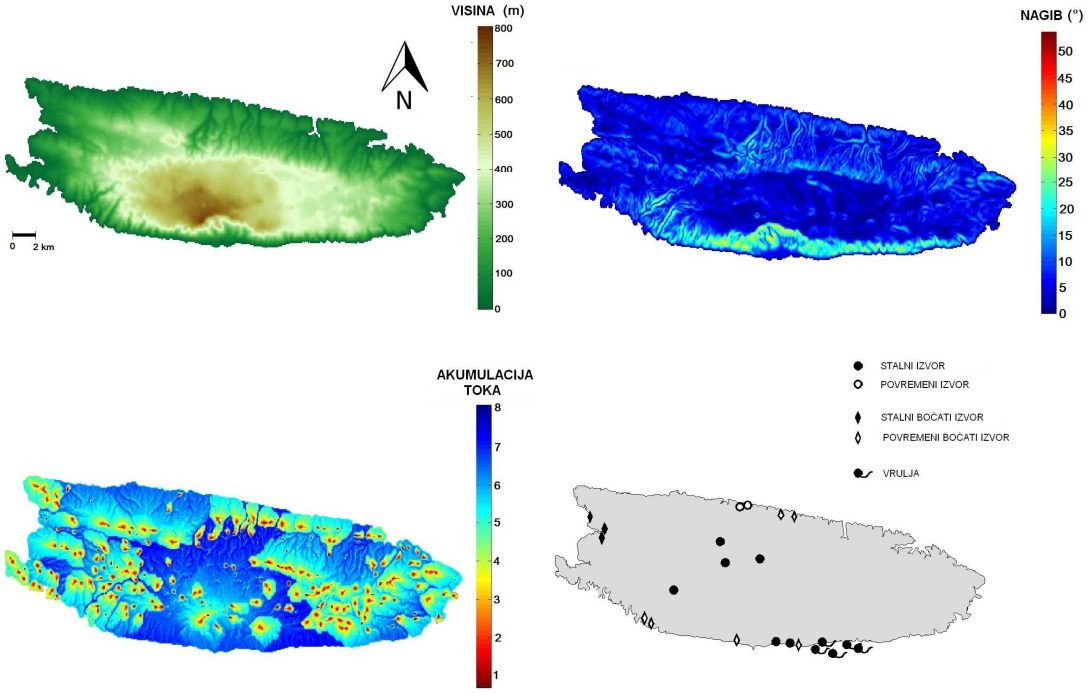
Ako tlačni senzor u kućištu sadrži i temperaturne senzore i EC elektrode, kao što je to slučaj CTD-diverom, moguće je dobiti vertikalnu raspodjelu parametara s obzirom da uređaj u svakom trenutku bilježi tlak odnosno dubinu. Slika 1.11 prikazuje očitane podatke s CTD divera prilikom temperaturnog i EC uzdužnog profiliranja rijeke Cetine na ušću. Uz kombiniranje profiliranja GPS podacima koji se paralelno skupljaju preko GPS antene, moguće je dobiti raspodjelu parametara i po površini promatranog profila. Na slici 1.12. prikazan je profil rijeke Cetine nedaleko od ušća s prikazom raspodjele mjerenog električne vodljivosti po površini profila.



Slika 1.12 Raspodjela električne vodljivosti na poprečnom profilu rijeke Cetine, nedaleko od ušća

Da bi se prostorna raspodjela načinila za snimljene parametre, potrebno je sinkronizirati mjerenja CTD divera i GPS traga koju osim koordinata u WGS84 (World Geodetic System) bilježi i pripadajući vremenski žig u UTC (Coordinated Universal Time) formatu. Na osnovu oba vremenska traga, GPS uređaja i CTD divera, lako je sinkronizirati podatke. U slučaju EC raspodjele bilježi se dubina snimanja, vrijeme snimanja, električna vodljivost i prostorne koordinate. Interpolacije podataka mogu se vršiti u 2D ili 3D prostoru.

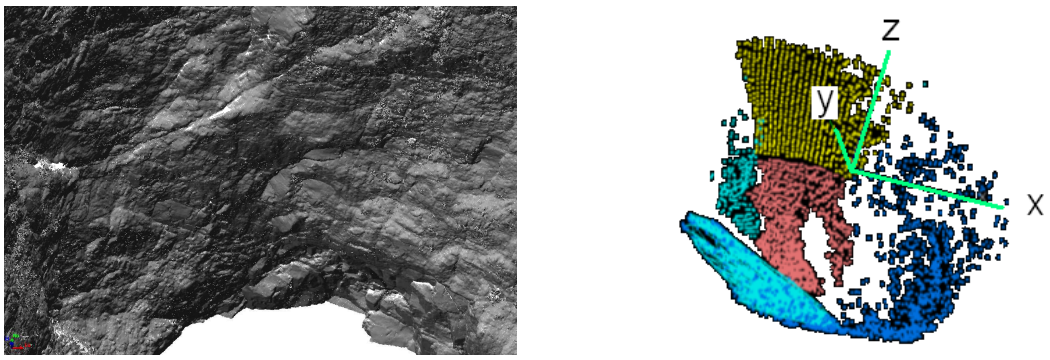
Podaci koji prikazuju morfometriju bilo kojeg dijela terena mogu se promatrati u vektorskom ili raster formatu. Ako se radi o analizi određenog sliva na osnovu DEM-a, u većini slučajeva raster grafika prikazuje matrice s vrijednostima podataka što prikazuju nadmorsku visinu, koordinate ili RGB vrijednost piksela iz koje se mogu razni atributi očitati, kao što je to na primjer tip pokrova zemljišta. U ovisnosti o odabranoj rezoluciji i području istraživanja moguće je na osnovu raspoloživih podataka dobiti i informacije o akumulaciji toka ili nagibu za svaki piksel unutar snimke. Na primjeru sa slike 1.13 uzet je u obzir GDEM SRTM na razmatranje, te se na osnovu DEM-a izradile morfometrijske karte otoka Brača s dodatnim informacijama o prostornoj rasprostranjenosti izvora.



Slika 1.13 DEM analiza otoka Brača s hipsometrijskom kartom, kartom nagiba padina, akumulaciji toka te prostornoj rasprostranjenosti izvora

Analiza hidroloških karakteristika bilo kojeg sliva je u današnje vrijeme nezamisliva bez DEM analize i korištenja raster i vektor grafike. Vektor grafika se koristi kod prikupljenih

podataka LiDAR metodom ili fotogrametrijom. Takozvani oblak točaka se obrađuje u vektorskom prostoru te se na osnovu njega mogu dobiti odgovori na pitanja o morfometriji, batimetriji, ili o površinama od interesa.



(a) (b)

Slika 1.14 Oblak točaka mjeren TLS uređajem na a) primjeru Crvenog jezera te b) mjeren fotogrametrijskom metodom na primjeru Modrog jezera kod Imotskog

Primjeri sa slika 1.14.a i 1.14.b su oblaci točaka dobiveni snimanjem Crvenog jezera kod Imotskog terestrialnim laserskim skenerom (TLS) i Modrog jezera fotogrametrijskom metodom. Vidljivo je kako TLS snimak nudi puno gušći raspored točaka, samim time i vjerodostojniji model od fotogrametrijskog snimka.

Količine podataka koje se obrađuju u svrhu praćenja i analiziranja krškog vodonosnika postaju s vremenom sve veći i pitanje njihovog postprocesiranja postaje zaseban problem unutar hidrometrije. Računalni programi i sve više rastuća moć računala uvelike olakšavaju posao istraživačima no postavlja se pitanje kod svake analize pravog omjera količine i kvalitete podataka s obzirom na istraživačke zahtjeve.

1.4 SADRŽAJ RADA

Razvojem novih tehnologija mjerenja i praćenja vodonosnika u poljima hidroakustike, radara, mjernih senzora i računalne tehnologije, nastaje potreba za implementacijom iste i generiranja novih protokola i metoda mjerenja. Nadalje, nova tehnologija pruža daleko veće mogućnosti te samim time otvara prostor za nove spoznaje vezane za krški vodonosnik te preispituje stare.

Glavni pokretač pri izradi predmetne disertacije je stjecanje novih i poboljšavanje starih saznanja o dinamici vode unutar krškog vodonosnika kao i na površini proučavajući podzemnu

dinamiku vode u špiljama i jamama kao i površinsku na primjeru krških jezera i otvorenih vodotoka uzimajući u obzir lokalnu i regionalnu skalu. Pri tom implementacija novih tehnologija u hidrologiji krša predstavlja poseban izazov i dodatnu motivaciju za usvajanje novih metoda i razvijanje postojećih.

Zasigurno, praćenje funkcioniranja krškog vodonosnika vodi do razumijevanja istog te nudi mogućnost ekstrapolacije spoznaja s lokalne na regionalnu skalu. Praćenje hidrodinamičkog odgovora krške jame na meteorološke pobude unutar hidrološke godine nudi odgovore i zaključke na lokalnoj razini i za predmetni speleološki objekt, no procesi kao što je pronos temperaturnog signala u vodi kroz krški provodnik, mijenjanje električne vodljivosti unutar promatranog razdoblja te praćenje razine vode mogu poslužiti za izvođenje zaključaka za promatranu regiju, odnosno. vodonosnik.

Nove tehnologije nude pri tom preciznija i znatno brža mjerenja. Vremenska i prostorna rezolucija mjerenja se povećavaju, a računalna tehnologija nudi izvrstan alat za analizu i uspostavljanje modela procesa u prirodi koji vode do boljeg razumijevanja.

Rad je podijeljen u sedam poglavlja.

Prvo poglavlje donosi uvodni opis problematike kao i općeniti pregled korištenih alata u svrhu skupljanja i analize podataka o krškom vodonosniku. Detektiranje osnovnih problema i prepreka kod istraživanja krša i dinamike vode unutar njega ujedno definira i motivaciju za izradu ovog rada. Osnovni pregled alata korištenih pri istraživanju daje informacije o opsežnosti hidrometrijskih i geomorfoloških mjerenja. Kraj prvog poglavlja daje prikaz sadržaja rada.

U *drugom poglavlju* su prikazana postojeća saznanja vezana za procese kretanja vode u kršu s naglaskom na Dinarski krš. Karakteristike krškog vodonosnika su opisane s referencom na poroznost i konceptualni prikaz transporta vode. Nadalje, detaljno je opisano ponašanje krškog izvora zapisano preko hidrograma, tj. mjerenja protoka na izvoru.

U okviru *trećeg poglavlja* detaljno je opisana korištena terenska oprema sa svojim prednostima i nedostatcima pri praćenju dinamike vode unutar krškog terena. Prikazane su metode mjerenja koje su primjenjivane tijekom istražnih radnji te izmjene i nadopune poznatog pristupa kako bi se točnost prikupljenih podataka povećala te sam način njihovog prikupljanja olakšao i unaprijedio. Matematički modeli korišteni pri analizi prikupljenih podataka, pobliže su opisani u ovom poglavlju. Korelacijske analize, analize vremenskih serija, višestruki regresijski modeli, neuralne mreže i globalni („black box“) modeli su korišteni pri izradi ovog rada, a u ovom poglavlju detaljno opisani.

U *četvrtom poglavlju* se iznose detaljne geografske, geološke, hidrološke i hidrogeološke značajke područja istraživanja. Kako se rad temelji na mjerenjima prikupljenim iz krških jama, površinskih tokova te krških jezera, ovo poglavlje detaljno opisuje karakteristike svakog područja istraživanjima posebice. Nadalje, opisana su i dosadašnja istraživanja cjelokupnog predmetnog područja te su navedena u literaturi prihvaćena saznanja o regionalnim i lokalnim kretanjima vode unutar izučavanog krškog terena.

U *petom poglavlju* se govori analizi prikupljenih podataka kao i o uspostavljenim modelima prema zabilježenim hidrološkim pojavama i mjestima na kojima se one odvijaju. Opisuju se detaljno mjerne postaje te se prikazuju prikupljeni podaci na osnovu kojih se simuliraju procesi u prirodi matematičkim modelima. Iako simulacije po sebi predstavljaju grubu aproksimaciju kompleksnog prirodnog procesa, one mogu poslužiti kod istraživanja i pridonijeti boljem razumijevanju izučavanih procesa. Pristup koji se koristio u ovoj vrsti analize temelji se na modelima opisanim u trećem poglavlju.

U *šestom poglavlju* predstavljeni su zaključci doneseni na osnovu dobivenih rezultata. Rezultati se uspoređuju s poznatim metodama iz literature te se otvara put konstruktivnoj diskusiji. Također se predstavlja i smjer daljnjeg znanstvenog djelovanja.

Sedmo *poglavlje* sadrži pregled korištene literature.

2. POSTOJEĆA SAZNANJA I CILJEVI DISERTACIJE

Kako disertacija za cilj ima uvesti nove pristupe i poboljšati postojeće kod hidroloških mjerenja unutar krškog vodonosnika i terena, ovo poglavlje daje pregled krških fenomena koji su praćenjem doveli do zaključaka i rezultata. Geomorfologija Dinarskog krša se obrađuje u brojnim znanstvenim publikacijama. Znanstvena literatura je bogata informacijama i saznanjima koja se sustavno počinju bilježiti krajem devetnaestog stoljeća kapitalnim djelom Jovana Cvijića „*Das Karstphänomen*“ [C8] objavljenim 1896 u Beču. Internacionalni znanstveni termini što opisuju krške fenomene potječu uglavnom iz južnoslavenskih jezika zahvaljujući upravo Jovanu Cvijiću. Od tada mnoge znanstvene discipline se posvećuju izučavanju krša te se pri tom interdisciplinarni pristup uspijeva prometnuti kao jedini ispravni.

Krš (eng: *karst*) je znanstveni termin koji je dobio ime po geografskom području unutar Dinarskog pojasa, uz obalu Jadranskog mora između Italije i Slovenije. *Karst* je germanizirana riječ iz talijanskog (*carso*) i slovenskog (*kras*) jezika. [C7, W2]. Sve tri riječi su nastale od stare indo-europske riječi *kar* ili *karra* što znači stijena. Riječi kao što su polje ili ponor su znanstveni termini u hrvatskom kao i u engleskom jeziku za morfološke pojave u kršu.

Krški vodonosnici se nalaze na svim kontinentima s preko 20% udjela u nezaleđenoj površini i kao važan vodni resurs poprimaju sve više značaja unutar znanstvenih, inženjerskih i regulatornih zajednica. Ogroman izazov leži upravljanju i karakterizaciji krškog vodonosnika

ponajviše zbog poroznosti kakvu ni jedan drugi tip vodonosnika ne posjeduje. Zbog toga svaki krški vodonosnik zasebno čini sustav punjenja i pražnjenja specifičnim te generalizacije o dinamici podzemne vode isključuje. Ta činjenica doprinosi iznimnoj važnosti hidrološkim mjerenjima unutar krškog terena i vodonosnika.

2.1 KRŠKI VODONOSNICI

Vodonosnik prema standardnoj definiciji je sloj stjenovitog materijala ili aluvijalnog sedimenta (pjeskoviti i šljunkoviti nanosi) sposobnog za spremanje i provođenje vode [W2]. Obje opisane sposobnosti su nužne za funkcioniranje vodonosnika. Šupljine unutar stjenovite mase osiguravaju prostor za spremanje vode unutar vodonosnika, a u slučaju krškog vodonosnika poroznost ima tri komponente kao što je to ranije opisano. Šupljine moraju biti povezane kako bi komunikacija vode u prostoru bila moguća.

Kako bi se najbolje opisala problematika vezana za krški vodonosnik što proizlazi iz kompleksnosti i heterogenosti istog, potrebno je prvo opisati „nekrški“ vodonosnik. Kod nekrških vodonosnika slobodan prostor između mineralnog granulata predstavlja dostupne šupljine za spremanje vode. Apsolutna poroznost se izražava u postotcima i predstavlja omjer zapremine pora i zapremine uzorka vodonosnika. Pore same po sebi nisu dovoljne da bi vodonosnik provodio vodu. Postojanje spojeva između pora i mogućih prolaza za komunikaciju vode unutar promatranog sloja je nužno. Sposobnost stijene da provodi vodu se naziva permeabilnost. Postoje stijene kao na primjer vulkanski plavac koje imaju visoku poroznost i istovremeno skoro nikakvu permeabilnost. Mnoge vrste stijena mogu biti efikasni provodnici vode no postoje i one vrste koje to ne mogu. Škriljci su tipični predstavnici stijena koje imaju nisku poroznost i nisku permeabilnost. Slojevi s takvim stijenama, npr. u kršu slojevi fliša, služe kao barijere za kretanje podzemne vode.

Voda u nekrškim vodonosnicima se kreće jako sporo, do par metara u godini [W2]. Osnovni konstitutivan zakon na reprezentativnoj skali daje vezu između gradijenta tlaka i brzine fluida. Eksperimentalno ga je utvrdio francuski inženjer Henry Darcy, 1856. godine te je zakon po njemu dobio ime. Prema Darcyevom zakonu brzina je proporcionalna hidrauličkom gradijentu.

$$v = -K \frac{dh}{dl} \tag{2.1}$$

Konstanta proporcionalnosti K predstavlja hidrauličku vodljivost u jedinici za brzinu te je vezana za svojstva stijene, fluida te gravitacije koja je ujedno i osnovni pokretač vode u vodonosniku.. Ako se poprečni presjek vodonosnika obilježi površinom A, u tom slučaju Darcyev zakon opisuje i zapreminu vode u kretanju kroz presjek u vremenu:

$$Q = Av = -A\frac{N\,d^2\,\rho\,g}{\eta}\frac{dh}{dl} \tag{2.2}$$

Parametar *d* je srednji promjer mineralnog granulata, *N* predstavlja geometrijski faktor koji uspostavlja vezu s nepravilnostima u obliku granulata. Umnožak Nd^2 je svojstvo stijene to jest njena permeabilnost. Permeabilnost i hidraulička vodljivost se često pogrešno poistovjećuju zbog toga što obje veličine predstavljaju sposobnost stijene u provođenju vode. Hidraulička vodljivost ima jedinicu brzine, a permeabilnost jedinicu površine. Kako Darcyev zakon vrijedi i za druge fluide, parametri ρ i η predstavljaju gustoću i viskoznost fluida respektivno. Gustoća i viskoznost funkcije u ovisnosti o temperaturi vode, a gravitacijska sila je opisana akceleracijom slobodnog pada g.

Darcyev zakon je jedna od najsnažnijih veza u hidrologiji. Povezan s jednadžbom kontinuiteta rezultira diferencijalnom jednadžbom koja opisuje polje toka podzemne vode. No jedna od najvažnijih činjenica koja čini jasnu distinkciju između krškog i nekrškog vodonosnika je ta da unutar krškog vodonosnika Darcyev zakon ne vrijedi.

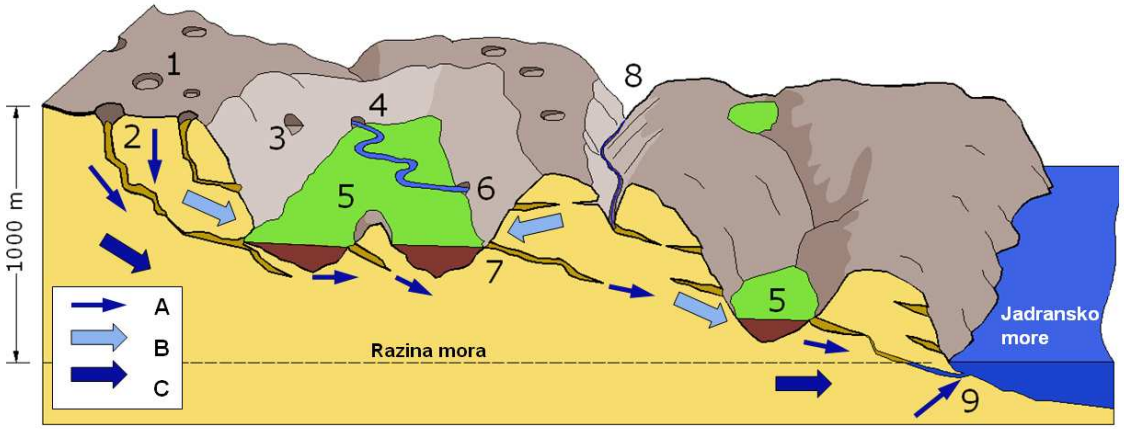
Nadalje, karakteristika krškog vodonosnika što ga razlikuje od ostalih tipova je pojava špilja, jama i kanala koji u kršu predstavljaju provodnike kroz koje voda brzo komunicira .Tablica 2.1 prikazuje osnovne karakteristike i razlike između tipova permeabilnosti prema ranije opisanom modelu trostruke poroznosti [B13, W2].

Tablica 2.1 *Karakteristike vodonosnika prema tri tipa permeabilnosti(White 2005)*

Permeabilnost	**Dimenzije**	**Mehanizam toka**	**Vrijeme putovanja**	**Raspodjela**
Krška matrica	μm - mm	laminaran	dugo	Kontinuirani medij
Pukotine	10 μm - 10 mm	uglavnom laminaran s nelinearnim komponentama	srednje	lokalizirana
Provodnici (kanali)	10 mm - 10 m	tok otvorenog vodnog lica, tok pod tlakom, turbulentan tok,	kratko	lokalizirana

Druga jasna razlika između dva tipa vodonosnika leži u povezanosti površinske i podzemne vode koja je kod krškog vodonosnika izrazita. Površinska i podzemna voda se kod nekrškog vodonosnika mogu smatrati odvojenim cjelinama dok kod krškog vodonosnika to nije moguće [B13, W2].

Ako se promatra krški vodonosnik unutar Dinarskog krša, trostruki model poroznosti vodonosnika kao i snažna veza između površinskog i podzemnog toka može pojasniti razloge smjera i prostorne raspodjele dominantnih tokova podzemne vode i prihranjivanje vodonosnika, lokalnih tokova uslijed kišom obilatih perioda te regionalnih tokova podzemne vode. Svaki geomorfološki element krškog terena se uklapa u jedan ili više tipova poroznosti prema modelu trostruke poroznosti.



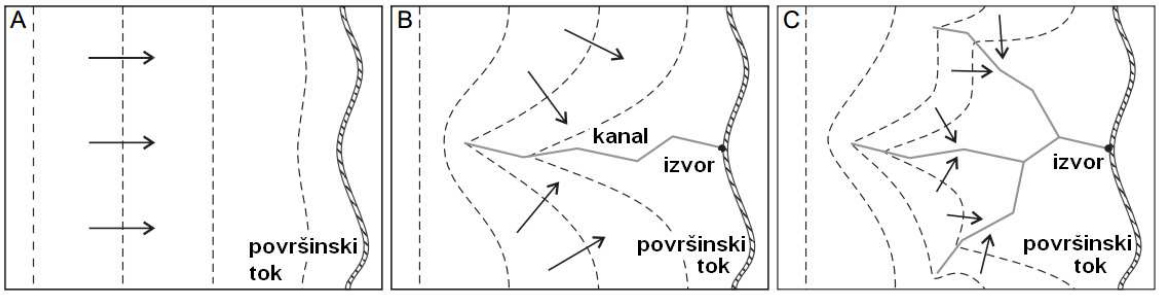
Slika 2.1 R Konceptualni model Dinarskog krša i tok podzemne vode (Krešić, 1987): (1) vrtača, (2) jama, (3) suha špilja ili fosilni kanal – bivši izvor, (4) aktivni izvor, (5) krško polje pokriveno nekonsolidiranim sedimentima, (6) aktivni ponor, (7) estavela, (8) duboki kanjon s vodotokom s gubicima, (9) vrulja. (A) je oznaka za dominantne lokalne tokove podzemne vode, (B) je oznaka za lokalne tokove uslijed kišama bogatog razdoblja a, (C) je oznaka za regionalni tok podzemne vode.

Barijera podzemnom toku vode u kršu može biti položaj morske vode ili nepropusne barijere ispod sloja karbonatnih stijena (slika 2.1).

Lokacija krških izvora te njihov maksimalni protok i druge karakteristike su indikatori stanja krškog vodonosnika kao i njihovog funkcioniranja u smislu sustava. Uz način prihranjivanja krškog vodonosnika i stupnju njegove izloženosti na površini, maksimalni protoci dominantnih izvora su snažno korelirani s brojem spojeva između krške matrice, pukotina i provodnika te njihovom snagom. Podzemni tokovi u krškim vodonosnicima u kojim dominiraju provodnici prihranjuju izvore s visokom varijabilnošću. Vodonosnici s dominantnim tokom kroz kršku matricu imaju sposobnost pohranjivanja velikih količina vode tako da u sušnim periodima izvori

mogu očuvati značajnu izdašnost. U oba slučaj svaki krški vodonosnik ima tendenciju takozvane samoorganizirane permeabilnosti [W6] koja rezultira u dreniranju krškog vodonosnika kroz jedan dominantan izvor.

Nova razumijevanja o razvoju permeabilnosti i njenoj distribuciji unutar karbonatnog vodonosnika su dobivena laboratorijskim istraživanjima kao i numeričkim modelima [D3, G2, K1]. Povećavanje toka i brzine otapanja karbonatnih stijena rezultiraju visokom permeabilnošću te samoorganiziranoj mreži kanala odnosno provodnika. U ovisnosti o toka vode kroz karbonatni vodonosnik formiranje kanala je usporeno ili ubrzano. Dakle, kod značajnog toka unutar krškog vodonosnika, vjerojatnost transporta cjelokupne vodne mase kroz provodnike se povećava do maksimuma nakon $10^3 – 10^6$ godina.



Slika 2.2 Razvijanje samoorganizirane permeabilnosti (Worthington i Ford, 2009) gdje su (A) inicijalno polje toka, (B) modificirano polje toka nakon proboja jednog kanala i (C) modificirano polje nakon proboja lateralnih kanala. Strjelice označavaju silnice, a crtkane linije ekvipotencijale.

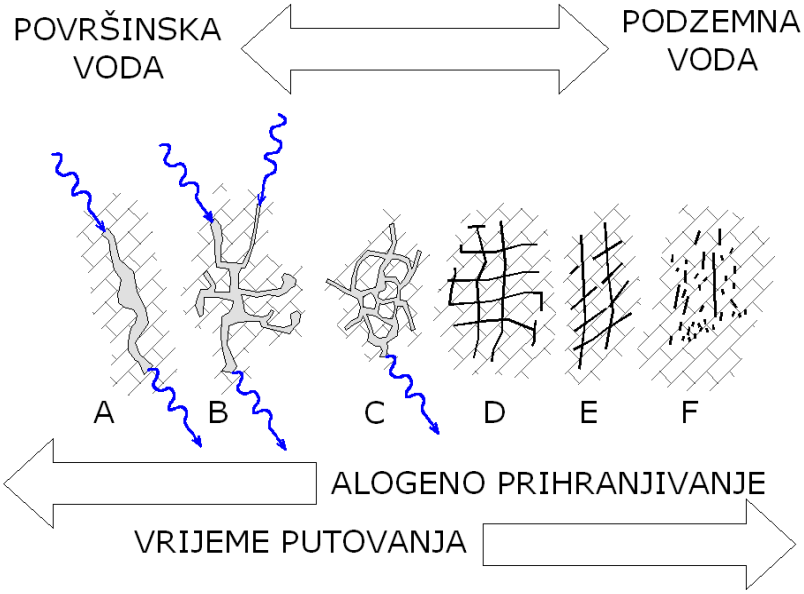
Glavna posljedica samoorganizirane permeabilnosti krškog vodonosnika je da slivovi pojedinih izvora u glavnom nadilaze orografski sliv definiran topografskim razdjelnicama. To ujedno predstavlja i razlog zašto se najizdašniji izvori na svijetu nalaze upravo unutar krških terena [K2]. Slika 2.2 prikazuje razvijanje samoorganizirane permeabilnosti u kršu.

Zbog povezanosti površinske i podzemne vode u kršu i brzom komuniciranju zahvaljujući kanalima unutar krškog terena što s površine najbrže sprovode vodu u podzemlje, nužno je da se u bilo kojem razmatranju krškog vodonosnika podzemna i površinska voda promatraju kao cjelina. Standardni konceptualni modeli krškog vodonosnika nude tri osnovna izvora njegovog prihranjivanja [C7].

Prvi izvor prihranjivanja može se opisati kao difuzni dio i odnosi se na oborine koje se s površine krša infiltriraju u vodonosnik. Difuzno prihranjivanje vodonosnika utječe na razinu podzemne vode unutar istog te je ova komponenta prihranjivanja identična kod svakog tipa vodonosnika.

Prihranjivanje alogenskog tipa izazvano je površinskom tokom što potječe sa susjednih slivova. Prihranjivanje vodonosnika alogenog karaktera događa se na mjestima gubitaka površinskog toka, a to mogu biti ponori ili riječna korita s gubitcima. U slučaju toka uslijed poplava susjednog sliva i alogenog prihranjivanja s velikim količinama, krški vodonosnik je podložan snažnom pulsu pri kojem ne postoji filtracije vode u procesu prelaska površinskog toka u podzemni. Pri tom krupni otpad kao i otopljeni kontaminanti dospijevaju s lakoćom u podzemlje.

Unutarnje prehranjivanje krškog vodonosnika se odnosi na površinu krškog terena iznad i transport vode s istog u podzemlje. Kod kišnog događaja voda s površine može na više načina dospjeti u podzemlje, a u ovisnosti o količini i intenzitetu oborina, morfometrijskim veličinama terena i krškim oblicima na njemu. Ponori transformiraju brzo svaki formirani površinski tok u podzemni, a kod površine krša gdje dominira primarni i sekundarni model poroznosti voda unosi ogromne količine energije u vodonosnik u vidu topline i nutrijenata te klastični sediment. Slika 2.3 prikazuje različite tipove permeabilnosti provodnika u kršu.



Slika 2.3 Različiti tipovi permeabilnosti u provodnicima (White, 2005) gdje su (A)jedinstveni provodnik s glavnim površinskim prihranjivanjem, (B) Razgranati provodnici s više točaka površinskog prihranjivanja, (C) anastomozna špilja nastala dprimarno duž međuslojnih pukotina, (D) Mreža provodnika razvijena niz vertikalne pukotine, (E) permeabilnost kroz pukotine proširene otapanjem, (F) Isključivo permeabilnost krške matrice. Tok je većinom difuzan kod slučaja (F), a lokaliziran kod slučaja (A). Vrijeme putovanja vode raste s lijeva na desno.

Procesi prihranjivanja krškog vodonosnika te njihovo razumijevanje mogu olakšati zadatke vezane za mjerenja u kršu, modeliranje i upravljanje neprocjenjivim vodnim resursom.

Svaki vodonosnik predstavlja geološku tvorevinu sposobnu da prikuplja, skladišti i ispušta znatne količine vode, a naziva se još i akvifer. Postoje geološke tvorevine koje ove funkcije nemaju ili pak ih ne ispunjavaju u onom opsegu kao vodonosnik.

Akvitard je geološka tvorevina s manjom moći propusnosti vode nego vodonosnik. Njegova permeabilnost je znatno manja, a zbog toga on ne sprječava protok vode nego ga usporava. Akvitard ne može snabdijevati dostatnim količinama izvore i površinske tokove, no sposoban je spremanju podzemnih voda.

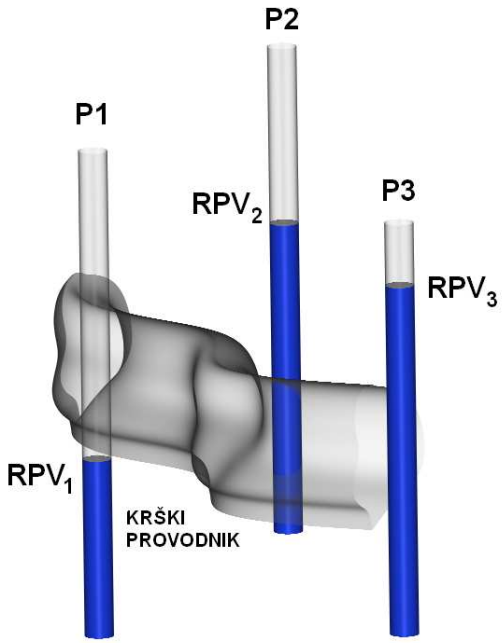
Akvilud ima još manju poroznost i permeabilnost od akvitarda te zbog toga ne zadovoljava potrebe za snabdijevanje vodom.

Akvifug su takve geološke tvorevine gdje je permeabilnost izrazito mala ili nikakva te u prirodi predstavljaju barijeru protoku podzemne vode. Akvifug ne može skladištiti vodu niti voda kroz njega može teći.

U ovisnosti o položaju slojeva i njihovih svojstava vezanih za poroznost i permeabilnost, vodonosnike dijelimo na neograničene, poluograničene i potpuno ograničene vodonosnike [B13]. Kod neograničenih vodonosnika ili vodonosnika sa slobodnim vodnim licem njihova površina ima izravnu vezu s atmosferom. Poluograničeni vodonosnici su pokriveni slojem akvitarda. Oni mogu biti prihranjivani kroz pokrovni poluograničeni sloj. U slučaju pozicije akvitarda ispod vodonosnika gubitci su također mogući. Potpuno ograničeni vodonosnici imaju pokrov od nepropusnih slojeva, dakle akviluda ili akvifuga. U slučaju zacjevljenih bušotina koji sa površine penetriraju nepropusni sloj i zadiru unutar vodonosnika, često se javljaju subarteški i arteški pritisci što rezultira razinama vode u cijevi iznad vrha vodonosnika ili iznad vrha terena.

Krški vodonosnik stavlja pred hidrogeologiju mnogo izazova [B4]. Njegova svojstva su slabo definirana jer kao što je ranije opisano, svojstva tečenja unutar istog su posebna. Nerijetko je velika razlika unutar jednog vodonosnika u razini podzemne vode, naročito uslijed snažnog prihranjivanja velikim količinama oborina [B13].

Kod mjerenja podzemne razine vode u krškim terenima dolazi zbog svega navedenog do velikih razlika na malom prostoru. Razlike se mogu objasniti time da pijezometri kojim se razina podzemne vode mjeri, dosežu različite hidrogeološke zone koje su međusobno odvojene [B13]. Razlike mogu ležati i u činjenici da pijezometri izrađeni unutar istog okršenog područja mogu svojim dnom zadirati u različite krške vodonosnike kao što je prikazano na slici 2.4.

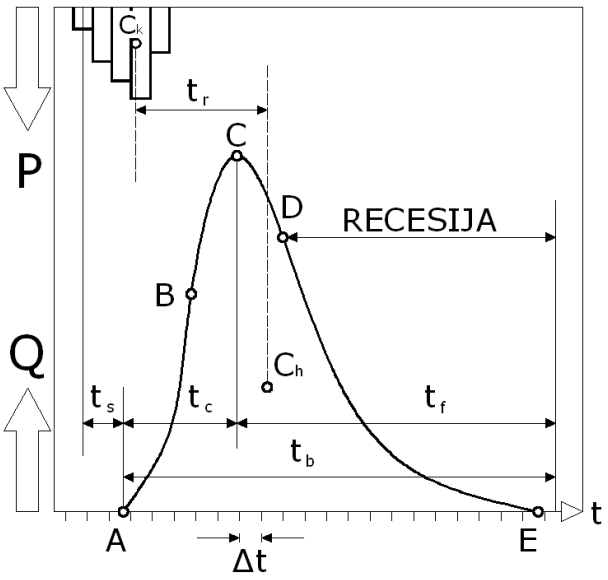


Slika 2.4 Različiti rezultati mjerenja razine podzemne vode pijezometrima u krškom masivu (modificirano prema Bonacci 1987).

Krški vodonosnici su poznati po relativno malom broju velikih izvora s velikim protocima. Ipak veliki izvori se pojavljuju, a njihovo praćenje i analiziranje parametara kao što su protok, mutnoća i fizikalno-kemijske značajke vode pomažu u procesu analize nepristupačnih dijelova vodonosnika i procesa koji se u njemu odvijaju [B24]. Odvodnja površinski generiranog toka uslijed velikih kiša može imati značajan utjecaj na krški izvor ako su u vodonosniku provodnici dovoljno razvijeni te sposobni provoditi velike količine vode. U Dinarskom kršu provodnici koji sačinjavaju tercijarni tip poroznosti vodonosnika su izrazito razvijeni tako da svaki meteorološki događaj karakteriziran značajnim količinama oborina rezultira u konačnici brzom povećanju protoka u izvorima te povećanju mutnoće. Drugi krški vodonosnici s nerazvijenim sustavom provodnika reagiraju umjerenije na velike oborine te kod njihovih izvora porast protoka je znatno umjereniji.

Odgovori svakog krškog vodonosnika na pobudu uslijed oborine se mogu detaljno analizirati konstrukcijom hidrograma. Hidrogram govori puno o strukturi vodonosnika kao i o njegovoj poroznosti.

Iako se procesi koji generiraju površinsko otjecanje i istjecanje iz krškog izvora uvelike razlikuju, terminologija koja karakterizira hidrogram je identična.



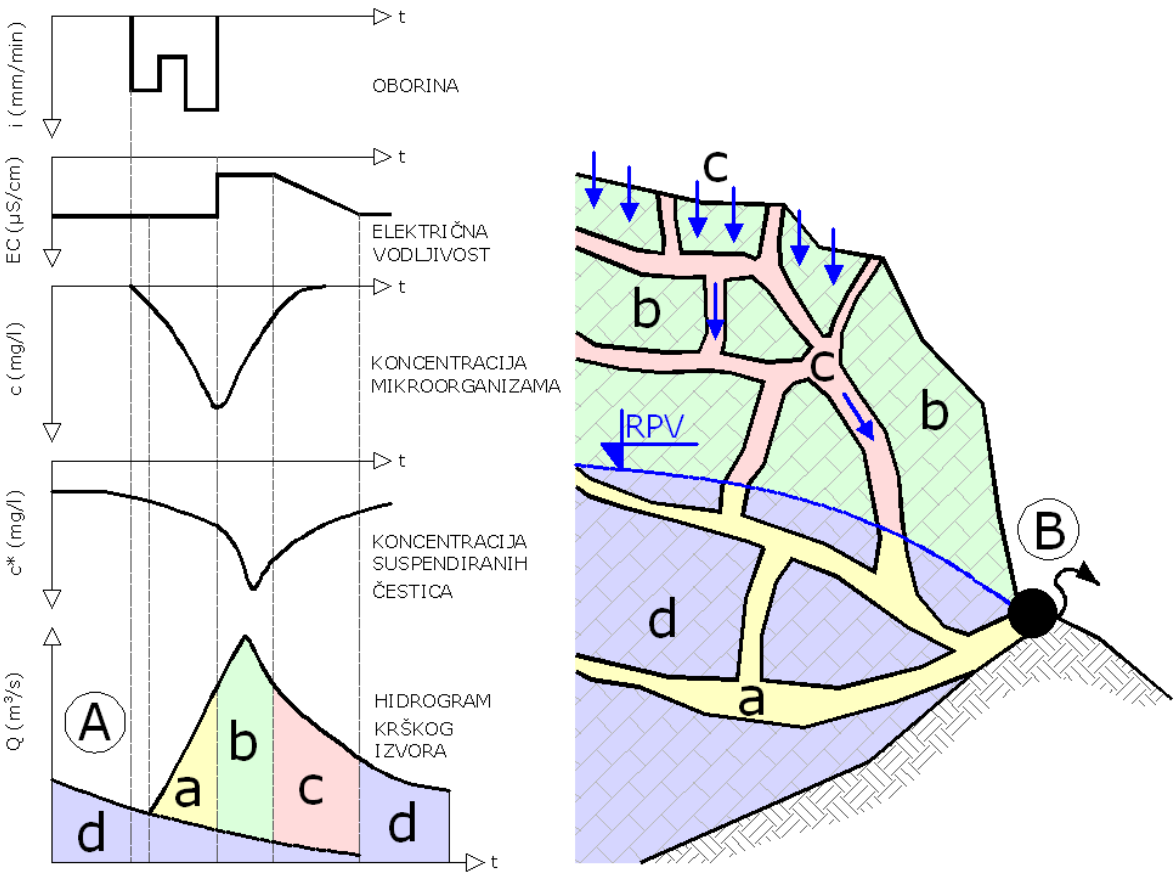
Slika 2.5 Sastavne komponente hidrograma.

Slika 2.5 prikazuje glavne elemente jednog hidrograma na kojoj je početak otjecanja nakon kišnog događaja označen točkom (A). Vrijeme između početka kiše i početka otjecanja naziva se naziva startno vrijeme i označeno je s (t_s). Vrijeme u kojem hidrogram doseže svoj maksimum u točki (C) se naziva vrijeme koncentracije i označeno je s (t_c). Oznaka (t_f) predstavlja vrijeme od maksimuma hidrograma (C) pa do teoretskog završetka otjecanja (E) i naziva se vrijeme opadanja. Zbroj vremena koncentracije i vremena opadanja daje vremensku bazu hidrograma (t_b). Vrijeme između težišta hijetograma (C_p) i težišta hidrograma (C_h) se naziva vrijeme kašnjenja ili vrijeme retardacije (t_r). Vremenski interval mjerenja označen je s (Δt). Oblik svakog hidrograma definiran je bazom (AE), podizanjem (AB), grebenom (BCD) i spuštanjem (DE). Točke infleksije na hidrogramu (B) i (D) označavaju prijelaz krivulje hidrograma iz konveksnog u konkavan oblik i obrnuto. Dio hidrograma koji opisuje recesiju se naziva još i krivulja recesije.

Oblik hidrograma ovisi o dimenzijama i obliku slivnog područja kao i o intenzitetu pale oborine na sliv. U slučaju dugog kišnog događaja s niskim intenzitetima, baza hidrograma se produžuje, a kod kratkih kiša visokog intenziteta ista se skraćuje. Površina ispod hidrograma predstavlja zapreminu otekle vode na mjestu mjerenja. Vrijeme kašnjenja daje dobar uvid te prve indikacije vezane za kapacitet izvora kao i za transmisivna svojstva pripadajućeg vodonosnika.

Hidrogram izvora je krajnji rezultat različitih procesa koji transformiraju palu kišu i druge načine prihranjivanja vodonosnika u jedinstveni točkasti izlaz u vidu izvora. Analiza hidrograma može poslužiti u definiranju zapremina malih i velikih povezanih provodnika iz kojih voda kroz

izvor istječe [B10]. Hidrogram krškog izvora i njegovi sastavni dijelovi se mogu objasniti prema području nastanka određene komponente toka u krškom masivu (A2, W2).



Slika 2.6 Hidrogram (A) krškog izvora (B) prema zonama porijekla vode (modificirano prema Bonacci 1987) gdje je (a) voda iz krških provodnika iz zasićene zone vodonosnika, (b) voda spremljena u nezasićenoj zoni, transportirana do izvora turbulentnim tokom kroz provodnike, (c) površinska voda transportirana kanalskim sustavom do izvora kroz kratko vrijeme i (d) voda iz krške matrice u zasićenoj zoni.

Kretanje vode u kršu se ne može egzaktno podijeliti na površinsku i podpovršinsku komponentu. Zato je iznimno važno proces kretanja vode u kršu promatrati integralno, iako nepoznanice uskogrudno vezane za poroznost vodonosnika i njegovu dinamiku predstavljaju najveći izazov. Stoga je bitno osloniti se na dostupne i provjerene metode koje svojom analizom nude odgovore na pitanja vezana uz proces kretanja vode u kršu. Promatranje krških izvora, mjerenje protoka i fizikalno kemijskih parametara vode može uvelike rasvijetliti nepoznate činjenice o krškom vodonosniku i njegovoj geometriji (slika 2.6).

2.1 OČEKIVANI DOPRINOSI DISERTACIJE

Praćenje i analiza vodnih resursa u kršu vodi do novih saznanja o hidrologiji i dinamici vode u krškim terenima koji sačinjavaju oko 50% teritorija Republike Hrvatske. Nova saznanja uvijek nude nove alate kod iznimno važnog procesa upravljanja i donošenja odluka vezanih za neprocjenjiv resurs – vodu. Bitno je naglasiti kako upravo mjerenja najnovijim tehnologijama i od nedavno dostupnim znanstvenoj i široj zajednici mogu biti katalizator procesa koji u konačnici vode do novih spoznaja i boljem i racionalnijem upravljanju vodama u kršu. Stoga ova disertacija nudi primjere kako se ta mjerenja mogu uspostaviti i na koji način ona doprinose općim spoznajama vezanim za hidrologiju krša.

Uspostavljanje novih metoda hidrometrijskih mjerenja na otvorenim vodotocima temeljenih na uporabi radara i probabilističkog pristupa nudi jednu novu metodologiju koja otvara mogućnosti mjerenja kod ekstremnih hidroloških situacija (poplava i visokih protoka) bez fizičkog kontakta mjeritelja i površinskog toka. Mjerenja ADCP-om, ADV-om zahtijevaju prisutnost mjeritelja na vodotoku, dok se mjerenje radarom može provesti sa sigurne udaljenosti, a probabilističkim pristupom mjeritelj lako može odrediti protok na osnovu mjerene površinske brzine. Po prvi puta u Hrvatskoj se u ovoj disertaciji dokumentirano koristi probabilistički pristup kod određivanja protoka površinskog vodotoka. Na primjerima vodotoka Cetine, Jadra i Sutine uspostavljaju se hidrometrijska mjerenja temeljena na hidroakustičkoj i radarskoj tehnologiji što otvara sasvim nove mogućnosti. Novi protokoli mjerenja i objedinjavanja starih metoda te poboljšanjem istih primjenom najnovije tehnologije daju za pravo uspostavljanje novog sustava mjerenja, posebice u slučaju ekstremnih hidroloških situacija.

Speleološki objekti su značajka krškog terena, a duboke jame predstavljaju svojevrsne pijezometre u terenu koji mogu dati sliku o kretanju podzemnih voda. U njima se očitava upravo dinamika krškog podzemlja i kretanja vode. Promatranjem razine vode u freatičnoj zoni kao i pronosa signala temperature i električne vodljivosti pobliže objašnjavaju upravo hidrodinamički odgovor krškog provodnika na meteorološku pobudu. Kontinuiranim prikupljanjem podataka uz pomoć CTD divera u visokoj rezoluciji o vodostaju, temperaturi i električnoj vodljivosti vode dolazi se do uvida u izučavane procese te se matematičkim modelima isti procesi simuliraju kako bi se sve uključene komponente u proces pobliže analizirale. Modeli temeljeni na višestrukim regresijskim modelima i neuralnim mrežama mogu predvidjeti samu dinamiku parametara u određenim situacijama. Kako bi se u ovom radu pobliže pojasnili promatrani procesi, u tu svrhu je

speleološki istražena duboka jama unutar sliva rijeke Cetine pod nazivom Nevidna Voda te je unutar iste CTD diverom praćeno kretanje vode.

Kako duboke jame predstavljaju odraz kretanja vode unutar krša, tako isto se krška jezera mogu s punim pravom promatrati kao prirodni piezometri. Najbolji primjer površinskog odraza podzemne vode u prirodi su krška jezera u Imotskom, Crveno i Modro jezero. Ova disertacija je velikim dijelom posvećena znanstveno istraživačkom radu vezanim za spomenuta dva krška fenomena. Iako su Imotska jezera svjetski prirodni fenomeni koji iz godine u godinu privlače pažnju šire tuzemne i inozemne javnosti, znanstvena briga koju ona s pravom zaslužuju nije adekvatna svjetskim razmjerima prepoznatljivosti. Po prvi put u povijesti ova disertacija prikazuje kontinuirano promatranje vodnog lica u Modrom jezeru te najnovija geodetska, morfometrijska i volumetrijska mjerenja oba jezera uz pomoć naprednih tehnologija zasnivanim na satelitskim mjerenjima, fotogrametriji, SoNAR i LiDAR tehnologiji. Prikupljeni podaci po prvi puta omogućavaju izradu preciznih računalno geometrijskih modela oba jezera te otklanjaju dosta krivih pretpostavki vezanih za morfologiju i geometriju koje su sustavno više desetljeća zastupljene u stručnoj literaturi. Uspostava matematičkog modela Modrog jezera u svrhu boljeg razumijevanja njegovog funkcioniranja nudi uvid u bilancu voda te izolirane komponente prihranjivanja jezera i njegovih gubitaka.

Doprinos predmetne disertacije može se sublimirati kao znanstveni doprinos vezan za metodološka poboljšanja pri hidrometrijskim mjerenjima te nova i iznimno važna saznanja u hidrologiji krša na lokalnoj i regionalnoj skali temeljena na mjerenjima unutar krškog vodonosnika i terena. Pri tom, naglasak regionalne skale se odnosi na dalmatinsko zaleđe, odnosno sliv Cetine i Imotsku krajinu. Planirana znanstvena istraživanja imaju za cilj proširiti novostečena saznanja kao i područje istraživanja.

3. METODOLOGIJA

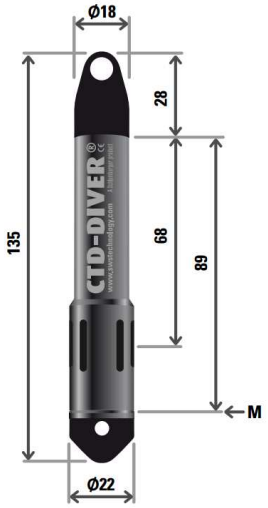
Pri hidrološkim mjerenjima u kršu te pri analizi prikupljenih podataka koja vodi do određenih zaključaka vezanih za promatrane prirodne procese, važno je poznavanje odabranog instrumentarija kako bi se pravilno istim rukovalo i prije svega izbjegle pogreške pri mjerenju. Naravno, kako je većina novih tehnologija temeljena na elektronici i programiranim rutinama što se preko mikroprocesora odvijaju i upravljaju mjerenjima, potrebna su osnovna znanja iz navedenih polja, kako bi se pravilno upravljalo odabranim instrumentarijem. Mnogi proizvođači nude komercijalnu opremu za hidrološka mjerenja te je svakom od njih cilj načiniti izvođenje mjerenja što razumnijima i jednostavnijima, tako da su priložene upute svakog instrumenta detaljne i predstavljaju kompletiranu literaturu vezanu za ponuđeni instrument. Ipak, na mjeritelju ostaje da odabere način i vrijeme provođenja mjerenja tako da dolazi do izražaja individualna snalažljivost i sposobnost rješavanja tehničkih problema koji se pri svakom mjerenju javljaju. Iskustvo koje proizlazi iz ponavljanja radnje na terenu pri različitim mjerenjima pomaže pri odabiru rješenja tehničkih poteškoća uzrokovanih nepredvidljivošću prirode, to jest njenim stohastičkim karakterom.

3.1 TERENSKA OPREMA

Terenska oprema koja se koristila pri znanstvenom istraživanju prezentiranom u ovom radu podijeljena je u ovom poglavlju prema principu rada pojedinačnog instrumenta. Tako se dijeli na tlačne senzore, hidroakustiku i radar, s time da je u poglavlju o radaru predstavljena i tehnologija LiDAR snimanja te fotogrametrija koje su korištene pri određivanju morfoloških značajki terena na kojem su se provodila hidrološka mjerenja.

3.1.1 Tlačni senzori (CTD sonde)

Kako se danas pri mjerenju vodostaja koriste tlačni senzori sve češće u odnosu na instrumente temeljene na plovku i protuutegu te akustičnim senzorima, njihove izvedbe dolaze u raznim kombinacijama, a na krajnjem korisniku uvijek ostaje odluka vezana za odabir instrumenta koji u najvećoj mjeri zadovoljava zahtjeve mjeritelja i terena. Jako robusni instrumenti s visokom frekvencijom mjerenja, samostalnom memorijom velikog kapaciteta i automatskim pohranjivanjem podataka se pokazuju kao pravi odabir kod mjerenja na teže pristupačnom terenu kao i kod mjerenja razine podzemne vode. Takav uređaj je CTD sonda (CTD diver) koja sa svojim keramičkim kućištem pruža zaštitu unutarnjoj elektronici i bateriji.



Slika 3.1 CTD sonda DI 273 Schlumberger Water Service (SWC), dimenzije su izražene u milimetrima, M je oznaka za membranu

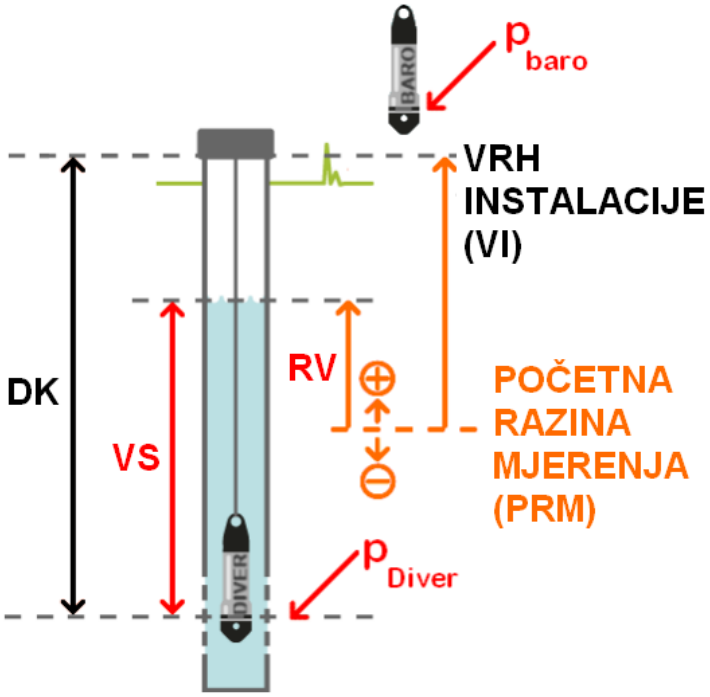
Uređaj najčešće korišten pri istraživanjima vezanim za ovaj rad je CTD sonda, model DI273 SWC [S1] prikazan na slici 3.1. Kompaktnost i robusnost ovog uređaja omogućuje njegovu implementaciju pri mjerenju razine podzemne vode u bušotinama ili jamama no isto tako može

poslužiti kao limnigraf kod površinskih tokova ili jezera. U ovom doktorskom radu upravo ovaj model je korišten pri mjerenjima razine vode u Crvenom i Modrom jezeru te jami Nevidna voda. Iz tablice 3.1 vidljive su tehničke karakteristike uređaja. Ono što predstavlja veliku prednost kod korištenja upravo ovog uređaja vidljivo je iz informacija o životnom vijeku baterije i kapacitetu memorije [S1]. Ove karakteristike jamče visoku autonomiju uređaja i korisnički orijentiran koncept.

Tablica 3.1 *Tehničke karakteristike CTD sonde DI 273 Schlumberger Water Service (SWC)*

CTD DIVER DI 273 - 100 metara vodnog stupca TEHNIČKE KARAKTERISTIKE	
MJERENJE RAZINE VODE	
Pritisak:	raspon od 0 do 100 mH2O
Točnost	±5,0 cmH2O
Rezolucija:	2,0 cmH2O
MJERENJE ELEKTRIČNE VODLJIVOSTI	
Raspon mjerenja el. vodljivosti:	0 mS/cm do 30 ili 120 mS/cm (podesivo)
Točnost:	±1 % od očitanja
Rezolucija:	0,1 % od očitanja
MJERENJE TEMPERATURE VODE	
Raspon mjerenja temperature:	-20 °C do 80 °C
Točnost:	± 0,1 °C
Rezolucija:	0,01 °C
OMOČENI MATERIJALI	
Kućište:	Keramika (ZrO_2)
O-prsten:	Viton®
Tlačni senzor:	Keramika (Al_2O_3)
Čep i vrh:	Najlon PA6, 30% staklena vlakna
Kućište senzora el. vodljivosti:	Keramika (ZrO_2)
Senzor el. vodljivosti:	Platinaste elektrode ili keramika (Al_2O_3)
OSTALE KARAKTERISTIKE	
Operativna nadmorska visina:	-300 do 5000 m n.m.
Memorija:	3 x 48000 mjerenja
Životni vjek baterije:	10 godina s intervalom mjerenja od 3 minute ili većim
Masa:	95 g
Interval mjerenja:	1 s do 99 h

Treba imati na umu kako uređaj mjeri cjelokupni tlak senzorom pa se tražena veličina što može biti ukupna dubina ili vodni stupac, dobije oduzimanjem referentne veličine atmosferskog tlaka. Instalacija uređaja može biti preko kabla (Slika 3.2.) ili nosača pričvršćivanjem na čvrstu vertikalnu podlogu.



Slika 3.2 Načini instaliranja CTD sonde uz pomoć kabla u zdencu te promatranju razine vode (RV) u odnosu na početnu razinu mjerenja (PRM). Ostale oznake stoje za: VS = vodni stupac, DK = duljina kabela, p_{baro} = registriran atmosferski tlak i p_{Diver} = registriran tlak na CTD sondi.

Slika 3.2 ujedno predstavlja i tipičan način instaliranja CTD sonde u zdencu. Primjena je moguća i kod površinske vode bez izraženog toka kao što je to slučaj kod jezera. Vodni stupac koji se registrira na uređaju, računa se prema izrazu (3.1):

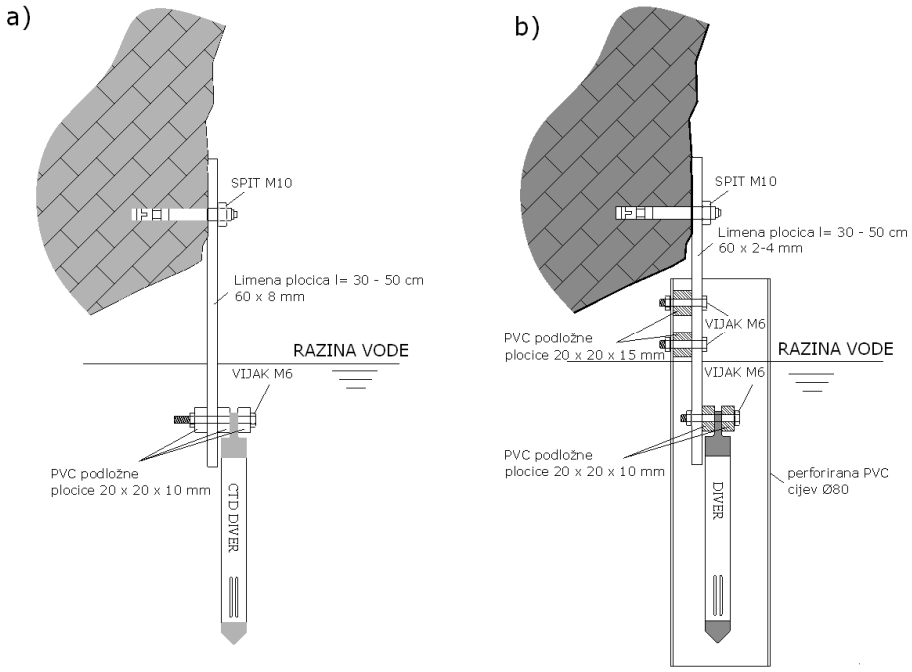
$$VS = 9806{,}65 \cdot \frac{p_{Diver} - p_{baro}}{\rho \cdot g} \tag{3.1}$$

Razina vode prema slici 3.2 se određuje u odnosu na početno zabilježenu razinu vode prema izrazu (3.2):

$$RV = VI - DK + 9806{,}65 \cdot \frac{p_{Diver} - p_{baro}}{\rho \cdot g} \tag{3.2}$$

Iz izraza (3.1) i (3.2) je vidljivo kako precizno određivanje razine vode ili ukupne dubine ako je kota najdublje točke poznata, iziskuje poznavanje atmosferskog tlaka u svakom vremenskom koraku zapisa prikupljenih podataka.

Kod mjerenja u nepristupačnim mjestima gdje česta kontrola uređaja nije moguća, važno je uređaj dobro osigurati, kako bi instalacija izdržala ekstremne situacije uslijed velikog protoka te kako bi se zadržala željena točnost mjerenja. Slika 3.3 prikazuje neke od osnovnih načina instalacije uređaja na stijenu.



Slika 3.3 Načini instaliranja CTD sonde uz pomoć nosača na stijenu uz promatrani vodotok bez zaštite uređaja a) i sa zaštitom u vidu perforirane PVC ili PE cijevi

Potrebni zapis atmosferskog tlaka se može dobiti referentnim uređajem na površini ili s obližnje meteorološke postaje s time da se treba voditi računa o razlici u nadmorskoj visini između instaliranog uređaja i meteorološke postaje. Odnos između atmosferskog tlaka i nadmorske visine je linearan te je predstavljen u sljedećem izrazu (3.3):

$$P_H = P_0 \cdot e^{-(M \cdot g \cdot h)/(R \cdot T)} \tag{3.3}$$

Izraz (3.3) sadrži oznake P_H za atmosferski tlak na visini H, P_0 za referentni atmosferski tlak, M za molekularnu masu zraka (28,8 10^{-3}kg/mol), g za gravitacijsku konstantu (9,81 m/s^2), H za

visinu u metrima, R·za univerzalnu plinsku konstantu (8,314 J/mol/K) te T za temperaturu u Kelvinima.

Kompenzacija rezultata u odnosu na atmosferski tlak se izvodi nakon prikupljanja podataka, a moguće ju je provesti specijaliziranim računalnim programima ili samostalnim programskim rješenjima. U slučaju da mjerenje atmosferskog tlaka i CTD sonde nije sinkronizirano u vremenskom koraku, bitno je napomenuti kako je nužna interpolacija između pojedinih mjerenja kako bi se povećala rezolucija podataka te se u konačnici rezultati sinkronizirali i kompenzirali. Uobičajeni postupak je linearna interpolacija između susjednih mjerenja, a korisnički programi je obavljaju automatizirano.

CTD sonde mjere i temperaturu što je važan podatak koji nudi informacije o regionalnom toku vode i njegovoj dinamici. Senzor koji mjeri temperaturu načinjen je od poluvodiča koji ne mjeri samo temperaturu nego i kompenzira vrijednosti tlačnog senzora uključujući i samu elektroniku što je nužno zbog efekata na točnost sustava uslijed promjene temperature.

Mjereni podaci za električnu vodljivost se također kompenziraju u odnosu na temperaturu, kako bi kod usporedbi uvijek radilo sa standardnom električnom vodljivosti vode pri temperaturi od 25°C.

Primjena CTD sondi pri mjerenju razine podzemne vode kao i u površinskim tokovima postaje standardna i u struci prepoznata kao najpreciznija metoda. Relativno pristupačne cijene ovih uređaja na tržištu omogućuju znanstvenicima prikupljanje podataka do nedavno u nezamislivim opsezima i točnošću.

3.1.2 Hidroakustika

U hidrologiji, osobito u hidrometriji, najveći tehnološki iskorak kod mjerenja protoka na otvorenim vodotocima se upravo dogodio primjenom hidroakustike. Hidroakustika se ne koristi samo za mjerenje protoka, nego i za morfometrijske analize vodotoka i jezera u raznim izvedbama uređaja i njihovim aplikacijama. Ono što je znatno unaprijedilo tehnologiju mjerenja su velike prednosti takvih uređaja naspram konvencijalnih metoda kao što je to mjerenje u nestacionarnim uvjetima toka, značajna preciznost, veći opseg prikupljenih podataka i informacija vezanih za fiziku strujanja te brzina samog mjerenja i učinkovitost. Visoko frekvencijski hidroakustični uređaji koji se koriste u hidrometriji se dijele na ADCP i ADV uređaje.

Prvo pojavljivanje ADCP uređaja za mjerenje protoka datira još od 1982. godine [R3], kada je kompanija RD Instruments iz Kalifornije po prvi puta konstruirala ADCP uređaj s baterijskim

napajanjem, namijenjen dugoročnim mjerenjima. Već 1986 RDI producira tri različita tipa ADCP uređaja (75 do 1200 kHz) namijenjenih za samostalnu instalaciju, pokretnu platformu (plovilo) i izravno mjerenje. Do 1991. godine ADCP uređaji koriste uskopojasni samostalni puls te autokorelacijsku metodu za proračun prvog momenta Dopplerovog spektra frekvencija. Širokopojasni ADCP uređaji koji su slijedili, smanjili su varijancu za 100 puta u odnosu na uskopojasne uređaje te kod mjerenja nude znatno više informacija i točniju procjenu brzine.

ADCP uređaj ima mogućnost snimanja vektorskog polja brzina vode. Mjerenja se vrše pokretno po prostorno dubinskim segmentima vodotoka, koji mogu biti manji od 5 cm pa na dalje u ovisnosti o radnoj frekvenciji uređaja. Mjerenje može sadržavati maksimalno 128 dubinskih segmenata što bi za usporedbu mjerenja klasičnim, hidrometrijskim krilom zahtijevalo 128 mjernih točaka samo na jednoj brzinskoj vertikali.

Prikladni transduktor (oscilator pretvarač) kao izvor ultrazvuka, upućuje zvučni udarac kroz vodu (ping). Odaslani ultrazvuk reflektira se od suspendiranih čestica u vodi koje imaju isti smjer i brzinu kao masa vode. Dio energije koji se uslijed refleksije vraća na izvor (transduktor) moguće je izmjeriti piezoelektričnim transduktorom. Takav transduktor djeluje kao izvor i kao prijemnik ultrazvuka (pijezo elektricitet je reverzibilan). Razlika emitirane i primljene energije na transduktoru određuje se kao promjena frekvencije zvuka, poznata pod nazivom Dopplerov pomak. Drugim riječima razlika između registriranog zvuka, to jest frekvencije uslijed gibanja prema ili od izvora je Dopplerov pomak koji se opisuje izrazom (3.4):

$$F_d = F_s \cdot \frac{V}{c} \tag{3.4}$$

U izrazu (3.4), F_d predstavlja Dopplerov pomak ili razliku frekvencija uslijed gibanja izvora koja može biti pozitivna ili negativna, F_s je frekvencija zvuka kod mirovanja izvora, V predstavlja relativnu brzinu između izvora i prijemnika zvuka (m/s), dok c predstavlja brzinu zvuka (m/s). Treba primijetiti da se prema izrazu (3.4) može zaključiti kako povećana relativna brzina između prijemnika i izvora kod približavanja ujedno povećava i Dopplerov pomak, a zbog udaljavanja prijemnika od izvora Dopplerov pomak postaje negativan. Ako se frekvencija zvuka povećava, povećava se i Dopplerov pomak, a ako se brzina zvuka povećava Dopplerov pomak se smanjuje.

Dopplerov pomak ili Dopplerov efekt je nazvan prema austrijskom fizičaru Christianu Doppleru (1803.-1853.) i opisuje promjenu promatrane valne duljine vala zbog međusobnog približavanja ili udaljavanja izvora i promatrača. Zvuk predstavlja periodičnu promjenu tlaka koja se širi elastičnim medijem, to jest, plinovitim, tekućim ili krutim elastičnim tvarima. Dakle, zvuk

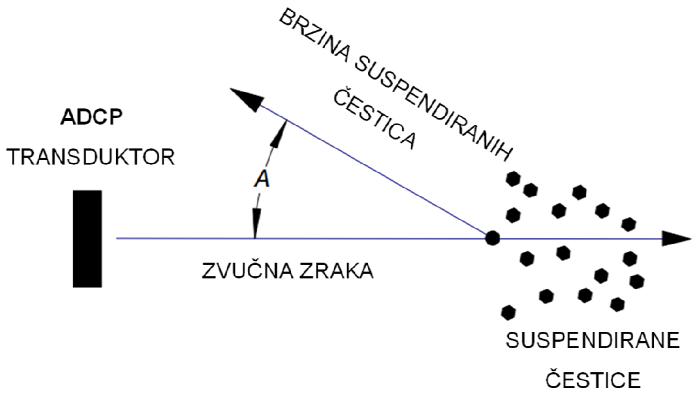
se opisuje kao valna pojava koja ima karakteristike kao što su valna duljina, frekvencija i brzina. Brzina zvuka u vodi pri temperaturi od 20°C i tlaku od 1 atm iznosi 1482 m/s ili 5336 km/h. U odnosu na komponente vala, frekvenciju (f) i duljinu (λ) brzina zvuka (C) se može dobiti prema izrazu (3.4):

$$C = f \cdot \lambda \tag{3.5}$$

U slučaju mjerenja protoka izvor zvuka se odbija o suspendirane čestice unutar toka i vraća se ka prijemniku. Kako ADCP u transduktoru ima i izvor i prijemnik zvuka, Dopplerov pomak se udvostručuje te se izraz (3.4) sukladno tome mijenja u:

$$F_d = 2F_s \cdot \frac{V}{c} \tag{3.6}$$

Ograničavajući čimbenik na Dopplerov pomak kod mjerenja brzine suspendiranog nanosa je razlika u kutu između zvučne zrake i relativnog vektora brzine suspendiranih čestica, to jest kut crte između kraka što spaja transduktor i suspendirane čestice i relativnog vektora brzine.

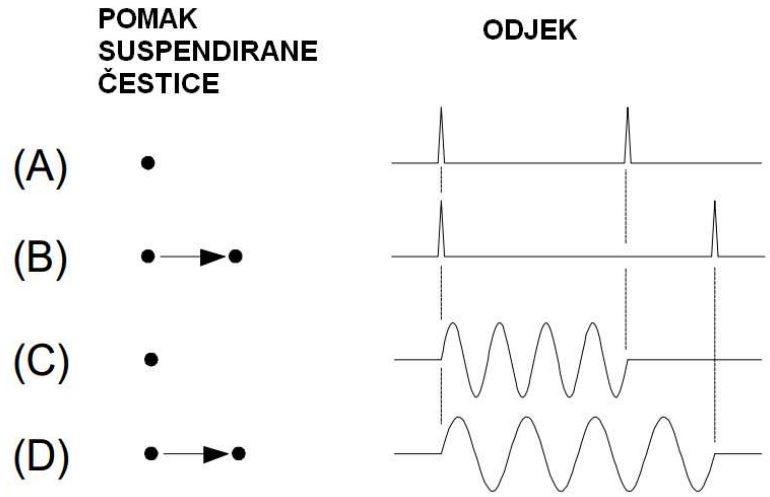


Slika 3.4 Prikaz načina mjerenja brzine suspendiranih čestica ADCP uređajem pri kojem se mjeri samo paralelna komponenta relativnog vektora brzine sa zvučnom zrakom. Oznaka A predstavlja kut između zvučne zrake i relativnog vektora brzine.

Prema slici 3.4 može se vidjeti kako je Dopplerov pomak ograničen kutom (A), to jest radijalnom komponentom te izraz (3.6) zbog toga poprima dodatni član:

$$F_d = 2F_s \cdot \frac{V}{c} \cos(A) \tag{3.7}$$

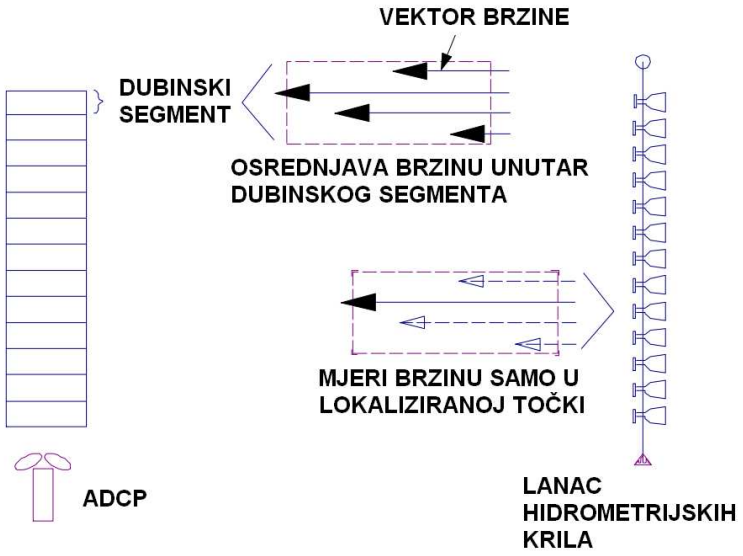
Mnogi Dopplerovi sonari koriste izravno mjerenje Dopplerovog pomaka, a RDI ADCP koji je u ovom radu korišten, mjeri vremensku dilataciju i to preko faznog pomaka. Zbog računalnog optimiziranja, preciznosti i praktičnosti kod proračuna, sam uređaj ne bilježi razliku u frekvencijama, to jest Dopplerov pomak, nego fazni pomak preko kojeg je lako doći i do vremenske dilatacija (Slika 3.5). Znajući udaljenost suspendirane čestice od transduktora kroz vrijeme, može se izračunati i vektor njene brzine.



Slika 3.5 Usporedni prikaz vremenske dilatacije. (A) i (B) prikazuju situacije zabilježenog odjeka za suspendiranu česticu u mirovanju i pokretu. (C) i (D) prikazuju isto, osim s razlikom u odabiru pulsa koji je u ovom slučaju sinusiodalan za razliku od dva kratka pulsa u prethodnom slučaju. Vidljivo je da vremenska dilatacija je jednaka u oba slučaja te analogno tome i zapis u odjeku.

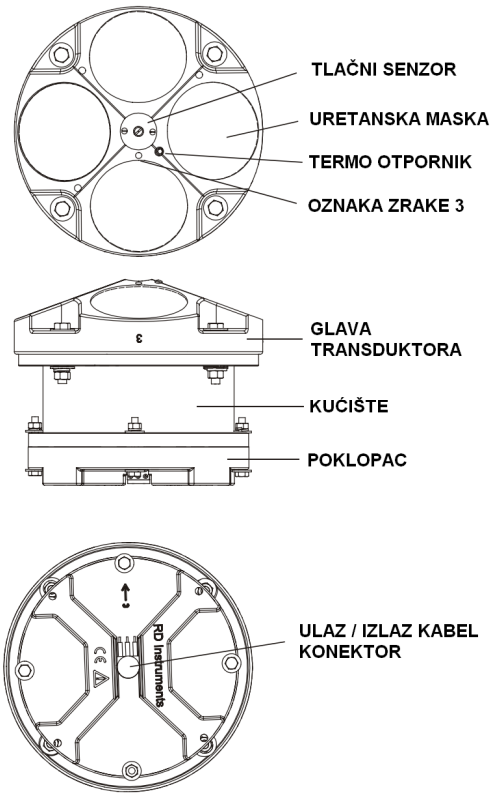
Autokorelacijom se uspoređuju zapisi odjeka pa se pri tom mogu detektirati i najmanji pomaci faze, tj. najmanje zabilježene brzine. U jednom odaslanom pulsu iz transduktora se kriju više njih kodiranih koji se analiziraju u odjeku autokorelacijskom metodom. Preduvjet za takav pristup analiziranju pomaka faze je korelacija svakog odaslanog pulsa međusobno.

Mogućnost osrednjavanja brzine po dubinskim segmentima na profilu od interesa je glavna prednost ADCP uređaja u odnosu na konvencionalne metode. Slika 3.6 zorno prikazuje razlike kod mjerenja na brzinskom profilu. Ovisno o uređaju i preferencijama korisnika maksimalni broj vertikalnih segmenata može varirati kao i njihova dimenzija. Veće radne frekvencije daju bolju preciznost no manja im je radna dubina za razliku od nižih frekvencija. Uobičajeno je da se frekvencija uređaja može podesiti prema zahtjevima korisnika i radnog zadatka. Tipične radne frekvencije ADCP uređaja su 1200 kHz, 600 kHz i 300 kHz dok brzina odašiljanja zvučnog pulsa iznosi 2 Hz.



Slika 3.6 Usporedni prikaz mjerenja protoka ADCP uređajem i klasičnim hidrometrijskim krilom.

Uređaj koji je korišten prilikom izrade ove disertacije ima komercijalni naziv Workhorse Monitor proizvođača Teledyne RD Instruments. Slika 3.7 prikazuje specifikaciju glave transduktora sastavljenog od četiri zvučne zrake [R3].



Slika 3.7 ADCP Workhorse Monitor Teledyne RD Instruments, Komponente transduktora.

Kao što je ranije opisano, četiri zvučne zrake osiguravaju određivanje tri komponente brzine i pozicije dna kako bi se integriralo polje brzina. Pregled specifikacija uređaja je prikazan u tablici 3.2.

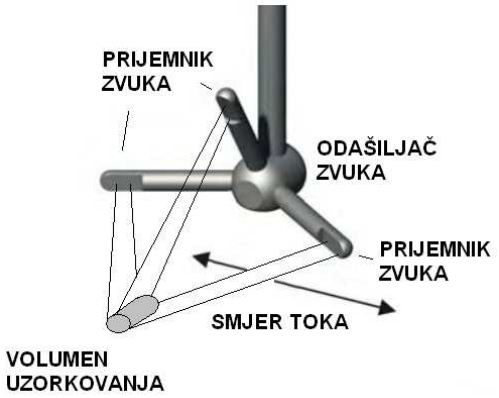
Tablica 3.2 *Tehničke karakteristike ADCP uređaja Workhorse Monitor Teledyne RDI*

Profiliranje poprečnog presjeka	Dimenzije vertikalnog segmenta[1]	Domet[2] 12 m **1200 kHz**		Domet[2] 50 m **600 kHz**		Domet[2] 110 m **300 kHz**	
	Vertikalna rezolucija	Domet[3]	Std. devijacija[4]	Domet[3]	Std. devijacija[4]	Domet[3]	Std. Devijacija[4]
	0,25 m	11 m	14,0 cm/s				
	0,5 m	12 m	7,0 cm/s	38 m	14,0 cm/s	vidi fusnotu [1]	
	1 m	13 m	3,6 cm/s	42 m	7,0 cm/s	83 m	14,0 cm/s
	2 m	15 m	1,8 cm/s	46 m	3,6 cm/s	93 m	7,0 cm/s
	4 m	vidi fusnotu [1]		51 m[2]	1,8 cm/s	103 m	3,6 cm/s
	8 m					116 m[2]	1,8 cm/s
Dalekometni način rada	2 m	19 m	3,4 m/s				
	4 m			66 m	3,6 cm/s		
	8 m					154 m	3,7 cm/s
Parametri profila	Točnost mjerenja brzine	0,3 % od brzine vode relativno prema ADCPu ± 0,3 cm/s		0,3 % od brzine vode relativno prema ADCPu ± 0,3 cm/s		0,5 % od brzine vode relativno prema ADCPu ± 0,5 cm/s	
	Rezolucija mjerene brzine	0,1 cm/s		0,1 cm/s		0,1 cm/s	
	Raspon brzina	± 5 m/s tvornički, ± 20 m/s max.		± 5 m/s tvornički, ± 20 m/s max.		± 5 m/s tvornički, ± 20 m/s max.	
	Broj vertikalnih segmenata	1 - 128		1 - 128		1 - 128	
	Brzina odašiljanja zvučnog pulsa	2 Hz (tipična vrijednost)		2 Hz (tipična vrijednost)		2 Hz (tipična vrijednost)	
Profil intenziteta odjeka	Vertikalna rezolucija	Dimenzije vertikalnog segmenta, podesivo prema korisniku					
	Dinamički raspon	80 dB					
	Preciznost	± 1,5 dB					
Transduktor i hardware	Kut zrake	20°					
	Konfiguracija	4 zrake, konveksne					
	Interna memorija	Dva PCMCIA kartična utora, bez memorijske kartice					
	Komunikacija	Serijski port, odabire se s prekidačem za RS-232 ili RS-422. ASCII ili binarni output (1200 - 115200 baud)					
Software	TRDI Windows programi: **WinSC** - skidanje podataka, **WinADCP** skidanje podataka i prikaz ili **WinRiver** - skidanje podataka i prikaz						
Napajanje	Ulaz	20 - 50 V DC					
Standardni senzori	Temperatura	Raspon -5° do 45°C, Preciznost ± 0,4°C, Rezolucija 0,01°C					
	Akcelerometar	Raspon ± 15°, Točnost ± 0,5°, Rezolucija 0,01°, maksimalni nagib ± 15°					
	Kompas	Točnost ± 2° [5], preciznost ± 0,5° [5], Rezolucija 0,01°, maksimalni nagib ± 15°					
Dimenzije	228,0 mm x 201,5 mm						

[1] Odabir korisnika vezan za dimenzije vertikalnog segmenta nije limitiran naznačenim tipičnim dimenzijama
[2] Dostupno u dugometnom načinu rada
[3] Rasponi profiliranja temeljeni na temperaturnim vrijednostima od 5° do 20°C, salinitet 35 ppt.
[4] Širokopojasni način rada, standardna devijacija jednog pinga
[5] < ±1,0° uobičajeno se postiže nakon kalibracije

Kako se kod ADV uređaja, za razliku od ADCP instrumenta, određuje protok u jednoj točki, bitno je karakteristične razlike uočiti u konstrukciji instrumenta te uporabi. Princip Dopplerovog pomaka se koristi i kod ADV uređaja, ipak kako je transduktor konstruiran bistatično (odvojeni odašiljač zvuka od prijemnika), izraz kojim se određuje razlika u frekvencijama je upravo (3.4) [S5]. ADV je dizajniran za snimanje trenutnih komponenti brzine u jednoj točki vodotoka s relativno visokom frekvencijom. Mjerenja se provode pomoću mjerenja brzine čestica u volumenu uzorkovanja prema principu Dopplerovog pomaka. Konstruirana akustična sonda koja registrira brzine u jednoj točki može imati dva ili tri prijemnika, te sukladno toj konstrukcijskoj karakteristici, može odrediti dvije ili tri komponente brzine. Brzina se određuje u volumenu

uzorkovanja koji iznosi 0,25 cm^2 i udaljen je 10 cm od odašiljača zvuka. Slika 3.7. prikazuje ADV sondu uređaja SONTEK ADV Flowtracker [S5].



Slika 3.8 Akustična sonda ADV uređaja SONTEK Flowtracker

Tehničke specifikacije ADV uređaja SONTEK Flowtracker su prikazane u tablici 3.3. Iz njih je vidljivo kako ovaj uređaj zahtjeva dodatno postprocesiranje podataka te odvojeno snimanje geometrije profila kako bi se odredio protok. Postprocesiranje podataka prikupljenih ADV uređajem će se u nastavku detaljnije opisati.

Tablica 3.3 *Tehničke karakteristike ADV uređaja SONTEK Flowtracker*

Brzina	Raspon	± 0,001 do 4,0 m/s
	Rezolucija	0,0001 m/s
	Točnost	± 1% mjerene brzine, ±0,25 cm/s
Lokacija volumena uzorkovanja	10 cm od centra transduktora	
Komunikacijski protokol	RS-2332	
Napajanje	8 AA alkalnih baterija (25+ operativnih sati)	
Masa	1,8 kg	
Širina akustične sonde	130 mm	
LCD/Monitor	Kratkoročno potapanje do 1 m dubine	
Operativna / skladišna temperatura	-20° do +50°C	

Hidroakustika i njeni principi se koriste također i u svrhu lociranja objekata ispod vode. Kako je moguće dobiti odjek od gibajućih čestica, tako je to moguće i kod stacionarnih predmeta. Sonarsko lociranje se koristi kod dubinomjera, snimanja geometrije riječnih korita i jezera. Za potrebe izrade ove disertacije, a prilikom znanstveno istražnih radova na Crvenom jezeru u Imotskom, korišten je komercijalni sonar, to jest uređaj za podvodno lociranje s radnom frekvencijom od 670 kHz i snagom od 23 dB.

Primjena hidroakustike je višenamjenska pri hidrološkim mjerenjima, a pristup i iskoristivost opreme uvelike ovisi o korisniku i namjeni instrumenata.

3.1.3 Radar

Radarski uređaji za mjerenje površinske brzine vodotoka imaju sve veću ulogu u hidrometriji [F6]. Njihova praktičnost se zasniva na činjenici da mjerenja ne zahtijevaju izravan kontakt s vodotokom, nego se mogu provesti s neke udaljene lokacije, što kod ekstremnih hidroloških situacija ima visoki značaj za sigurnost pri mjerenjima.

Radar i sonar dijele iste principe u fizici prema kojima određuju lokaciju ili brzinu promatranog objekta. Osnovna razlika je u tipu odaslanih valova koji su kod sonara su akustični, a kod radara radio valovi. Tip radara kontinuiranih valova (CW radar) se koristi kod određivanja brzina jer može odaslati više valova različitih frekvencija, a preko Dopplerovog pomaka, analogno ADCP i ADV uređajima, određuje brzinu objekta.

Radar koji se koristio tijekom znanstveno-istražnih radova vezanih za ovu disertaciju nosi oznaku RYUKAN WJ7661 [Y1], japanskog proizvođača Yokogawa Denshikiki Co., Ltd., a njegove specifikacije su prikazane u tablici 3.4.

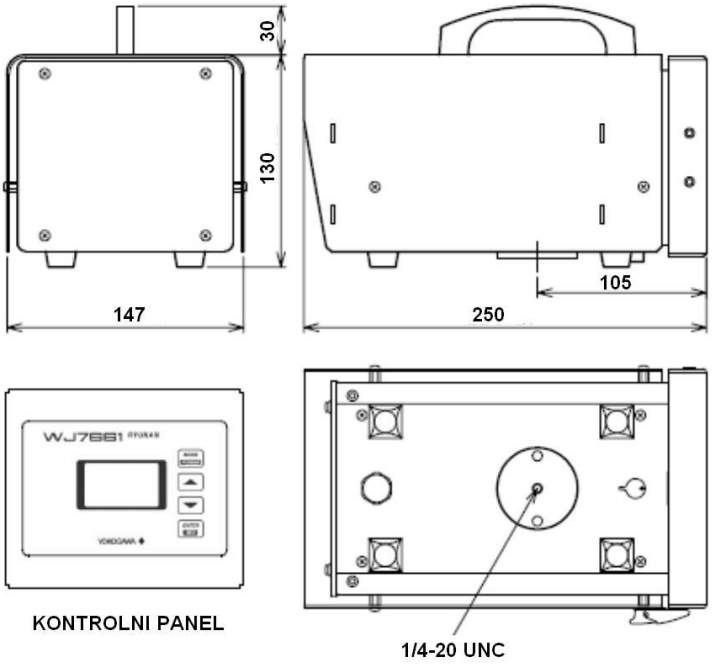
Tablica 3.4 *Tehničke karakteristike radarskog uređaja RYUKAN WJ7661.*

RYUKAN WJ7661	
Stavka	Sadržaj
Princip mjerenja	Mikrovalni Dopplerov pomak
Korišteni radio valovi	CW 24,15 GHz 7 mW tip.
Antena	Horn antena, polukut 12°
Raspon mjerenja	0,5 m/s do 20 m/s
Točnost	± 2% ± 0,05 m/s od mjerene brzine
Rezolucija	0,01 m/s
Vrijeme osrednjavanja	Podesivo: 1 s, 2s, 10 s, 20 s 30 s, 1 min, 2 min, 5 min ili 10 min [(1)]
Kut mjerenja	Inklinacija 20° do 45°; Devijacija 0°do 20°
Udaljenost pri mjerenju	20 m ili manje [(2)]
Display	Monokromni LCD, 128 x 64 točke s LED osvjetljenjem
Memorija	Ugrađena flash memorija 65000 podataka
Komunikacija	USB 2.0; USB Memorijski stick [(3)]
Operativna temperatura	-10° do +50°C
Skladišna temperatura	-20° do +60°C
Napajanje	6 AA alkalnih baterija (aproksimativno 5 radnih sati [(4)])
Dimenzije	147 mm (Š) x 130 mm (V) x 250 mm (D)
Masa	2 kg

[(1)] 20 s ili više je preporučivo za rijeke
[(2)] Ovisi o stanju površine vode
[(3)] Preporučuje se standardni USB prenosivi stick
[(4)] Ako se ne koristi ekstema USB memorija te pozadinsko LED svjetlo stoji isključeno

Kao što se može vidjeti iz tehničkih specifikacija radarskog uređaja, nužno je da zraka bude usmjerena paralelno s tokom ili do maksimalno 20° ukošena u odnosu na smjer toka. Horizontalna inklinacija zrake u odnosu na vodotok iznosi 20°do 45°. Ove podatke je nužno unijeti u uređaj pri

mjerenju kako bi se provele potrebne prilagodbe kod proračuna brzine. Preporučljivi interval osrednjavanja brzine je minimalno 20 sekundi. Naravno, na korisniku je da odabere duljinu intervala, no pokazalo se da kod nemirne površine, to jest izrazite pulsacije površinske brzine, dulji intervali osrednjavanja daju bolje rezultate. Slika 3.9 prikazuje radarski uređaj te kontrolni panel preko kojeg se unose sve operativne komande.



Slika 3.9 Radarski mjerač površinske brzine toka RYUKAN WJ7661 (dimenzije su u mm)

Praktičnost primjene radara se pokazuje brzom akvizicijom podataka s visokom točnošću te sigurnošću na radu postignutom zbog neizravnog kontakta s vodotokom. Podaci se pohranjuju u internu memoriju a njihov zapis u CSV formatu se može prenosim USB memorijskim uređajem eksportirati. Ipak nužno je voditi i dodatne bilješke kao što su to stacionaže brzinskih vertikala na promatranom profilu.

3.1.4 LiDAR tehnologija i digitalna fotogrametrija

U analizi morfoloških karakteristika krškog terena kao i geometrije pojedinih vodnih tijela, koriste se klasične geodetske metode te upotrebljavaju totalne stanice i GPS prijemnici, no dostupnost novih tehnologija kao što su to LiDAR i digitalna fotogrametrija čini tu zadaću jednostavnijom i učinkovitijom. Velike količine prikupljenih podataka i preciznost snimanja omogućavaju iznimno kvalitetne analize prostornih oblika u terenu [H4].

LiDAR (Light Detection And Ranging) tehnologija temelji se na fizici svjetlosti, to jest poznavanju brzine svjetlosti i uskom koherentnom snopu laserske zrake koju mjerni uređaj emitira u prostor. LASER (Light Amplification by Stimulated Emission of Radiation) je optička naprava koja emitira koherentni snop fotona. Funkcioniranje mjernih uređaja s LiDAR tehnologijom je analogno funkcioniranju radara i sonara. Razlika između LiDAR tehnologije i radara je u tome što LiDAR odašilje jako uski puls svjetlosti, a radar širokovalni radio signal. Zraka se kreće brzinom svjetlosti te se odbija od predmeta u prostoru i u konačnici vraća u prijemnik. Prijemnik i odašiljač se nalaze u kućištu uređaja. Uređaj također mjeri vrijeme prolaska laserske zrake do prepreke i natrag do prijemnika.

Ako je brzina svjetlosti poznata i iznosi 0,3 m/ns onda se udaljenost do prepreke može izračunati prema sljedećem izrazu:

$$D = \frac{c \cdot t}{2} \tag{3.7}$$

gdje su oznaka D udaljenost, c brzina svjetlosti, a t mjereno vrijeme od odašiljanja zrake do registriranog povratka. Kako je vrijeme potrebno da foton pređe mjerenu udaljenost dva puta (od uređaja do prepreke i natrag), potrebno je desnu stranu izraza podijeliti sa dva.

Korištenjem podataka o udaljenosti i kutovima, to jest razmaku između izmjerenih točaka, svaka od točaka može biti prezentirana u kartezijanskom koordinatnom sustavu (x, y, z). Uređaj također bilježi i intenzitet vraćenog signala što može dati informacije i o skeniranom materijalu u ovisnosti o reflektanci pojedinačnog materijala.

Terestrialni LiDAR uređaj korišten kod znanstvenog rada vezanog za ovu doktorsku radnju je model ILRIS 3D kanadskog proizvođača Optech [P9]. Njegove tehničke specifikacije su prikazane u tablici 3.5.

Na tržištu postoje mnoga računalna rješenja za analizu i obradu oblaka točaka prikupljenih LiDAR tehnologijom. Ipak, važno je naglasiti da pri takvoj analizi presudni udio ima računalna moć računala na kojem se analiza vrši. Manipuliranje s ogromnom količinom podataka u virtualnom kartezijanskom koordinatnom sustavu zahtjeva prije svega izrazitu grafičku i računalnu moć računala. Uspoređivanje skeniranih točaka kao i preklapanje različitih skeniranih područja se provodi statističkim i geostatističkim metodama tako da nedostatni kapaciteti računala produljuju rad i umanjuju efikasnost instrumenta.

Tablica 3.5 *Tehničke karakteristike LIDAR 3D skenera ILRIS 3D Optech*

ILRIS 3d Optech (LIDAR - 3D scanner)	
Parametar	Sadržaj
Udaljenost merenja uz 80% refleksiju	1250 m
Udaljenost merenja uz 10% refleksiju	400 m
Minimalna udaljenost	3 m
Brzina laserske repeticije	10000 Hz
Najveće postignuta preciznost udaljenosti	4mm na 100 m
Najveće postignuta kutna preciznost	8 mm na 100 m (80 µrad)
Vidno polje	40° x 40°
Minimalna veličina koraka	0,000745° (13 µrad)
Maksimalna gustoća točaka	1,3 cm na 1000 m
Rotacijska brzina	0,001° do 20° /s
Minimalna veličina rotacijskog koraka	0,001146° (20 µrad)
Promjer zrake	19 mm na 100 m
Laserska valna duljina	1535 nm
Klasa lasera	1 ili 1M
Integrirana kamera	3,1 MP
Veličina uređaja (D x Š x V)	320 mm x 320 mm x 240 mm
Masa	14 kg
Operativna temperatura	0° do +40°C
Skladišna temperatura	-20° do +50°C
Relativna vlažnost	0 do 95 %
Napajanje	75 W (baterija traje 5 operativnih sati)
Pohranjivanje podataka	Prijenosna USB memorija

Ipak, mora se naglasiti da zbog visoke nabavne cijene, ovi uređaji još ne nalaze široku primjenu u poljima kao što su to na primjer geologija, građevinarstvo, arhitektura, arheologija ili forenzika.

Jeftiniji sustav za snimanje 3d modela u prirodi se može naći u rješenju temeljenom na digitalnoj fotogrametriji. Po definiciji fotogrametrija je znanost ili tehnika određivanja oblika, veličine ili položaja nekog objekta snimanjem, mjerenjem i interpretacijom fotografskih snimaka.

Sustavi digitalne fotogrametrije se sastoje od digitalne kamere i računalnog programa koji na osnovu fotografija izrađuje 3D digitalni model. Digitalna fotogrametrija u kombinaciji s drugim, na primjer projektorskim postupcima, te u sprezi s tehnikama računalne analize slike, omogućuje gotovo u potpunosti automatizirano dobivanje trodimenzijskoga digitalnog modela snimljenog objekta.

Korišteni sustav u ovom radu temelji se na računalnom programu KURAVES-G^2, proizvođača KURABO Industries iz Japana [K3], te Canon SLR digitalnom kamerom.

3.2 HIDROMETRIJSKE METODE MJERENJA

Metode mjerenja se uglavnom odnose na korištenje hidroakustike i radara. Te tehnologije zahtijevaju definirane pristupe i protokole kako bi se njihova učinkovitost i točnost maksimizirala. Pri određivanju protoka u otvorenim kanalima, potrebno je definirati karakteristike toka koji se promatra.

Tok može biti karakteriziran u ovisnosti o dva osnovna parametra, a to su vrijeme i udaljenost. Prva podjela temeljena na promatranoj vremenskoj skali dijeli tok na stacionarni i nestacionarni. Druga podjela se odnosi na skalu udaljenosti, a prema njoj tok može biti jednolik ili nejednolik. Većina tokova u prirodi može se svrstati u jednu od sljedećih kategorija [B7, B8, H2, J6, N1]:

- Stacionarno jednoliko tečenje gdje je protok konstantan s vremenom kao i površina poprečnog presjeka korita. Tipičan primjer su uređeni i stabilizirani vodotoci.
- Stacionarno nejednoliko tečenje gdje je protok konstantan s vremenom, ali površina poprečnog presjeka korita nije. Tipičan primjer je stacionarno tečenje u rijekama gdje je svaki profil različit.
- Nestacionarno jednoliko tečenje gdje je površina poprečnog presjeka korita konstantna, a protok kroz vrijeme varira. Tipičan primjer je tok pod tlakom kroz cijev.
- Nestacionarno nejednoliko tečenje gdje ni protok ni površina poprečnog presjeka korita nisu konstantni kroz vrijeme. Primjer takvog toka je prolaz vodnog vala kroz prirodno korito te za analiziranje predstavlja najkompleksniji zadatak.

Protok se može mjeriti kod sva četiri slučaja toka. Ove podjele toka se još zovu i kinematske podjele, a osim njih moguće su i dinamičke podjele. Podjela između laminarnog i turbulentnog tečenja se odnosi na tok gdje se ne miješaju slojevi (lamina) i tok gdje se slojevi miješaju, tj. gdje se djelići tekućine ne gibaju u istom sloju. Dakle vertikalna distribucija brzina u nekom toku ovisi upravo o ovoj kategorizaciji, odnosno o Reynoldsovom broju (3.8).

$$\mathrm{Re} = \frac{v \cdot D}{\upsilon} \tag{3.8}$$

U izrazu (3.8), Re predstavlja Reynoldsov broj, v je brzina toka (m/s), D je dubina (m), a ν je kinematička viskoznost tekućine (m^2/s). Reynoldsov broje je bezdimenzionalan, a kada je manji od 400 vodotok ima laminarno tečenje, između 400 i 800 ima prijelazni režim, a za vrijednosti

veće od 800 tok je turbulentan. U prirodi su laminarni tokovi unutar otvorenih kanala kako na površini tako i u podzemlju iznimna rijetkost, jer većina tokova se odvija unutar turbulentnog režima.

Druga dinamička podjela se odnosi na mirno, kritično i silovito tečenje odnosno veličinu Froudeovog broja kojeg opisuje izraz (3.9).

$$Fr = \frac{\bar{v}}{\sqrt{g \cdot A / B_s}} \tag{3.9}$$

Gdje je *Fr* Froudeov broj, oznaka $\bar{v}$ je srednja brzina na promatranom presjeku (m/s), *A* je površina presjeka (m^2), a B_s je širina vodotoka pri promatranom vodostaju. Za široke rijeke A/B_s približno iznosi *d*, gdje *d* predstavlja srednju dubinu vodotoka. Ako je Froudeov broj manji od jedan, tečenje je mirno, ako je jednak jedan tečenje je kritično, a ako je veći od jedan tečenje je silovito.

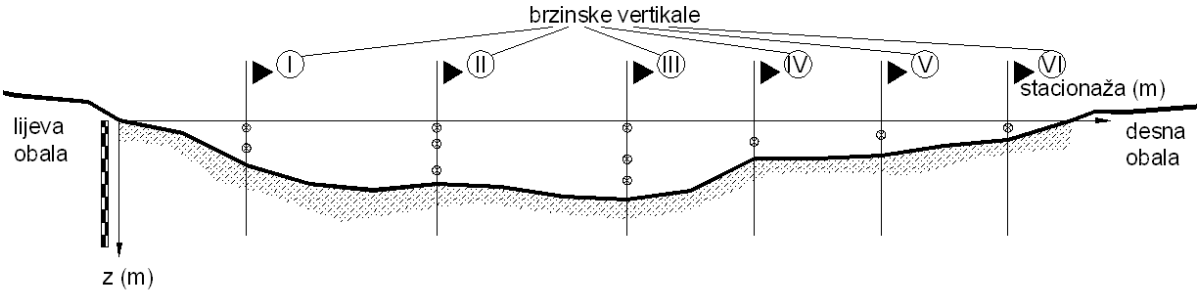
Osnovni koncept protoka zasniva se na relaciji između protoka, brzine i površine presjeka. Kod otvorenih tokova u prirodi (rijeka i umjetnih kanala), protok (3.10) u bilo kojem trenutku se može izraziti kao:

$$Q = \bar{v} \cdot A \tag{3.10}$$

gdje je *Q* protok (m^2/s), $\bar{v}$ srednja brzina na promatranom presjeku (m/s), a A je površina presjeka (m^2). Prema osnovnom konceptu se zasniva i glavna metoda mjerenja protoka koja se sastoji od određivanja brzine i površine protoka. Ta metoda se naziva još metoda brzine i površine za razliku od nekih drugih primjenjivanih kao što su metoda nagiba, metoda razrjeđenja, elektro magnetska metoda ili metoda mjerenja hidrotehničkim građevinama.

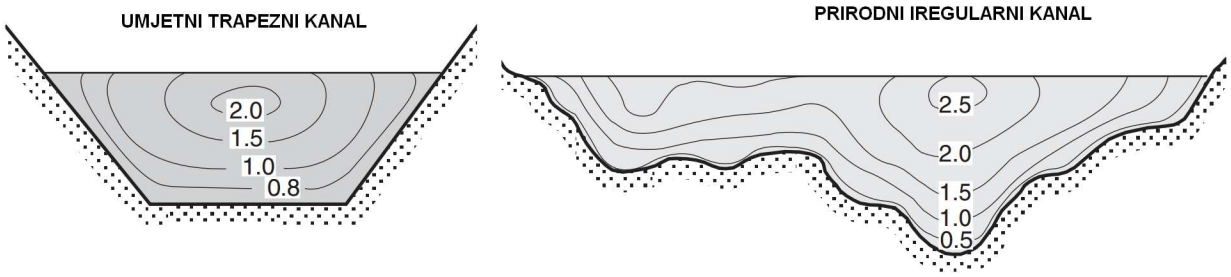
ADCP mjerenja i ADV mjerenja protoka zasnivaju se na metodi brzine i površine, dakle, mjerenja se svode na problem određivanja srednje brzine i površine poprečnog presjeka. Površina se mjeri određivanjem stacionaže pojedinih vertikala, a vertikale sadržavaju podatke o dubini i lokacijama točaka na kojima se mjeri brzina (slika 3.10). Snimanje površine presjeka na terenu se dakle sastoji u mjerenju udaljenosti vertikale od lijeve obale te određivanju dubine na tom mjestu. Pri tom se koriste razne tehnike no u slučaju ADCP uređaja, površina presjeka se određuje hidroakustikom i ugrađenim akcelerometrom koji mjeri relativnu poziciju mjernog uređaja. Nadogradnje s GPS prijemnicima pri mjerenju površine presjeka su sve učestalije i prelaze u širu primjenu. Kod mjerenja brzine u jednoj točki (ADV) dubine se mogu mjeriti s baždarenom letvom

ili užetom s utegom na kraju, a udaljenost od lijeve obale (stacionaža) vrpcom ili GPS prijemnikom.



Slika 3.10 Prikaz principa mjerenja površine na poprečnom presjeku obale i brzina u točki

Distribucija brzina unutar poprečnog presjeka snažno ovisi o geometriji (obliku) promatranog profila kao što je to prikazano na slici 3.11. Važno je naglasiti kako je značajna distribucija brzina kako u horizontalnom pravcu, tako i u vertikalnom. Vertikalna distribucija brzina se još naziva i profilom vertikalnih brzina, a određuje se za svaku brzinsku vertikalu. Postavlja se pitanje o odabiru broja brzinskih vertikala i količine mjernih točaka.

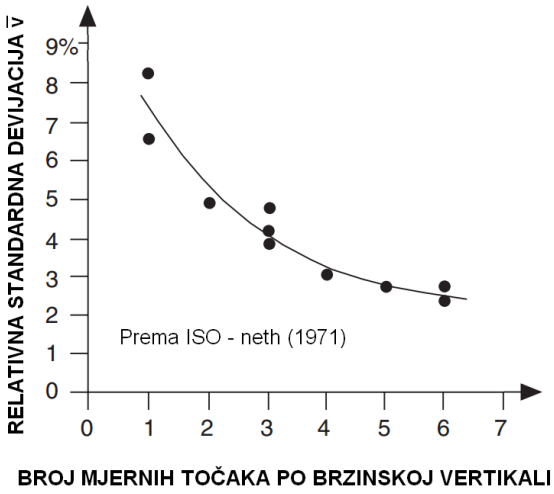


Slika 3.11 Primjer distribucije brzina po promatranom presjeku za trapezni i iregularni kanal

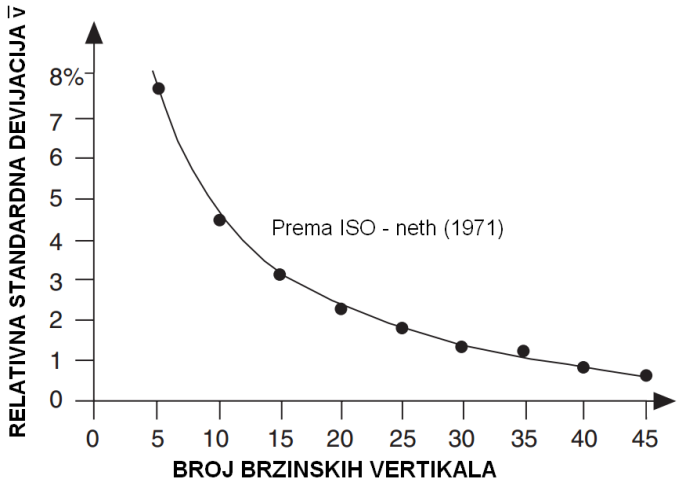
Odabir broja mjernih točaka po brzinskoj vertikali i broja brzinskih vertikala na presjeku ovisi o traženoj točnosti mjerenja (više informacija o pojedinačnim brzinama daju precizniju procjenu srednje brzine na presjeku), ekonomičnosti mjerenja (više mjerenih točaka oduzima više vremena, to jest poskupljuje mjerenja) i praktičkim okolnostima (uvjeti nestacionarnog tečenja)

Tehnički odbor Internacionalne organizacije za standardizaciju (ISO) je izradio studiju o utjecaju odabira broja brzinskih vertikala i broja mjernih točaka na točnost mjerenja protoka. Studija se temelji na velikom broju mjerenja protoka na rijekama u SAD-u, Europi i Indiji [B11]. Slika 3.12 i slika 3.13 pokazuju odnos standardne devijacije srednje brzine kao funkciju broja mjernih točaka brzine u svakoj vertikali i broja brzinskih vertikala. Iz slike 3.11 je vidljivo kako

odabir više od 3 točke za mjerenje brzine po vertikali jako malu u konačnici povećava točnost mjerenja, a slika 3.13 sugerira da mjerenja s pokretnim plovilom, to jest mjerenja s velikim brojem brzinskih vertikala itekako povećavaju točnost.



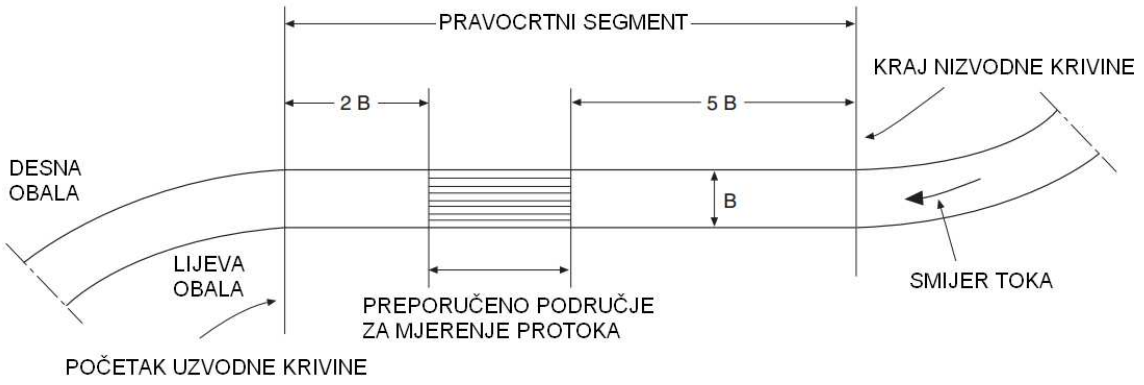
Slika 3.12 Broj mjernih točaka po brzinskoj vertikali u odnosu na točnost mjerenja srednje brzine



Slika 3.13 Broj brzinskih vertikala u odnosu na točnost mjerenja srednje brzine

Kod odabiranja područja na vodotoku za mjerenje protoka, potrebno je udovoljiti nekim od osnovnih zahtjeva struke, kako bi se točnost mjerenja maksimizirala. Segment na kojem se mjeri protok bi trebao biti pravocrtan i relativno ravnomjernog profila [B23]. Kontrahiranje profila ili naglo širenje uzrokuje velike nepravilnosti kod određivanja protoka. Ipak u nekim slučajevima, kao što su to ekstremne hidrološke situacije, ovi uvjeti ne mogu biti zadovoljeni, pa se mjerenja pokušavaju poboljšati odabirom većeg broja brzinskih vertikala. Geometrija korita bi trebala biti

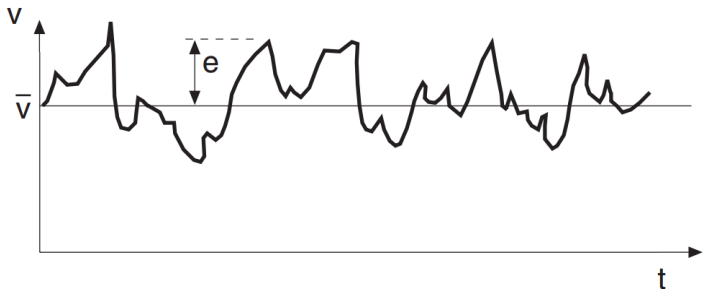
stabilna jer u slučaju promjena, odnos između protoka i vodostaja se mijenja. Slika 3.14 sumira osnovne zahtjeve kod odabira segmenta vodotoka za mjerenje protoka.



Slika 3.14 Broj brzinskih vertikala u odnosu na točnost mjerenja srednje brzine

Nakon mjerenja geometrije poprečnog presjeka, odabira broja mjernih točaka i brzinskih vertikala te odabira lokacije mjerenja, prikupljeni podaci se koriste za određivanje srednje brzine presjeka. Pri tom, kao što je već naglašenu, uzima se u obzir vertikalna distribucija brzina, to jest određivanje brzinskih profila, te horizontalna distribucija brzina unutar presjeka.

Zadatak mjerenja brzine u pojedinoj točki adresira i pitanje intervala osrednjavanja. Naime, brzine mjerene prema vremenskom koraku nisu jednake zbog pulsacije brzine, kako na površini, gdje je ta pojava puno izraženija, tako i u bilo kojoj drugoj točki na brzinskoj vertikali. Slika 3.15 prikazuje varijaciju brzine mjerene u točki vodotoka kroz vrijeme mjerenja.

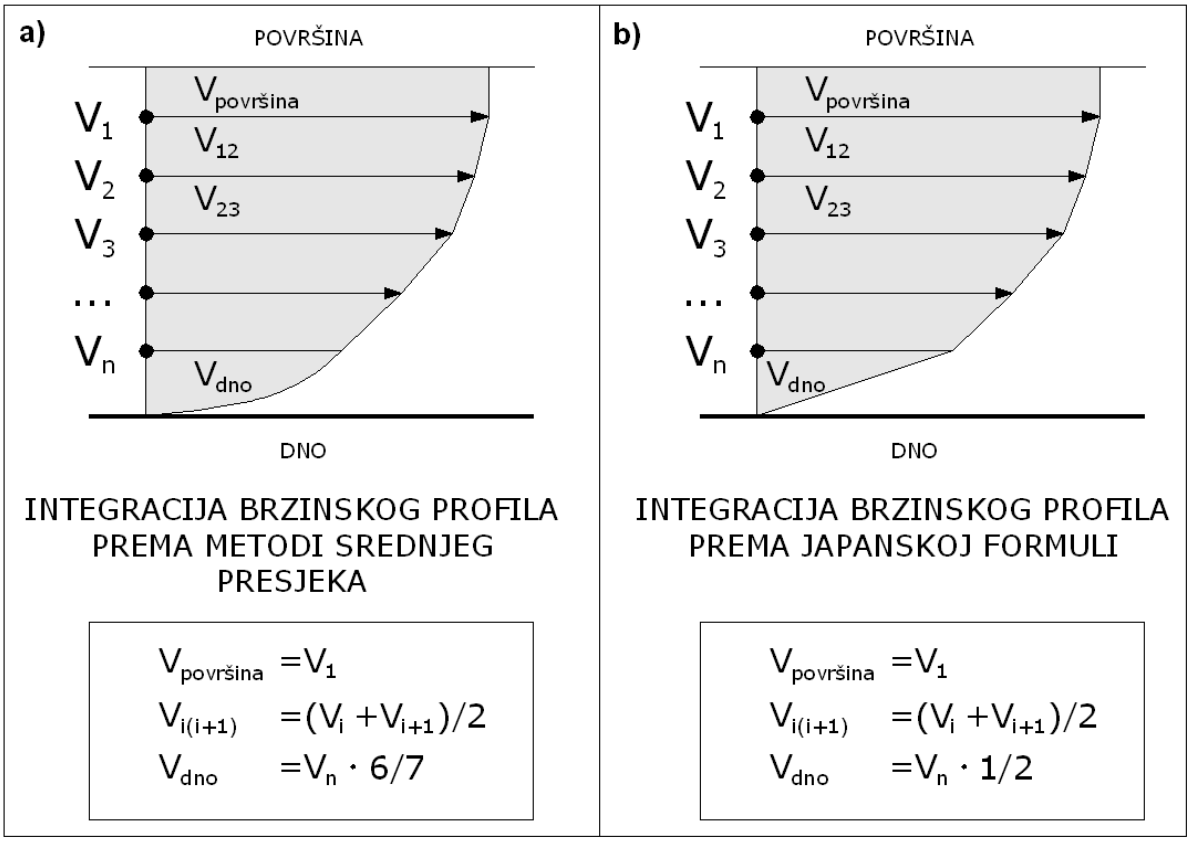


Slika 3.15 Varijacije brzine (v) kroz vrijeme (t), gdje su ($\bar{v}$) srednja brzina u točki, a (e) stohastička komponenta

Preporučeni intervali osrednjavanja brzine [B17] za velike brzine iznosi t = 30 s do 50 s, a za niske brzine t = 60 s do 100 s.

Srednja brzina na cjelokupnoj brzinskoj vertikali se dobiva integriranjem brzinskog profila. U stvarnosti brzinski profil ovisi o režimu toka, hrapavosti dna, površinskoj napetosti te utjecaju vjetra, no kao što je vidljivo iz slike 3.12 uz tri mjerne točke brzine na brzinskoj vertikali dobiva se značajna točnost kod određivanja srednje brzine.

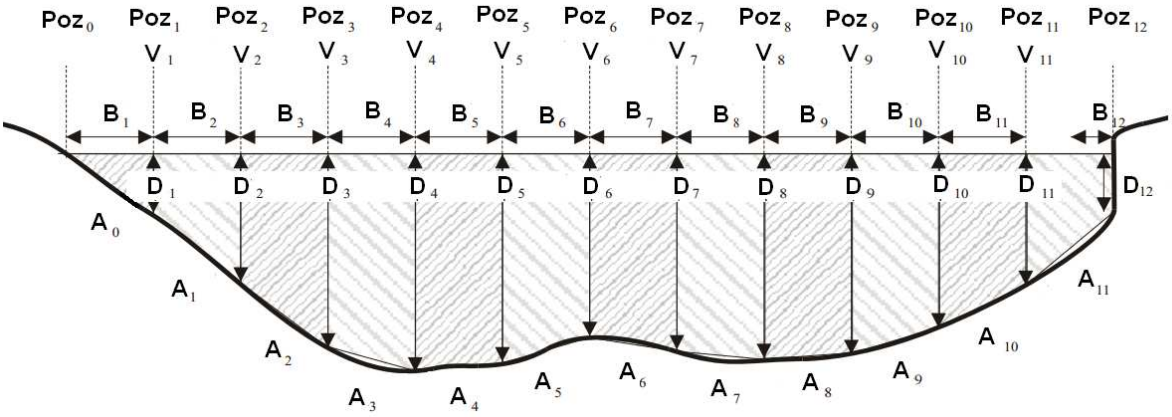
Jedna od najraširenijih metoda za određivanje protoka je metoda srednjeg presjeka, opisana ISO standardom 748 (1997) i ISO 9196 (1992). Druga metoda za određivanje protoka koja se nalazi u širokoj primjeni u svijetu je takozvana japanska formula. Prema tim metodama, a sukladno slici 3.16 definirana je integracija brzinskog profila [S5].



Slika 3.16 Integracija brzinskog profila za n mjernih točaka a) prema metodi srednjeg presjeka i b) japanskoj formuli.

Prema metodi srednjeg presjeka, sve točke u kojima je definirana brzina, spajaju se pravcima osim zadnjeg segmenta. Vidljivo je kako su metodološke razlike male, a odnose se na segment između dna korita i najbliže mjerne točke dnu.

Integracija po poprečnom presjeku se vrši uz pomoć dobivenih srednjih brzina za svaku brzinsku vertikalu za obje metode. Metoda srednjeg presjeka je opisana na slici 3.17.



Proračun protoka na rubovima profila

Početni rub, lijeva obala:

$Q_0 = B_0 = A_0 = 0,0$

Završni rub, desna obala:

i = brzinska vertikala (Poz_i , D_i)

$B_i = Poz_i - Poz_{i-1}$

$A_i = B_i \cdot (D_i + D_{i-1}) / 2$

Rubni korekcijski faktor = CF_i

$V_i = CF_i \cdot V_{i-1}$

$\bar{V}_i = (V_i + V_{i-1})/2$

$Q_i = A_i \cdot V_i$

Proračun protoka po sredini profila

$B_i = Poz_i - Poz_{i-1}$

$A_i = B_i \cdot (D_i + D_{i-1}) / 2$

$\bar{V}_i = (V_i + V_{i-1})/2$

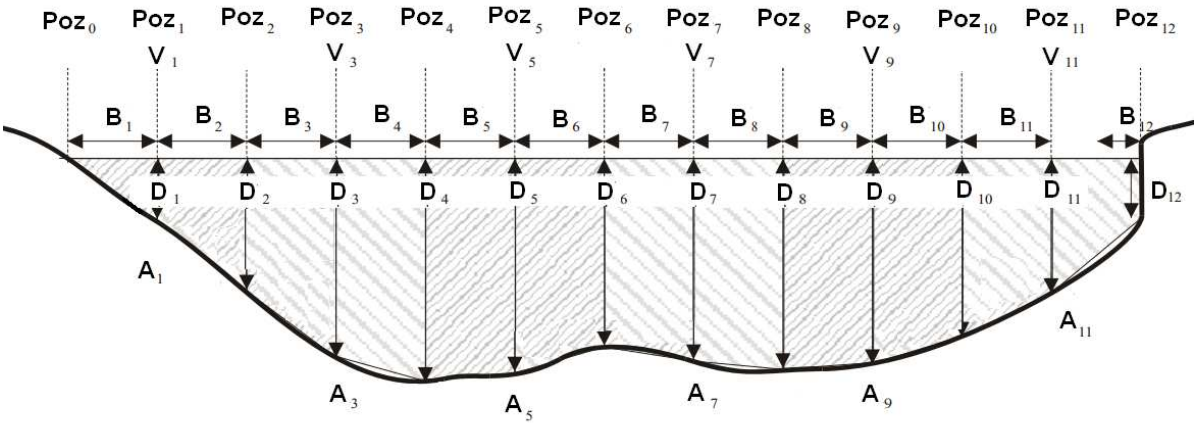
$Q_i = A_i \cdot \bar{V}_i$

$Q = \Sigma Q_i$

Slika 3.17 Integracija brzina na poprečnom presjeku vodotoka prema metodi srednjeg presjeka.

Metoda srednjeg presjeka nudi popravljene vrijednosti određenih parcijalnih protoka na rubovima presjeka uslijed korištenja rubnog korekcijskog faktora (CF) koji je bezdimenzionalan i kreće se od 0,80 do 1,00. U slučaju da se na promatranom presjeku pojavljuje otok, to jest da se vodotok dijeli na dva dijela, korekcijski koeficijent se koristi na početku otoka identično kao na završnom rubu presjeka (desna obala) te analogno na završetku otoka parcijalni protok se određuje kao na početnom rubu (lijeva obala). Ova formula ima široku primjenu i mnogi nacionalni hidrološki servisi je koriste kao standard. Uređaji koji vrše automatski integraciju brzina na poprečnom presjeku, u ovisnosti o korisnikovim željama mogu birati između više metoda, a metoda srednjeg presjeka je svakako jedna od najrasprostranjenijih.

Japanska formula za određivanja protoka je modifikacija metode srednjeg presjeka te uz pojednostavljeni pristup nudi dodatnu mogućnost proračuna protoka na promatranom presjeku. Slika 3.18 daje prikaz postupka proračuna protoka prema Japanskoj formuli.



$$B_i = Poz_{i+1} - Poz_{i-1}$$
$$A_i = (Poz_i - Poz_{i-1}) \cdot (D_i + D_{i-1}) / 2) + (Poz_{i+1} - Poz_i) \cdot (D_{i+1} + D_i) / 2)$$
$$Q_i = A_i \cdot V_i$$
$$Q = \Sigma Q_i$$

Slika 3.18 Integracija brzina na poprečnom presjeku vodotoka prema Japanskoj formuli.

Mjerenje protoka na vodotocima je karakterizirano odabirom metoda i instrumenata. Ipak osnovni zahtjevi zadatka su uglavnom ograničeni prvenstveno s traženom točnošću dostupnom opremom i instrumentarijem, iskustvom i sposobnošću mjeritelja, dostupnošću terena, dubinom i širinom vodotoka, rasponima brzina vodotoka te učestalošću mjerenja. Uzimajući ove čimbenike u obzir, na korisniku je da odabere najprihvatljiviju metodu i uređaje kako bi mjerenje bilo što učinkovitije.

3.3 METODE ANALIZE PODATAKA I MODELIRANJE

Na osnovu prikupljenih podataka izvršene su analize poradi boljeg uvida u prirodne procese i njihove zakonitosti te su uspostavljeni matematički modeli koji su pojednostavnivši kompleksne pojave u prirodi pomogli u boljem razumijevanju istih. U ovom poglavlju će se pobliže objasniti metode modeliranja te karakteristike odabranih modela.

3.3.1 Višestruki linearni regresijski modeli

Kako bi se dobio bolji uvid u kompleksni hidrodinamički sustav unutar duboke krške jame, uspoređena je pouzdanost višestrukih linearnih regresijskih modela s oscilacijama vanjskih meteoroloških parametara. Višestruki linearni regresijski modeli predstavljaju izvrstan alat kod simuliranja kompleksnih sustava na osnovu promatranih parametara što pokreću cjelokupno funkcioniranje sustava. [W3].

Opći oblik višestruke regresije je dat u sljedećem izrazu:

$$y = f(x_1, x_2, ...x_i, ...x_K) + \varepsilon \tag{3.11}$$

U navedenom modelu y je zavisna varijabla. To je pojava čije se varijacije izražavaju pomoću nezavisnih varijabli $x_1, x_2, ...x_K$. Varijabla ε izražava nepoznata odstupanja od funkcionalnog odnosa. Pretpostavi li se da je veza između y i ($x_1, x_2, ...x_K$) linearna, model (3.11) postaje višestruki linearni regresijski model:

$$y = a_0 + a_1 x_1 + a_2 x_2 + ... + a_j x_j + ... + a_K x_K + \varepsilon \tag{3.12}$$

U izrazu (3.12), y je zavisna ili regresand varijabla, dok su $x_1, x_2, ...x_K$ nezavisne, regresorske ili eksplanatorne varijable, $a_0, a_1, a_2 ... a_K$ su nepoznati parametri, a ε je slučajna varijabla.

Pretpostavi li se da se linearna regresijska veza između varijable y i odabranog skupa regresorskih varijabli utvrđuje na osnovi uzorka veličine n (n opažanja ili mjerenja odabranih varijabli), tada se vektorska jednadžba (3.12) može napisati u vidu sustava od n jednadžbi sa n nepoznanica:

$$\begin{aligned}
y_1 &= a_0 + a_1 x_{11} + a_2 x_{12} + \ldots + a_j x_{1j} + \ldots + a_K x_{1K} + \varepsilon_1 \\
y_2 &= a_0 + a_1 x_{21} + a_2 x_{22} + \ldots + a_j x_{2j} + \ldots + a_K x_{2K} + \varepsilon_2 \\
&\vdots \\
y_i &= a_0 + a_1 x_{i1} + a_2 x_{i2} + \ldots + a_j x_{ij} + \ldots + a_K x_{iK} + \varepsilon_i \\
&\vdots \\
y_n &= a_0 + a_1 x_{n1} + a_2 x_{n2} + \ldots + a_j x_{nj} + \ldots + a_K x_{nK} + \varepsilon_n
\end{aligned} \tag{3.13}$$

Sustav jednadžbi (3.13) se može kraće napisati u matričnom obliku gdje sljedeći izraz definira višestruki linearni regresijski model:

$$Y = aX + \varepsilon \tag{3.14}$$

Gdje su matrice:

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{bmatrix} \qquad X = \begin{bmatrix} 1 & x_{11} & x_{12} \cdots x_{1j} \ldots x_{1K} \\ 1 & x_{21} & x_{22} \cdots x_{2j} \ldots x_{2K} \\ \vdots & \vdots & \vdots \quad \vdots \quad \vdots \\ 1 & x_{i1} & x_{i2} \cdots x_{ij} \ldots x_{iK} \\ \vdots & \vdots & \vdots \quad \vdots \quad \vdots \\ 1 & x_{n1} & x_{n2} \cdots x_{nj} \ldots x_{nK} \end{bmatrix} \qquad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{bmatrix} \qquad a = \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_i \\ \vdots \\ a_K \end{bmatrix} \tag{3.15}$$

U izrazu (3.15) Y je vektor opaženih vrijednosti zavisne varijable (response vector), X je matrica čiji prvi stupac sadrži jedinice, a ostali stupci su opažene vrijednosti nezavisnih varijabli $x_1, x_2, \ldots x_K$ koje se nazivaju konstruktivnom matricom (design matrix), a ona je dimenzije $n \times K + 1$ .Vektor nepoznatih parametara *a* je dimenzije *K+1* i naziva se još vektorom nagibâ i sjecišta (slope vector), a ε je vektor slučajnih varijabli ε_i (n- dimenzionalna slučajna varijabla) koji se naziva i vektorom pogreške (error vector).

Nadalje, potrebno je istaknuti da ε_i, za i=1, 2,..., n nisu observabilne i njihovim uključivanjem u model, model (3.12) postaje stohastički model. Premda se promatra samo uzorak veličine n, pretpostavlja se da jednadžba (3.12) vrijedi za sva moguća opažanja odabranih varijabli tako da se promotreni se uzorak može smatrati kao jedna realizacija svih mogućih uzoraka fiksne veličine iz iste populacije.

Općenito za svako opažanje ($x_{i1}, x_{i2}, ...x_{iK}$) postoji distribucija vjerojatnosti varijable ε_i, dakle, prema tome postoji i distribucija vjerojatnosti zavisne varijable y_i.

Polazne pretpostavke u analizi modela višestruke linearne regresije su:

- Veza između zavisne varijable i odabranog skupa nezavisnih varijabli je linearna.
- Greške relacije su međusobno nezavisne, identično normalno distribuirane slučajne varijable s očekivanom vrijednosti nula i varijancom σ^2 :

$$\begin{aligned} &E(\varepsilon_i) = 0 \qquad Var(\varepsilon_i) = \sigma^2 \qquad \varepsilon_i \sim N(0, \sigma^2) \\ &Cov(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \varepsilon_j) = 0 \quad \text{i} \neq \text{j}, \text{i}, \text{j} = 1, \cdots, \text{n} \end{aligned} \tag{3.16}$$

- Nadalje, pretpostavlja se da su varijable x_i međusobno nezavisni vektori.

Kako bi se procijenio vektorski parametar a, koristi se pristup **M**etode **N**ajmanjih **K**vadrata, to jest MNK-procjena â. U tu svrhu potrebno je naći minimume sljedeće funkcije:

$$\sum_i \left(Y_i - a_0 - a1X_{i,1} - \ldots - a_K X_{i,K}\right)^2 \tag{3.17}$$

Ova funkcija ima minimum kada je:

$$a = \hat{a} = (X^T X)^{-1} X^T Y \tag{3.18}$$

MNK-procjena parametra „*a*“ se označava kao “$\hat{a}$ „ (a-hut), gdje su $(X^T X)^{-1}$ i $X^T X$ simetrične matrice dimenzija $K+1 \times K+1$.

Kada se procjenitelji uvrste imamo sljedeći izraz:

$$\hat{Y} = \hat{a}X = X(X^T X)^{-1} X^T Y \tag{3.19}$$

Reziduali se mogu odrediti prema:

$$\hat{r} = Y - \hat{Y} = \hat{a}X = \left(I - X(X^T X)^{-1} X^T\right)Y \tag{3.20}$$

Standardna devijacija greške je:

$$\hat{\sigma} = \sqrt{\sum_i r_i^2 / (n - K - 1)} \tag{3.21}$$

Varijanca od $\hat{a}_0, \hat{a}_1, \ldots, \hat{a}_K$ je sadržana u dijagonalnim elementima matrice standardne pogreške:

$$\hat{\sigma}(X^T X)^{-1} \tag{3.22}$$

Dakle, $\hat{a}_i$ je vrijednost od ai prema MNK-procjenitelju ili $\hat{a}_i$ je vrijednost slučajne varijable koja se rasipa po normalnoj razdiobi oko a_i uz varijancu σ_i^2 gdje je:

$$\hat{\sigma}_i^2 = \hat{\sigma}^2 \alpha_{ii} \quad i = 1,2,\ldots,n \tag{3.23}$$

Gdje su α_{ii} dijagonalni elementi matrice standardne pogreške.

Intervali povjerenja za uobičajenu pouzdanost β = 0,95 se određuje prema Studentovoj distribuciji t(K-n), dakle za (K-n) stupnjeva slobode i korespondirajućoj vjerojatnosti (p=1- β) određuje se vrijednost inverzne kumulativne studentove distribucije t_β. Kod velikog broja mjerenja (stupnjeva slobode) većeg od 120, t_β iznosi 1,96 za β = 0,95.

Interval povjerenja pouzdanosti β za regresijski parametar ai može se izraziti formulom:

$$[\hat{a}_i - t_\beta \hat{\sigma}_i , \hat{a}_i + t_\beta \hat{\sigma}_i] \quad i = 1,2,\ldots,n \tag{3.24}$$

Višestruki linearni regresijski model kao i analiza njegove nepouzdanosti nudi dodatne odgovore o analiziranim sustavima u prirodi. Njegova primjena uz mogućnosti programerskih rješenja nude brzi uvid u ovisnost ključnih parametara sustava o vanjskim utjecajima.

3.3.2 Neuralne mreže

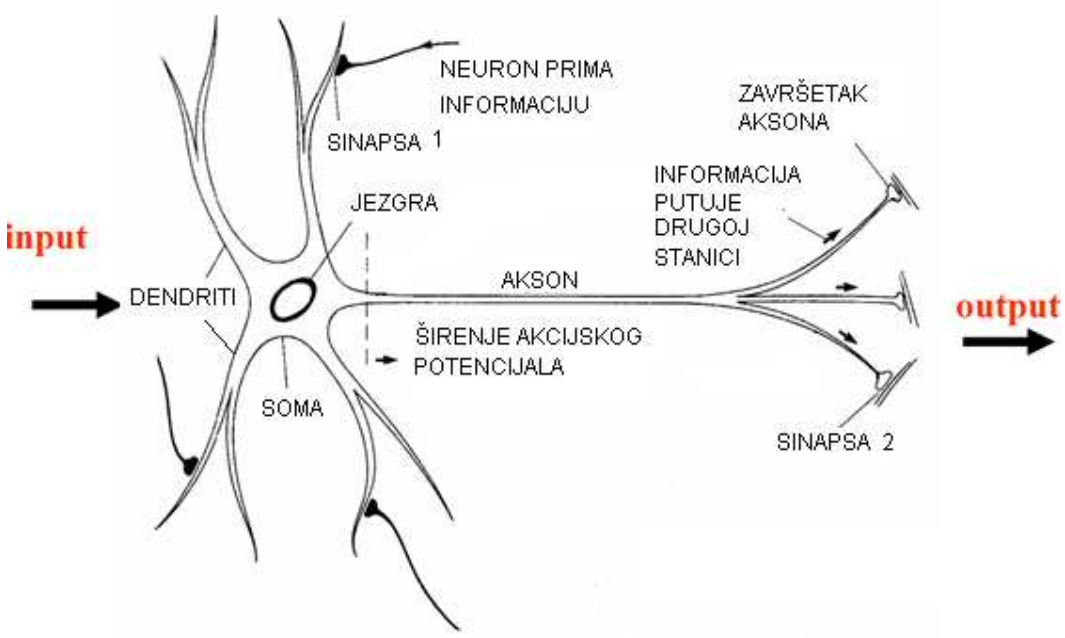
Neuralne mreže su snažan alat kod modeliranja hidroloških pojava jer pružaju alternativno rješenje iznimno teškog problema hidrologije, a to je određivanje odnosa između ovisnih i neovisnih varijabli koje predstavljaju hidrološke elemente [F1, F5, J1, L1].

Primjena umjetnih neuralnih mreža (Artificial Neural Networks ili ANN) je raširena u mnogim poljima prirodnih, tehničkih i humanističkih znanosti. Mogućnost dekompozicije kompleksnih sustava u jednostavnije elemente pruža uvid u njihove međusobne veze i u cjelokupno funkcioniranje promatranog sustava. Taj proces upravo omogućavaju neuralne mreže. Postoje mnogi tipovi neuralnih mreža, ali sve su karakterizirane sa svojim konstruktivnim komponentama: uređenim sustavom čvorova i definiranim vezama između istih.

Čvorovi mogu biti promatrani kao računalne jedinice neuralne mreže. Oni imaju svoj ulaz informacija, zatim ih obrađuju te prosljeđuju drugom čvoru ili izlazu. Ovaj proces može biti jako jednostavan (zbrajanje ulaza) ili kompleksan (promatrani čvor može sadržavati u sebi cjelokupnu drugu mrežu).

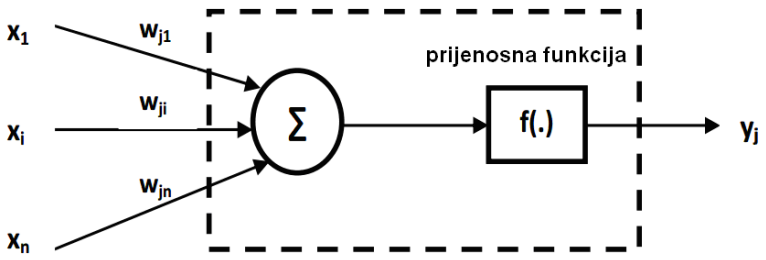
Veze između čvorova određuju tok informacija unutar mreže. Veze mogu biti jednosmjerne ili dvosmjerne. Interakcija čvorova preko definiranih veza određuje globalno ponašanje umjetne neuralne mreže koje se ne može opaziti pri promatranju zasebnih elemenata. To znači da mogućnosti mreže uvelike nadmašuju mogućnosti svojih vlastiti elemenata što umjetne neuralne mreže svrstava u snažne alate.

Čvor umjetne neuralne mreže se promatra kao umjetni neuron. Umjetni neuron je računalni model inspiriran prirodnim neuronom ilustriranim slikom 3.19.



Slika 3.19 Ilustracijski prikaz stvarnog neurona.

Prirodni neuron prima signal preko sinapsi lociranim na dendritima neurona. Kad signal postaje dovoljno snažan (prelazi određeni prag), neuron se aktivira i širi informaciju kroz akson.Taj signal se tada šalje drugoj sinapsi i može aktivirati drugi neuron. Ipak, neuron ili čvor umjetne neuralne mreže predstavlja krajnju simplifikaciju prirodnog procesa. Model umjetnog neurona prikazan na slici 3.20, definiran je ulazima (sinapse) koji se množe težinskim faktorima (snaga promatranog ulaza) te se uvrštavaju u aktivacijsku funkciju čvora koja određuje aktiviranje neurona. Drugom funkcijom (prijenosnom funkcijom) se određuje izlaz neurona. Dakle, umjetne neuralne mreže sadrže umjetne neurone kako bi obrađivali informacije, a ovisno o težinskim faktorima na vezama između neurona, izlaz može biti različit.Težinski faktori se mogu odrediti i prilagoditi tako da za određeni ulaz možemo dobiti željeni izlaz.

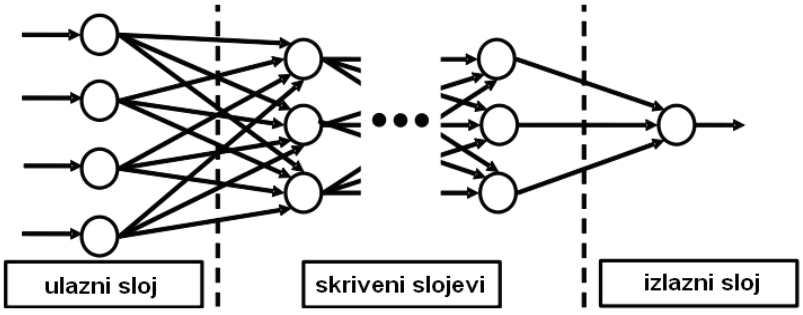


Slika 3.20 Prikaz umjetnog neurona.

Kod umjetnih neuralnih mreža koje sadržavaju na stotine i milijune čvorova taj proces zahtjeva računalne algoritme kako bi se težinski faktori odredili na taj način da izlaz neuralne mreže bude onaj željeni. Taj proces prilagođavanja težinskih faktora se zove učenje ili treniranje mreže.

Postoji veliki broj tipova umjetnih neuralnih mreža rasprostranjenih u upotrebi. Prvi model je razvijen 1943. godine [L1], a do danas je razvijeno na stotine različitih modela koji se smatraju tipovima umjetnih neuralnih mreža. Razlike između različitih tipova mogu ležati u algoritmima za treniranje, aktivacijskim funkcijama, topologiji i drugim karakteristikama. Ukratko, svi modeli se dijele na osnovne dvije kategorije, a to su feed-forward i feedback mreže.Najrasprostranjenija familija feed-forward mreža je uslojena (layered) neuralna mreža u kojoj su neuroni organizirani u slojeve (layers) s vezama strogo usmjerenim s jednog sloja prema drugom.

Najčešći tip feed-forward mreže je Multi Layer Perceptor ili MLP (višeslojni perceptor) koja ima tri vrste slojeva kao što je prikazano na slici 3.21, a to su: ulazni sloj (input layer), izlazni sloj (output layer) te skriveni slojevi (hidden layers).



Slika 3.21 Prikaz MLP neuralne mreže (topološka struktura).

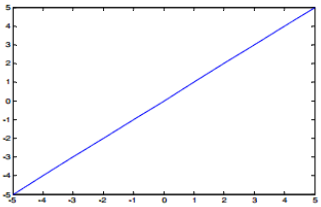
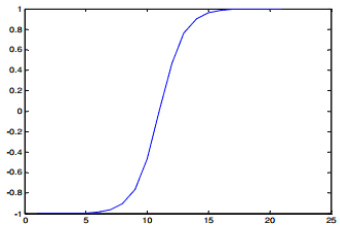
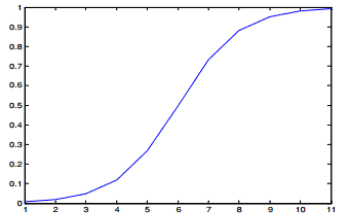
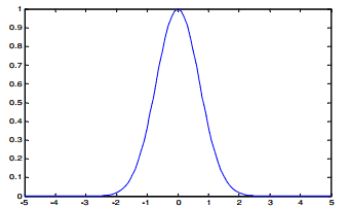
Neuroni u ulaznom sloju služe kao pufer zona za distribuiranje ulaznog signala x_i (i= 1,2...n) prema neuronima skrivenog sloja.

Svaki neuron j u skrivenom sloju zbraja ulaz signala x_i nakon što se snaga ulaza definira težinskim faktorom w_{ji} određenog za svaku vezu te se proračunava signal kao funkcija f zbroja svih ulaza prema sljedećem izrazu:

$$y_j = f\left(\sum_{i=1}^{n} w_{ji} \cdot x_i\right) \tag{3.25}$$

Funkcija f se zove još prijenosna ili transfer funkcija. U tablici 3.6 prikazane su uobičajene prijenosne funkcije koje se koriste MLP mrežama kao i u drugim tipovima umjetnih neuralnih mreža.

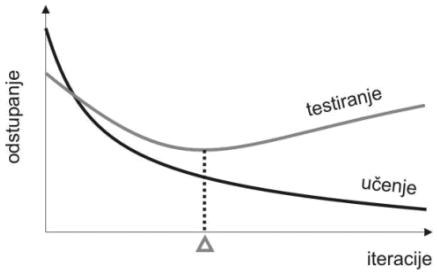
Tablica 3.6 *Pregled prijenosnih funkcija kod MLP neuralna mreža*

ime funkcije	grafička ilustracija	matematički izraz
linearna funkcija		$f(x) = x$
hiperbolni tanges		$f(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}}$
sigmoidalna funkcija		$f(x) = \frac{1}{1 + e^{-x}}$
Gauss RBF (Radial Basis Function)		$\varphi_j(x) = \exp\left(-\frac{1}{2\sigma_j^2}\left\|x - x_j\right\|^2\right)$

Najčešći oblik prijenosne funkcije jest sigmoidalna funkcija [F1]. Ova je funkcija derivabilna što je, kako će se pokazati, bitna prednost pri postupku učenja umjetne neuronske mreže. Sigmoidalna funkcija ponekad se naziva i logističkom funkcijom.

U slučaju kada se koriste složenije prijenosne funkcije, poput sigmoidalne, ili dopušta rad s realnim brojevima, uobičajeno se definira arhitektura mreže i prije postupka obrade podatka obavi postupak učenja ili treniranja. Za razliku od konvencionalnih tehnika obrade podataka gdje je postupak obrade potrebno analitički razložiti na određeni broj algoritamskih koraka, kod ovog tipa neuronskih mreža takav algoritam ne postoji. Znanje o obradi podataka, tj. znanje o izlazu kao funkciji ulaza, pohranjeno je implicitno u težinama veza između neurona. Težinski faktori se postupno prilagođavaju kroz postupak učenja neuronske mreže sve do trenutka kada je izlaz iz mreže, provjeren na skupu podataka za testiranje, zadovoljavajući. Pod postupkom učenja kod neuronskih mreža podrazumijevamo iterativan postupak predočavanja ulaznih primjera (uzoraka, iskustva) i eventualno očekivana izlaza.

Uz pojam učenja umjetne neuronske mreže vezani su pojmovi iteracije epohe. Pod iteracijom podrazumijevamo korak u algoritmu postupka za učenje u kojem se odvija podešavanje težinskih faktora, dok je epoha jedno predstavljanje cjelokupnog skupa za učenje. Skup primjera za učenje često se dijeli na tri odvojena skupa: skup za učenje, skup za testiranje i skup za provjeru (validaciju). Primjeri iz prvog skupa služe za učenje u užem smislu (podešavanje težinskih faktora). Pomoću primjera iz drugog skupa vrši se tijekom učenja provjera rada mreže s trenutnim težinskim faktorima kako bi se postupak učenja zaustavio u trenutku degradacije performanse mreže. Umjetnu neuronsku mrežu moguće je pretrenirati, to jest nakon određenog broja iteracija mreža gubi svojstvo generalizacije i postaje specijalizirana za obradu podatka iz skupa primjera za učenje dok preostale podatke obrađuje loše. Stalnim praćenjem izlaza iz mreže dobivenog pomoću primjera iz skupa za testiranje moguće je otkriti iteraciju u kojoj dobiveni izlaz najmanje odstupa od željenog kao što je to prikazano na slici 3.22. Točnost i preciznost obrade podataka moguće je naposljetku provjeriti nad trećim skupom primjera – skupom za provjeru.



Slika 3.22 Grafički prikaz odstupanja stvarnih izlaza kroz iteracije.

MLP ili višeslojna neuronska mreža sa sigmoidalnom funkcijom kao prijenosnom funkcijom procesnih elemenata je u stanju predstaviti nelinearne odnose ulaznih i izlaznih podataka. Učinkovita i popularna metoda učenja višeslojnih mreža jest algoritam sa širenjem pogreške unazad ili – BACKPROPAGATION algoritam (BP algoritam). BP algoritam je predstavljen 1985. godine [F1]. Algoritam koristi metodu gradijentnog spusta kako bi minimizirao nastalu pogrešku. Učenje višeslojne mreže pomoću BP algoritma svodi se na pretraživanje u n-dimenzionalnom prostoru hipoteza, gdje je n ukupan broj težinskih faktora u mreži. BP algoritam daje promjenu težinskog faktora Δw_{ji} na vezi između neurona *i* i *j* prema sljedećem izrazu:

$$\Delta w_{ji} = \eta \, \delta_j \, x_i \tag{3.26}$$

Gdje je η parametar koji se naziva brzinom učenja a δ_j je faktor koji ovisi o tome, da li je neuron *j* iz ulaznog sloja ili skrivenog sloja. Za neurone iz izlaznog sloja izraz glasi:

$$\delta_j = \left(\partial f / \partial net_j\right)\left(y_j^{(t)} - y_j\right) \tag{3.27}$$

Izraz za neurone skrivenog sloja glasi:

$$\delta_j = \left(\partial f / \partial net_j\right)\left(\sum_q w_{jq}\delta_q\right) \tag{3.28}$$

U izrazu (3.27), net_j je zbroj svih ulaznih signala pomnoženih s određenim težinama koji ulaze u neuron j, a $y_j^{(t)}$ je ciljani izlaz neurona *j*. Kako nema ciljanih izlaza za neurone u skrivenom sloju, u izrazu (3.28) stvarni izlaz skrivenih neurona j je zamijenjen zbrojem svih δ_q dobivenih za neuron *q* koji je povezan na izlaz neurona *j* te pomnožen s pripadajućim težinama. Cjelokupan proces treniranja počinje od izlaznog sloja. Izraz (3.27) se računa za svaki neuron unutar sloja te se težine aktualiziraju iteracijski. Epoha u procesu učenja je kompletirana kada se proračunaju sve nove aktualizacije težina.

Kod hidroloških proračuna je uobičajeno postavljanje matematičkih modela ili kreiranje grafičkih relacija na osnovu prikupljenih podataka. Dakle, hidrološki proračun sadrži prepoznavanje uzorka što je također jedan od ciljeva primjene umjetnih neuralnih mreža. Kako ne postoji zadovoljavajući matematički model oblika y = f(x) koji će zadovoljiti kompleksnost hidroloških elemenata, umjetne neuralne mreže pružaju moćan alat u hidrologiji zbog svojih karakteristika vezanih za autoučenje, autoorganiziranje i autoadaptaciju. Drugi tip neuralne mreže koja se često u hidrologiji upotrebljava zasniva se na nelinearnom autoregresivnom modelu s egzogenim ulazom (Nonlinear AutoRegressive models with eXogenous Inputs –NARX) [S3]. NARX neuralne mreže imaju formulaciju oblika y(t) = f(x(t), x(t-1),…x(t-d), y(t), y(t-1),…y(t-d))

gdje x(t) i y(t) predstavljaju vremenske serije ulaza i izlaza, f predstavlja mapiranje uspostavljeno višeslojnim perceptorom (MLP), a d zakašnjenje vremenskog koraka (delay).

3.3.3 Probabilistički pristup određivanja protoka

Kod hidrometrijskih metoda mjerenja, postoji više metoda koje omogućuju proračun protoka na presjeku od interesa. Kao što je to prikazano u izrazu (3.10), umnožak srednje brzine na presjeku s površinom presjeka daje protok. Ako se pri tom promatraju umnošci vektora brzina s pripadajućim diferencijalnim dijelovima površine presjeka, izraz (3.10) prelazi u sljedeći oblik:

$$Q = \int_A v dA = \bar{v} \cdot A \tag{3.29}$$

Izrazi (3.10) i (3.29) definiraju najrasprostranjeniju metodu određivanja protoka, a to je pristup umnoška površine i brzine. Probabilistički pristup kod formulacije problema protoka fluida temelji se na pretpostavci da postoji funkcija gustoće vjerojatnosti $f(v)$ koja daje vjerojatnost pojave bilo koje brzine unutar presjeka. Imajući u vidu osnovni koncept probabilističkog pristupa proračuna protoka, srednja brzina na presjeku može biti definirana prema slijedećem izrazu.

$$\bar{v} = \int_0^{v_{\max}} v \cdot f(v) dv \tag{3.30}$$

Po prvi puta se probabilistički pristup kod određivanja protoka u literaturi koristi 1989. Chiu [C3, C4] je predložio svoju metodu koristeći se dvodimenzionalnom funkcijom vjerojatnosti raspodijele brzina. Služeći se formulacijama vjerojatnosti dao je izraz za srednju brzinu i maksimalnu brzinu u riječnom profilu u obliku linearne veze preko bezdimenzionalnog parametra entropije. Po prvi puta objedinjujući koncept probabilističkog pristupa i koncept maksimalne informacijske entropije , analitički je derivirana raspodjela brzina za tok fluida u prostoru vjerojatnosti:

$$v = \frac{v_{\max}}{M} \ln\left[1 + (e^M - 1) F(v)\right] \tag{3.31}$$

gdje je M parametar, $v_{\max}$ je maksimalna brzina na presjeku od interesa a $F(v)$ je kumulativna funkcija raspodjele vjerojatnosti ili vjerojatnost brzine da bude manja ili jednaka brzini v gdje je $0 \le v \le v_{\max}$.

Kumulativna funkcija raspodjele brzina može se promatrati kao ekvivalent frakciji površine presjeka u kojem je brzina manja ili jednaka v, dakle funkciji prostornih koordinata. Takva funkcija predstavlja ogroman izazov, no kod vertikalne osi presjeka (y osi) na kojoj se v_{max} pojavljuje, $F(v)$ se može definirati kao:

$$F(v) = \frac{\xi}{\xi_{max}} \tag{3.32}$$

Gdje prikladan izraz za ξ je dan kao [C3]:

$$\xi = \frac{y}{D-h}\exp\left(1-\frac{y}{D-h}\right) \tag{3.33}$$

Gdje je ξ_{max} maksimalna vrijednost ξ pri kojoj se pojavljuje v_{max}. Ako se v_{max} pojavljuje na površini vodotoka, što je nužno za pretpostaviti kod mjerenja protoka uz pomoć radara, tada se ξ_{max} može proračunati izrazom (3.32) za vrijednost y = D. U slučaju da se maksimalna brzina pojavljuje ispod površine na udaljenosti h ili y = D – h iznad dna kanala, tada ξ_{max} iznosi 1 (ξ_{max} = 1). Izraz (3.31) s obzirom na kumulativnu funkcija raspodjele vjerojatnosti je ekvivalentan izrazu [C5, C6]:

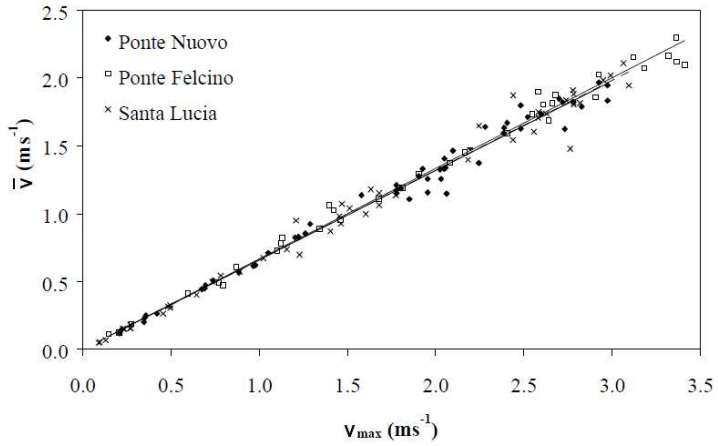
$$F(v) = \frac{1}{e^M - 1}\left[\exp\left(M\frac{v}{v_{max}}\right)-1\right] \tag{3.34}$$

Kako je funkcija gustoće vjerojatnosti brzine jednaka f(v) = dF(v)/dv, a funkcija gustoće od v/v_{max} je $f(v/v_{max}) = v_{max}\, f(v)$, izraz (3.35) je ekvivalentan izrazu:

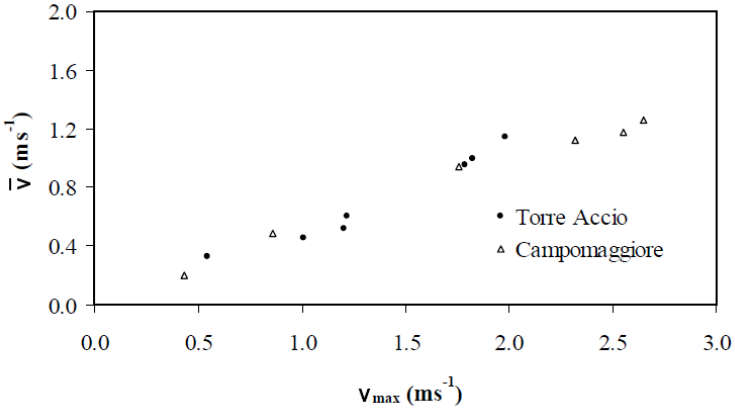
$$f(v/v_{max}) = \frac{M}{e^M - 1}\exp\left(M\frac{v}{v_{max}}\right) \tag{3.35}$$

Valja primijetiti kako u izrazu (3.35) jedini figurirajući parametar je M. Srednja vrijednost omjera v/v_{max} može se analitički dobiti iz izraza (3.31) i (3.34):

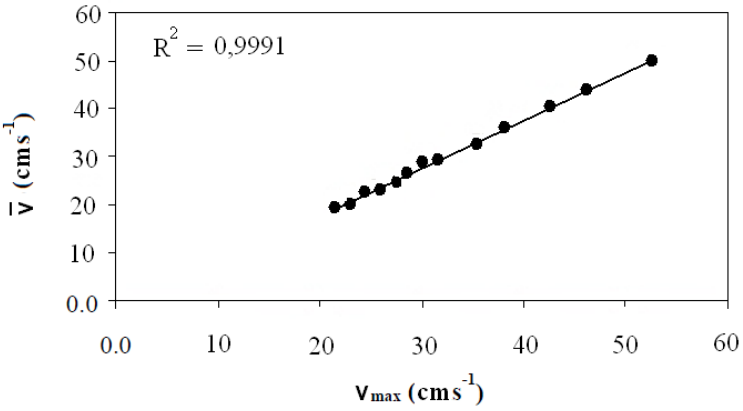
$$\frac{\bar{v}}{v_{max}} = \phi = \frac{e^M}{e^M - 1} - \frac{1}{M} \tag{3.36}$$



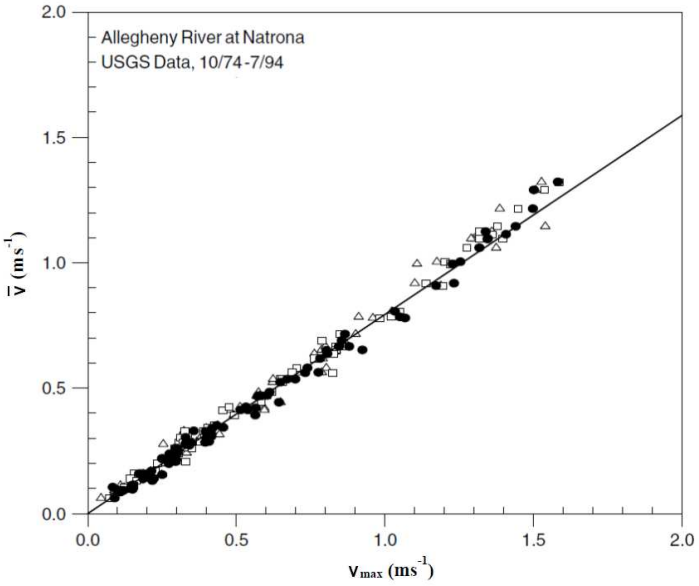
Slika 3.23 Prikazi odnosa v/v_{max} za tri promatrana profila duž rijeke Tiber $\Phi(M)=0.663$ (Moramarco et al., 2004).



Slika 3.24 Prikazi odnosa v/v_{max} za dva promatrana profila duz rijeke Basento u južnoj Italiji (Moramarco et al., 2004).



Slika 3.25 Prikazi odnosa v/v_{max} za laboratorijske uvjete na eksperimentalnom profilu (Nikmehr i Farhoudi, 2010) Central Laboratory of University of Tehran.



Slika 3.26 Prikazi odnosa v/v_{max} za profil Natrona na rijeci Allegheny u SAD-i, Φ(M)=0.81 (Chiu i Chen, 1999).

Uporaba distribucije vjerojatnosti u izrazu (3.31) kod raznih uvjeta tečenja snažno ovisi o stabilnosti $f(v/v_{max})$. Upravo ovaj uvjet generira motivaciju za promatranje omjera Φ između srednje i maksimalne brzine [F6]. U literaturi postoje mnoga istraživanja koja se bave upravo ovim odnosom.

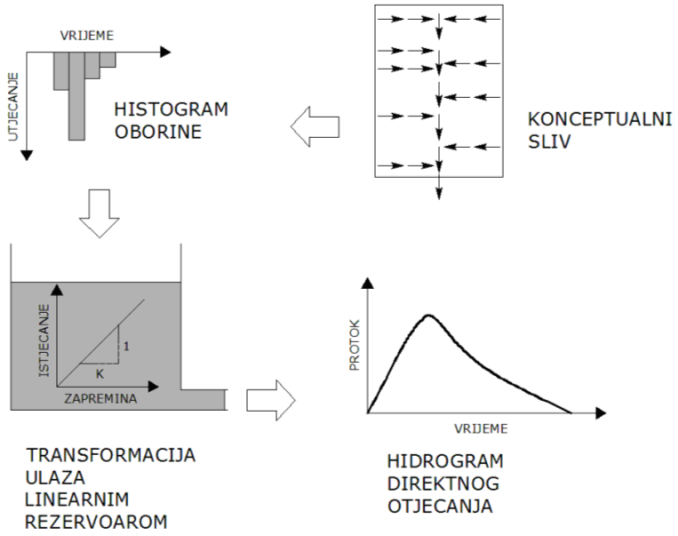
Slike 3.23, 3.24, 3.25, 3.26 sugeriraju kako problem određivanja protoka na profilu od interesa prema probabilističkom pristupu sadrži i zadatak analize povijesnih podataka na profilu, to jest zapisa srednje i maksimalne brzine za različita mjerenja pri različitim uvjetima tečenja [M5]. Znakovito je kako se u sva četiri slučaja postiže linearna veza između v i v_{max}.

Drugi dio zadatka kod određivanja protoka prema probabilističkom pristupu sastoji se od utvrđivanje maksimalne brzine unutar presjeka v_{max}. Tu dolazi do primjene radarske opreme, jer us pomoć nje se uz vrlo male napore može doći do površinskih brzina vodotoka. Iako se maksimalna brzina vodotoka ne nalazi na površini toka, ta pretpostavka omogućava uporabu radar kod mjerenja protoka.

3.3.4 Linearni i nelinearni rezervoar

Proces transformacije oborine u otjecanje je nelinearan i dinamičan, a ulazi i izlazi u sustav prostorno su distribuirani. Zbog složenosti opisanog procesa, koriste se konceptualni modeli kako

bi se u nedostatku informacija simulirao isti. Jedan od konceptualnih modela u širokoj primjeni je i model linearnog rezervoara [J4].



Slika 3.27 Konceptualni model linearnog rezervoara.

Konceptualni model linearnog rezervoara prikazan na slici 3.27 zasnovan je na pretpostavci da se vodonosnik aproksimativno ponaša kao rezervoar u kojem je zapremina S u linearnoj vezi sa otjecanjem kao što je prikazano izrazom:

$$S = K \cdot Q \tag{3.37}$$

gdje Q predstavlja protok koji izlazi iz rezervoara, a K predstavlja koeficijent zapremine vodonosnika ili konstantu koja označava vrijeme ispuštanja nekog vodonosnika s mjernom jedinicom vremena. Ova vrijednost je recipročna vrijednosti koeficijenta recesije α .

Promjena zapremine rezervoara u vremenu definirana je jednadžbom kontinuiteta:

$$\frac{dS}{dt} = R - Q \tag{3.38}$$

gdje je Q oznaka za protok koji se ispušta iz rezervoara, R predstavlja protok koji ulazi u rezervoar (Recharge), a član na lijevoj strani predstavlja promjenu zapremine vode u vodonosniku u vremenu.

Uvrštavanjem jednadžbe (3.37) u (3.38) slijedi:

$$K\frac{dQ}{dt} = R - Q \tag{3.38}$$

Pri tom se da zapaziti da je K obrnuto proporcionalna vrijednost koeficijenta recesije α:

$$\alpha = \frac{1}{K} \tag{3.38}$$

Uvrštavanjem (3.38) u (3.37) dobije se sljedeći izraz:

$$\frac{1}{\alpha}\frac{dQ}{dt} = R - Q \tag{3.39}$$

Iznalaženje analitičkog rješenja moguće je s obzirom da se radi o linearnoj diferencijalnoj jednadžbi prvog reda, a rješenje glasi:

$$Q(t) = e^{-\alpha t}\left(C + \alpha \cdot R\left(\frac{e^{\alpha t}}{\alpha} - \frac{1}{\alpha}\right)\right) = e^{-\alpha t}\left(C + R\left(e^{\alpha t} - 1\right)\right) \tag{3.40}$$

Sređivanjem prethodnog izraza dolazi se do općeg rješenja koje primjenom za svaki vremenski korak Δt, uz poznavanje početnog uvjeta, daje vrijednost hidrograma otjecanja iz rezervoara na kraju tog vremenskog koraka.

$$Q(t + \Delta t) = Q(t) \cdot e^{-\alpha \Delta t} + R(t + \Delta t)(1 - e^{-\alpha \Delta t}) \tag{3.41}$$

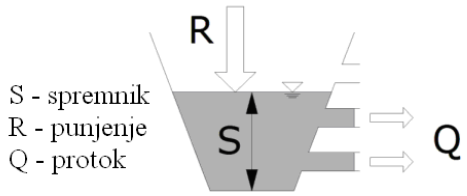
Kao što se može vidjeti iz općeg rješenja, potrebno je odrediti koeficijent recesije α kako bi se mogao simulirati hidrogram otjecanja. U literaturi su poznate mnoge metode koje određuju koeficijent recesije α [P7], no u ovom slučaju gdje je poznat hidrogram za jednu hidrološku godinu pruža se mogućnost interpoliranja linearnog regresijskog modela na recesijskom dijelu hidrograma eksponencijalnog oblika. Izraz odabranog oblika dobiva se metodom najmanjih kvadrata, a eksponent u jednadžbi predstavlja koeficijent recesije α.

Kalibracija modela, to jest podešavanje parametara na osnovi usporedbe simuliranog i zabilježenog hidrograma za promatrano razdoblje, vrši se preko koeficijenta efikasnosti modela (CE):

$$CE = 1 - \frac{\sum_{i=1}^{302} \left(Q_i - Q^{SIM}{}_i\right)^2}{\sum_{i=1}^{302} \left(Qi - Q_{AVG}\right)^2} \tag{3.42}$$

gdje su• Q_i oznaka za vrijednost mjerenog protoka, $Q^{SIM}{}_i$ oznaka za vrijednost simuliranog protoka, a Q_{AVG} oznaka za srednju vrijednost mjerenog protoka. Koeficijent *CE* može uzeti vrijednost od -∞ do 1. U slučaju da su simulirani i mjereni hidrogram identični, *CE* uzima vrijednost 1 te je riječ o idealnom modelu. Što je odstupanje veće od 1, sve je slabije podudaranje simuliranog i mjerenog hidrograma.

Za razliku od linearnog rezervoara koji pretpostavlja linearnu zakonitost između zapremine rezervoara i istjecanja, nelinearni rezervoar pretpostavlja nelinearni odnos istjecanja proporcionalno prema zapremini vodonosnika [S4, W5] kao što je to prikazano na slici 3.28.



Slika 3.28 Konceptualni model nelinearnog rezervoara gdje su : S – zapremina rezervoara, R – protok koji ulazi u rezervoar (Recharge) i Q – protok koji izlazi iz rezervoara

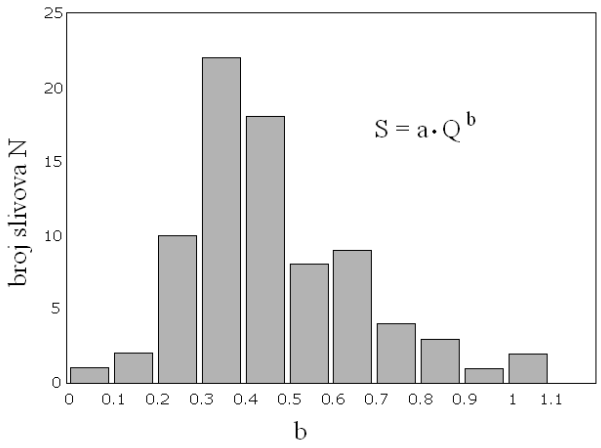
Mailletova [M2] eksponencijalna funkcija ($Q_t = Q_0 \cdot EXP(-t/K)$) u širokoj je primjeni kod opisivanja recesije baznog otjecanja, gdje su Q_t oznaka za protok u vremenu t, Q_0 oznaka za inicijalni protok i K oznaka za konstantu retencije. Ova eksponencijalna funkcija implicira da vodonosnik reagira kao jedinstveni linearni rezervoar s linearnim odnosom S = KQ kao na slici 3.25. Kako bi se uvela nelinearnost u odnos između zapremine i istjecanja, ovaj izraz je modificiran uvođenjem eksponenta b:

$$S = aQ^b \tag{3.43}$$

Ako se volumeni u gornjoj jednadžbi izraze kao visine iznad jedinične površine uz vremenski korak (dan), u tom su slučaju dimenzije članova jednadžbe: *S* (mm), *Q* (mm/d) i *a* ($mm^{1-b}db$). Eksponent b je bezdimenzionalan. Prema tome, model linearnog rezervoara je slučaj kada je *b* = 1. Spajanjem jednadžbe (3.43) i jednadžbe (3.38) dobije se jednadžba recesijske krivulje za nelinearni rezervoar počevši od trenutka Q_0:

$$Q_t = Q_0\left[1 + \frac{(1-b)Q_0^{1-b}}{ab}t\right]^{1/(b-1)} \tag{3.44}$$

Eksponent b u jednadžbi (3.44) određen je empirijski i njegova je distribucija u odnosu na broj promatranih slivova prikazana na slici 3.29 [W5].



Slika 3.29 Distribucija vrijednosti eksponenta b kod nelinearnog rezervoara (Wittenberg 1999).

Prikazan primjer predstavlja višegodišnja istraživanja na slivovima Njemačke od kojih je veliki broj i na krškim terenima. Srednja vrijednost eksponenta b je 0,5 uz standardnu devijaciju od 0,25. Navedenu vrijednost dokazalo je više autora koji su teoretskim pristupom potvrdili odnos zapremine i otjecanja koji odgovara izrazu $S = aQ^{0.5}$ ili $Q = cS^2$ za protok kod izvora [W5, F5]. Empirijski izraz parabole fizikalno je vezan za otjecanje iz otvorenog vodonosnika.

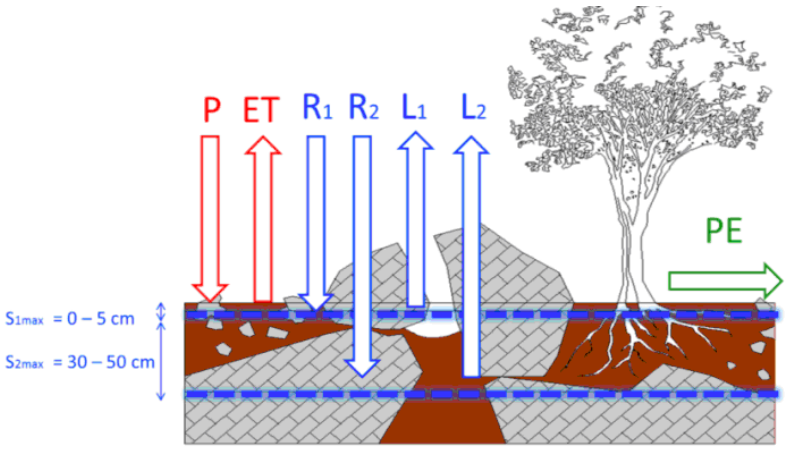
Kako bi se opisalo funkcioniranje slivova u prirodi, kombinacije vezanih linearnih i nelinearnih rezervoara u seriji ili paralelno, mogu ponuditi realistične simulacije glavnih vrijednosti od interesa.

3.3.5 Model vlage u tlu

U krškim je područjima jedan od najvećih izazova određivanje efektivne oborine. Zbog izrazite heterogenosti u mnogim slučajevima zakon održanja ne vrijedi. Bilanciranje voda temelji se na zakonu održanja pa i većina modela za određivanje efektivne oborine, kao i Palmerov postupak [P3], polazi od pretpostavke da je ulaz u sustav jednak izlazu. Bilanca vode postavlja se na granicu između zraka i tla, a tlo se dijeli na površinski S1 i podpovršinski sloj S2 koji zadržava vlagu dostupnu biljkama. Prema Palmeru, procjena dubine površinskog sloja je oko 20 cm, a

podpovršinskog oko 100 cm [P3]. Ipak, krški tereni u vadoznoj zoni epikrša imaju puno manje vode dostupne biljnom pokrovu [P4]. Kad se raspolaže s maksimalnim kapacitetima, iz njih se mogu uz izvjesne pretpostavke procijeniti sadržaji vode u tlu bez stvarnog mjerenja.

Promatrano krško područje ima izrazito heterogene karakteristike. S pedološkog aspekta u njemu prevladava vapnenac te se smjenjuju tla od potpuno nerazvijenih (kamenjari ili litosol), preko automorfnih tala nastalih na vapnencu, do aluvijalnog tla u krškim poljima. Uvidom u pedološke karte tog područja (Osnovna pedološka karta Hrvatske) [P6], mogu se uočiti prevladavajući tipovi. Tako se prema gruboj procjeni može zaključiti kako prevladavaju dvije vrste tla: crvenica i smeđe tlo na vapnencu. Maksimalni kapacitet vode u rasponu je od 35% do 45% od ukupnog volumena, dakle od 350 do 450 mm vode po metru dubine. Međutim, javlja se problem homogenosti dubine i kamenitosti tla koje znatno smanjuju kapacitet. Kako se Palmerova metoda koristi u hidrološkom modeliranju krških područja [J4], preporuka je da se za vrijednosti površinskog i podpovršinskog sloja S1 i S2 uzimaju znatno manje vrijednosti od onih prema Palmeru. U ovom radu uzeti su maksimalni kapaciteti vlage u tlu od 0 do 5 mm u površinskom i od 100 do 200 mm u podpovršinskom sloju.



Slika 3.30 Bilanca voda na dodiru tlo –zrak prema Palmeru uz krškom terenu prilagođene S1 i S2 vrijednosti

Komponente u bilanci voda prema Palmeru, a prikazano na slici 3.30 su: evapotranspiracija ET, ukupne oborine P, efektivne oborine PE, punjenje vodonosnika R i gubici iz vodonosnika L. Sukladno zakonu održivosti i komponentama, jednadžba bilance prema Palmeru glasi:

$$P + L1 + L2 = ET + PE + R1 + R2 \tag{3.45}$$

Gdje su ET oznaka za evapotranspiraciju, L1 oznaka za gubitak iz površinskog sloja, L2 oznaka za gubitak iz podpovršinskog sloja, P oznaka za oborinu, PE oznaka za efektivnu oborinu ili količinu koja otječe sa slivnog područja, R1 oznaka za procjeđivanje u površinski sloj, a R2 oznaka za procjeđivanje u podpovršinski sloj.

Određivanje evapotranspiracije ovisi o potencijalnoj evapotranspiraciji PET i sadržaju vlage u tlu. Kako bi se dobila potencijalna evaporacija, koristi se formula prema Eagelmanu [E1] koja glasi:

$$PET = C \cdot 6.1 \cdot e^{\left(\frac{17.1 \cdot t}{234.2+t}\right)} \cdot \left(100 - RELH\right)^{0.5} \tag{3.46}$$

Ako je vremenski korak jedan mjesec u izrazu (3.46) oznake imaju slijedeće značenje::

- RELH - relativna vlažnost zraka
- C - konstanta ovisna o srednjoj temperaturi zraka izraženoj u °C

  C = 0,6 ako je t < 0°C

  C = 1,13 ako je t > 21°C C = 0,63 + 0,024t ako je 0°C ≤t ≤21°C

U slučaju da je vremenski korak u modelu sveden na trajanje od jednog dana, izraz (3.46) poprima nove komponente:

$$PET = \varphi \cdot C \cdot C_w \cdot 6.1 \cdot e^{\left(\frac{17.1 \cdot t}{234.2+t}\right)} \cdot \left(100 - RELH\right)^{0.5} \tag{3.47}$$

Nove komponente u izrazu (3.47) za potencijalnu evapotranspiraciju koje osiguravaju traženu vremensku skalu su koeficijenti φ = 0,0329 (skaliranje na vremenski korak od jednog dana) i C_w = 0,8 (konstanta ovisna o brzini vjetra).

Gubitak vode s površine tla odvija se procesom evapotranspiracije, evaporacije vode s vodnih površina i transpiracije vlage kroz biljke. Prema Palmeru gubitak vode iz površinskog dijela izravno ovisi o oborinama P i o potencijalnoj evapotranspiraciji PET.

Prema tome, gubici u površinskom sloju mogu se odrediti na sljedeći način:

$$L1 = PET \ \ ako\ vrijedi\ \ PET - P \wedge P < S1 \tag{3.48}$$

$$L1 = S1\ ako\ vrijedi\ \ PET - P > 0 \wedge PET - P > S1 \tag{3.49}$$

$$L1 = 0 \; ako \; vrijedi \; PET - P < 0 \vee S = 0 \tag{3.50}$$

Gdje je S1 oznaka za zapreminu vode u površinskom sloju (sukladno efektivnoj poroznosti i koeficijentu zasićenosti).

Gubici u podpovršinskom sloju L2 mogu se izračunati iz uvjeta:

$$L2 = 0 \; ako \; vrijedi \; 0 \geq L2 \tag{3.51}$$

$$L2 = S2 \; ako \; vrijedi \; L2 \geq S2 \tag{3.52}$$

$$L2 = (PET - P - L1) \cdot \frac{S2}{SMAX} \; ako \; vrijedi \; 0 < L2 < S2 \tag{3.53}$$

Gdje su S2 oznaka za zapreminu vode u podpovršinskom sloju (sukladno efektivnoj poroznosti i koeficijentu zasićenosti), a SMAX oznaka za maksimalni kapacitet površinskog i podpovršinskog sloja (SMAX= S1MAX + S2MAX).

Efektivna oborina PE i prihranjivanje R, procjeđivanjem do oba sloja, ovise o paloj oborini P, potencijalnoj evapotranspiraciji PET i zapremini vode S = S1 + S2 u tlu:

$$PE = 0 \wedge R = 0 \; ako \; vrijedi \; 0 > P - PET \tag{3.54}$$

$$PE = 0 \wedge R = P - PET \; ako \; vrijedi \; 0 < P - PET < SMAX - S \tag{3.55}$$

$$PE = P - PET - R \wedge R = SMAX - S \; ako \; vrijedi \; P - PET > SMAX - S \tag{3.56}$$

Gdje je S oznaka za ukupni kapacitet vode u površinskom i podpovršinskom sloju (S = S1 + S2).

Stvarna evapotranspiracija ovisi o iznosu pale oborine, potencijalnoj evapotranspiraciji te gubitku vode iz oba sloja L = L1 + L2.

$$ET = PET \; ako \; vrijedi \; 0 \leq P - PET \tag{3.57}$$

$$ET = P + L \; ako \; vrijedi \; 0 > P - PET \tag{3.58}$$

Početni uvjeti kod određivanja bilance prema Palmeru su sadržaj vode u tlu na početku promatranog razdoblja S1FST i S2FST. Promjena količine vode u tlu na kraju vremenskog koraka u odnosu na prethodni određuje se iz uvjeta:

$$DELTAS1 = 0 \wedge DELTAS2 = 0 \; ako \; vrijedi \; R = 0 \wedge L = 0 \tag{3.59}$$

$$DELTAS1 = -L1 \wedge DELTAS2 = -L2 \; ako \; vrijedi \; L > 0 \tag{3.60}$$

$$DELTAS1 = R \wedge DELTAS2 = 0 \; ako \; vrijedi \; R > 0 \wedge R < S1MAX \tag{3.61}$$

$$DELTAS1 = S1MAX - S1' \wedge DELTAS2 = R - DELTAS1 \; ako \; vrijedi \; R > S1MAX - S1' \tag{3.62}$$

Sadržaj vode na kraju vremenskog koraka i na početku idućeg određuje se na sljedeći način:

$$S1 = S1' + DELTAS1 \tag{3.63}$$

$$S2 = S2' + DELTAS2 \tag{3.64}$$

Opisani model vlage u tlu koji je nužno inkorporirati u sveobuhvatni model promatrane prirodne pojave kao što su to hidrološki režim jezera ili izvora. Njegovi parametri su također podložni kalibraciji modela, a vrše se preko analize koeficijenta efikasnosti (3.42). Uzimajući u obzir vlagu u tlu pri modeliranju, sustav daje realističnije vrijednosti te je u mogućnosti simulirati pojave uslijed suše ili ekstremnih oborina.

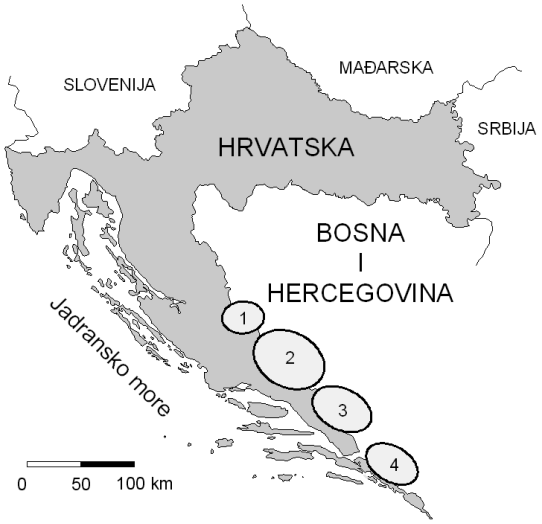
4. PODRUČJA ISTRAŽIVANJA

U ovom poglavlju pobliže su predstavljena područja istraživanja koja su bila od interesa pri izradi disertacije. Opisana su pojedinačno geografska i geološka svojstva pojedinog područja kao i hidrološke i hidrogeološke značajke. Tri osnovna područja istraživanja su predmet ovog rada, a podijeljena su na načine kretanja vode u kršu, to jest geološkim i geomorfološkim značajkama krških fenomena koji služe kao medij kod kretanja vode. Prvo područje istraživanja je duboka jama i nalazi se unutar sliva hidrološkog sliva rijeke Cetine na planini Dinara. Drugo područje istraživanja je površinski tok rijeke Cetine na kojem je izrađena je analiza mogućnosti uporabe probabilističkog koncepta kod mjerenja protoka. Treće i zadnje područje istraživanja su Crveno i Modro jezero kod Imotskog. Ona predstavljaju presliku kretanja podzemnih voda unutar krškog masiva, jer razina vode u jezerima je izravno vezana s razinom podzemne vode.

Ova tri područja od interesa kroz primjenu različitih metoda mjerenja i analize čine jednu cjelinu koja se upravo bavi kretanjem vode kroz krški masiv s naglaskom na eksperimentalna istraživanja te iznesenim zaključcima nude nova saznanja vezana za hidrologiju krša.

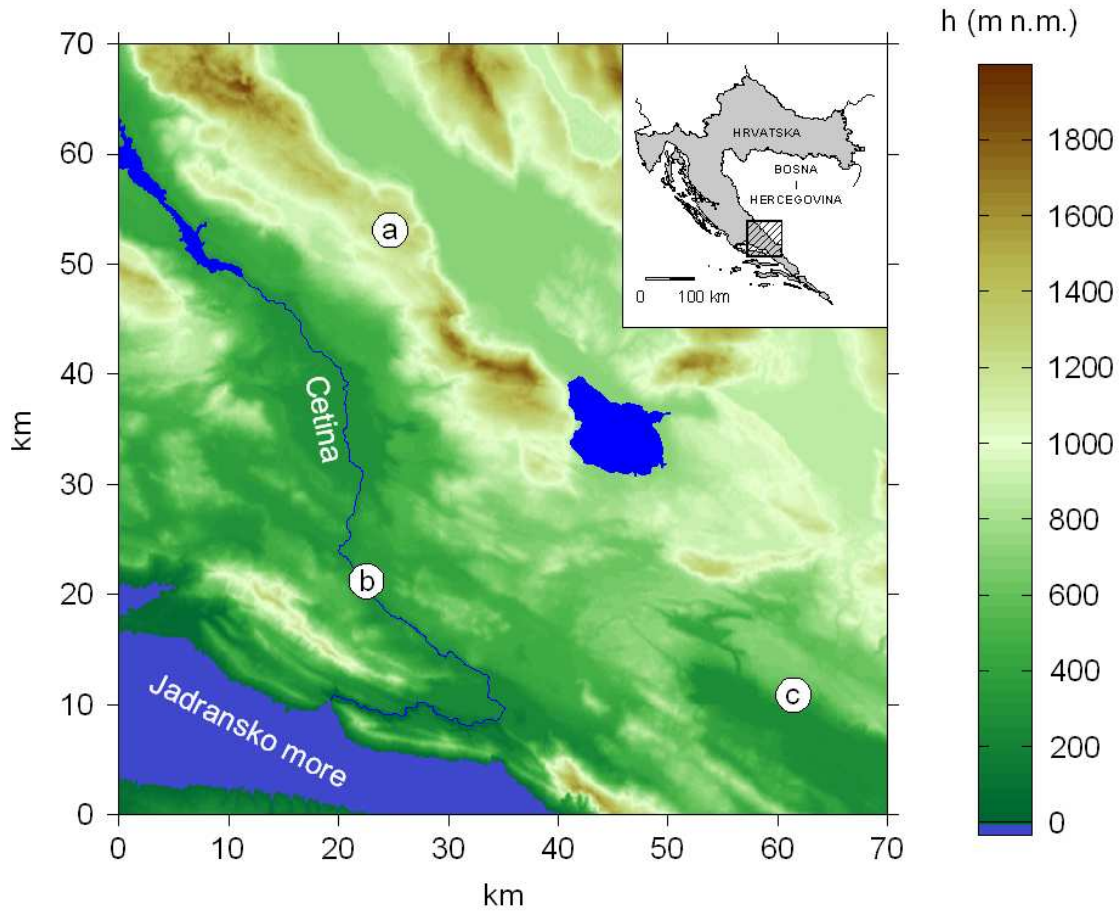
4.1 GEOLOŠKE I GEOGRAFSKE ZNAČAJKE PODRUČJA ISTRAŽIVANJA

Tri osnovne geografske lokacije vezane za istraživanja prezentirana u ovom radu, nalaze se u južnom dijelu Dalmacije i jugozapadnom dijelu Bosne i Hercegovine. Kako državna granica između Republike Hrvatske i Bosne i Hercegovine unutar Jadranskog sliva dijeli većinu vodotoka i njihovih slivova, svako razmatranje kretanja voda s administrativnog gledišta predstavlja izazov u vidu problema vezanih za prekogranične vode i vodonosnike (Transboundary aquifers). Slika 4.1 prikazuje dijeljene slivove između Hrvatske i Bosne i Hercegovine koji svojim najvećim dijelom upravo sačinjavaju Jadranski sliv [P11].



Slika 4.1 Prekogranične vode između Hrvatske i Bosne i Hercegovine unutar Jadranskog sliva gdje je 1. sliv Krke, 2. sliv Cetine, 3. sliv Neretve (desno) i 4. sliv Neretve (lijevo) i Trebišnjice.

Područja istraživanja ovog rada leže unutar slivova Cetine i Neretve (desno). Točke na slici 4.2 upravo označavaju glavne lokacije na kojima su vršena hidrološka mjerenja. Lokacija (a) se odnosi na jamu Nevidna voda unutar sliva Cetine na teritoriju Bosne i Hercegovine gdje je praćena hidrodinamika speleološkog objekta uslijed osnovnog ulaza u sustav u vidu oborine. Lokacija (b) je profil na rijeci Cetini kod Čikotine Lađe gdje je mjeren protok površinskog toka, te pri tom primijenjen probabilistički pristup Lokacija (c) označava područje Imotskog gdje su praćene hidrološke funkcije i sustav Modrog i Crvenog jezera.



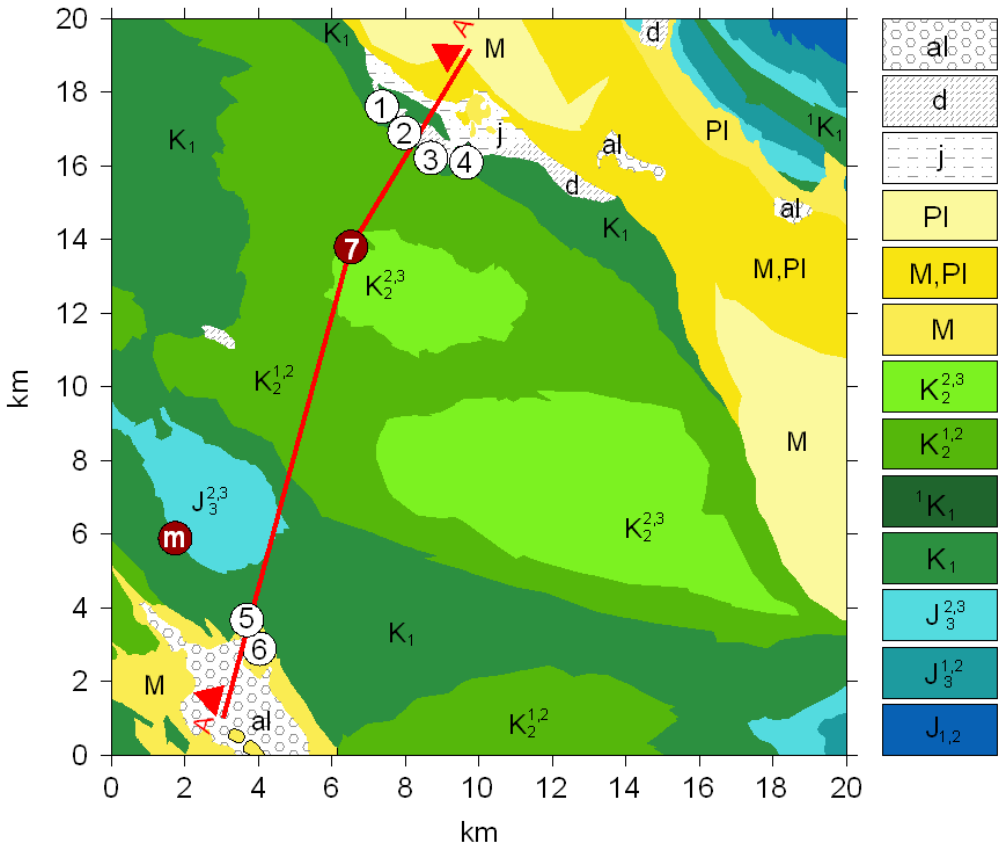
Slika 4.2 Geografske pozicije pojedinih istraživanih lokaliteta: (a) jama Nevidna voda, (b) profil na rijeci Cetini kod Čikotine Lađe i (c) Crveno i Modro jezero kod Imotskog

4.1.1 Jama Nevidna voda

U Dinarskom kršu se duboke jame kao podzemni krški oblik učestalo pojavljuju na nadmorskim visinama većim od 1000 m n.m. Vertikalni kanali služe kao provodnici i dominantni kolektori površinskih voda, ali ujedno i presijecaju podzemne tokove vode u krškom vodonosniku te se mogu smatrati svojevrsnim prirodnim pijezometrima. Dinamika hidrološkog sustava pojedine jame je najčešće izravno vezana za oborinu kao glavni izvor prehranjivanja vodonosnika kroz nezasićenu zonu istog [P10]. Nadalje, topljenje snijega je također mehanizam unosa tvari, kao i pronosa topline kroz vodu nezasićene zone. Razine zasićenog područja vodonosnika su podložne jakim oscilacijama. Razina podzemne vode se mijenja brzinom većom od 1m/h, a oscilacije mogu biti preko 100 m [B13].

Jama Nevidna voda se nalazi u Bosni i Hercegovini na istočnoj strani Dinare uz granicu Republike Hrvatske. Ulaz jame se nalazi na nadmorskoj visini od 1231 m n.m, a ukupna dubina iznosi 653 m. Hidrološka aktivnost predmetnog speleološkog objekta je prisutna tijekom cijele godine.

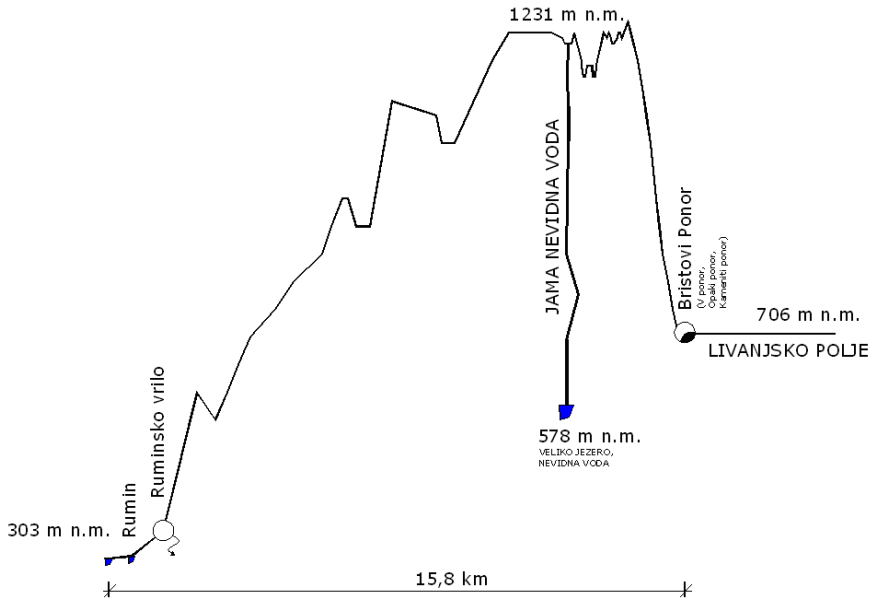
Slika 4.3 predstavlja pojednostavljenu geološku kartu na lokaciji jame Nevidna voda s naznačenim ponorima sa sjeveroistočne strane na Livanjskom polju te izvorima s jugozapadne strane Mali Rumin i Rumin Vrilo. Također je naznačena lokacija kišomjera u mjestu Gornji Bitelić.



Slika 4.3 Litostratigrafska karta područja istraživanja oko jame Nevidna voda. Tumač: (al) – aluvij, (d) – deluvij, (j) – jezerski sediment, (Pl) – paleocenski lapori i pjeskovite gline, (M,Pl) – mastrihtski i paleocenski bijeli lapori, (M) – lapori i konglomerati, ($K_2^{2,3}$), ($K_2^{1,2}$) – vapnenci gornje krede, ($^1K_1$) – vapnenci donje krede s dolomitima, (K_1) – vapnenci donje krede, ($J_3^{2,3}$), ($J_3^{1,2}$) – vapnenci gornje jure, ($J_{1,2}$) – jurski vapnenci s proslojcima dolomita (OGK 1:100.000, list: Sinj). Oznake s brojevima predstavljaju: (1) – Veliki ponor, (2) – Bristov ponor, (3) – Opaki ponor, (4) – Kameni ponor, (5) izvor Mali Rumin, (6) izvor Rumin Vrilo i (7) jama Nevidna voda. Oznaka (m) predstavlja lokaciju kišomjera u mjestu Gornji Bitelić. Poprečni presjek (A-A) je naznačen u slici 4.4.

Jama je se nalazi u naslagama gornje krede s prijelazom u dolomite i breče u dubljim dijelovima jame. Čitav teren karakterizira nekolicina velikih i jakih rasjeda [H1]. Rasjedi se

najčešće pružaju u pravcu SI - JZ, odnosno S - J te uzdužni, paralelni rasjedi s osima SZ – JI. Na slici 4.2 naznačen je uzdužni presjek (A-A) prikazan na slici 4.4.



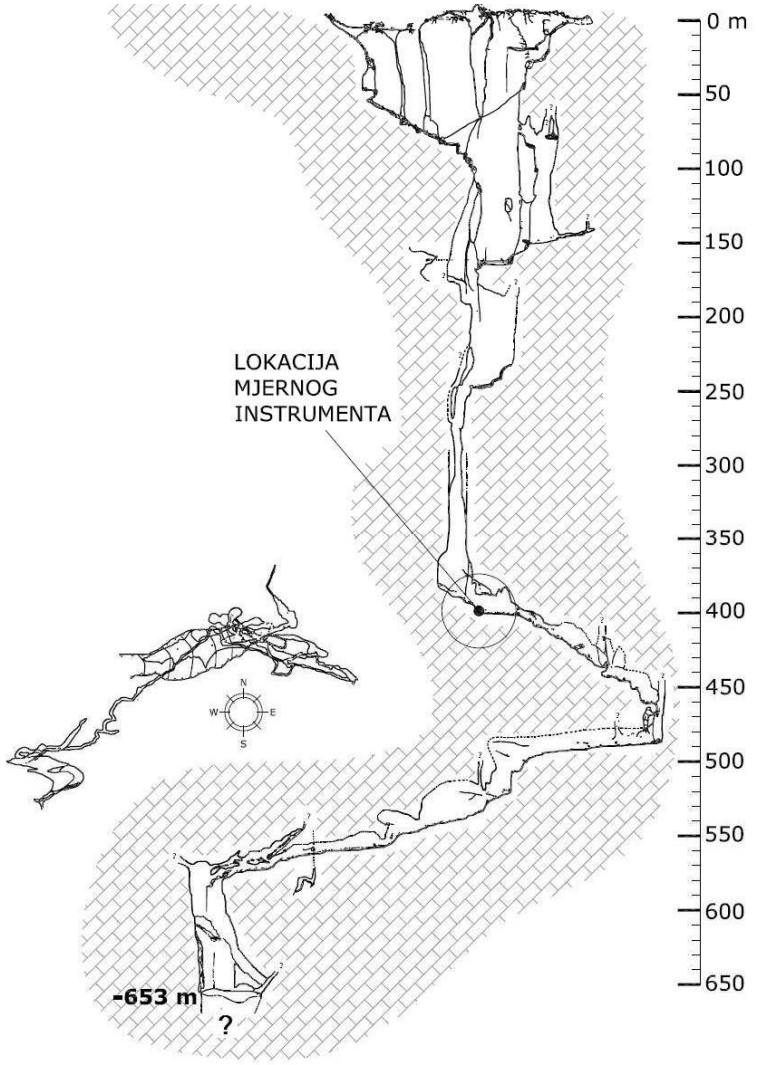
Slika 4.4 Poprečni presjek (A – A) s naznačenom lokacijom jame Nevidna voda te lokacijama ponora i izvora sa suprotnih strana padina Dinare.

Znanstvena hidrološka istraživanje jame Nevidna voda se provode od 2008. godine. U sklopu istih postavili su se mjerni uređaji za kontinuirano mjerenje osnovnih kemijskih i fizičkih parametara vode. Kontinuirano mjerenje temperature vode, električne vodljivosti i hidrostatskog tlaka se provodilo kroz cijelu hidrološku godinu od 13.8.2008. do 5.9.2009.

Speleološka istraživanja su otpočela 2005. godine te dovršena 2008. godine. U njima je sudjelovalo više speleoloških društava i klubova iz Republike Hrvatske i Bosne i Hercegovine: SO HPD Mosor - Split, SO PDS Velebit - Zagreb, SO HPK Mihovil - Šibenik SO PK Split - Split, SO HPD Imber - Omiš, SO PD Profunda - Selca, Brač, HBSD - Zagreb, SD Špiljar - Split, SO HPD Željezničar - Zagreb, SO PD Dubovac – Karlovac te PD Cincar – Livno.

Prema utvrđenim podzemnim vezama hidrološkog sliva rijeke Cetine [M1] i s geografskom položaju jame Nevidna voda, može se reći za promatrani speleološki objekt da je na glavnom pravcu toka podzemnih voda između ponora u Livanjskom polju (Veliki ponor, Bristov ponor, Opaki ponor i Kameni ponor) i izvora sa zapadne strane Dinare koji u značajnoj mjeri prehranjuju Cetinu (Rumin vrilo i Mali Rumin). Nevidna voda je najdublja do sada istražena jama na dinarskom masivu u Bosni i Hercegovini. Smještena je dva kilometra unutar granice Bosne i

Hercegovine na platou iznad sela Odžak. Dva ulaza čine najniži dio krške udoline i nalaze se na nadmorskoj visini od 1231 m n.m. Dijeli ih prirodni most. Manji ulaz ima dimenzije 20x30 m, a veći ulaz 30x50 m.



Slika 4.5 Uzdužni profil jame Nevidna voda, tlocrt i lokacija mjernog instrumenta. Topografski snimili: Domagoj Laušić, Marin Glušević, Luka Mudronja,Goran Rnjak, Inga Patarčić, Teo Barišić, Ivica Radić; mjerili: Goran Rnjak, Marko Babić, Davor Cvitanić, Katja Milišić, Luka Mudronja, Ana Bakšić, Vedrana Jerić-Miloš, Loris Redovniković, Ivo Andrić, Ivančica Zovko; nacrt izradili: Domagoj Laušić, Goran Rnjak.

Položaj mjernog uređaja, prikazan na slici 4.5, korišten tijekom istraživanja, bio je na dubini od 395 m u nezasićenoj zoni vodonosnika. Pretpostavlja se da je zasićena zona izravno u vezi s razinom otkrivenog jezera na dnu jame (653 m). Ispod površine jezera uočeni su potopljeni stalagmiti koji spadaju u sige što nastaju u nezasićenoj zoni. Prema tome se pretpostavljaju visoke oscilacije razine vode na dnu jame. Nadalje, pretpostavlja se da je na toj dubini u prijašnjoj fazi

razvoja bio dio jame u vadoznim uvjetima. Razina vode na mjestu mjerenja u jami je izravno ovisila o protoku generiranom površinskim tokom iznad ulaza objekta te provođenjem istog glavnim kanalom kao i infiltracijom i perkolacijom kroz samu matricu krša.

Slika 4.5 prikazuje također uzdužni profil jame Nevidna voda, tlocrt te lokaciju mjernog instrumenta. Dva ulaza u jamu su ujedno i najniže točke lokalnog orografskog sliva. Na dubini od 250 metara počinje stalni tok vode, a za vrijeme izraženih oborina prisutan je kroz cijeli objekt. Perspektiva daljnjeg speleološkog istraživanja postoji no za to je potrebno provođenje ronjenja u cilju istraživanja potopljenih kanala.

4.1.2 Sliv rijeke Cetine

Mjerenje protoka na otvorenom vodotoku vršeno je na rijeci Cetini na profilu Čikotina Lađa (2) (slika 4.2). Cetina predstavlja tipični primjer otvorenog vodotoka unutar izrazito razvijenog Dinarskog krša.

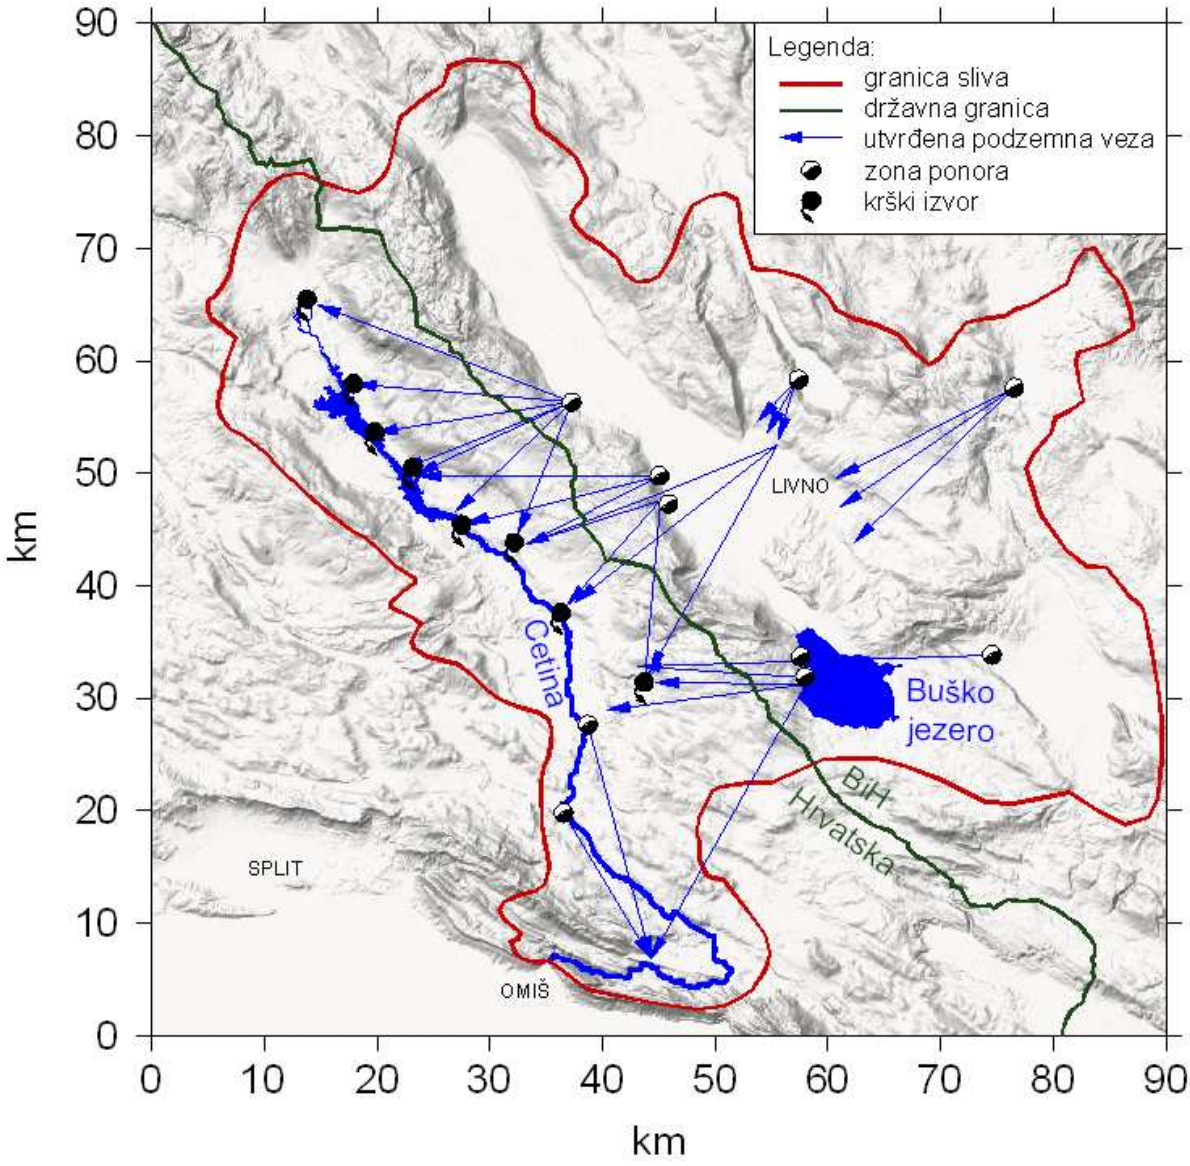
Sliv rijeke Cetine ima procijenjenu površinu od 4000 km^2 [M1]. Od toga su dvije trećine sliva unutar Bosne i Hercegovine, a jedna trećina unutar Republike Hrvatske. Dio sliva unutar Republike Hrvatske predstavlja orografski sliv rijeke Cetine, a ostatak predstavlja hidrološki sliv [M1] (slika 4.6). Duljina vodotoka od izvora Glavaš do ušća u Jadransko more u Omišu iznosi 105 km.

Promatrajući morfološku strukturu sliva Cetine, mogu se izdvojiti dvije velike cjeline: planinsko područje i polja u kršu. Odnosi tih reljefnih cjelina definiraju kretanje površinskih i podzemnih voda unutar sliva. Pojava površinskih tokova je vezana uglavnom za krška polja i kompozitne doline, tj. doline složene strukture u kojoj se izmjenjuju kanjoni, dolinska proširenja i probojnice, a komunikacija voda između polja se odvija podzemnim putem.

Opće geološke značajke sliva Cetine su određene prema Osnovnoj geološkoj karti (OGK) 1:100.000, listovi: Knin, Glamoč, Bugojno, Livno, Sinj, Omiš i Imotski. U geološkom smislu sliv rijeke Cetine predstavlja složenu građu, prvenstveno sastavljenu od naslaga mezozoika i kenozoika, a u manjem dijelu su zastupljeni magmatiti i metamorfiti.

Složeni tektonski odnosi unutar sliva su imali bitnu ulogu na cjelokupne hidrogeološke odnose unutar predmetnog područja. Jura (J) je zastupljena na cjelokupnom prostoru sliva u regularnom superpozicijskom odnosu prema naslagama gornjeg trijasa. Kreda (K) je najzastupljeniji kronostratigrafski član, razvrstan u više skupina (zona), kako donje krednih, tako i gornje krednih neraščlanjenih litoloških cjelina. Ovi sedimenti pretežno su pozicionirani u

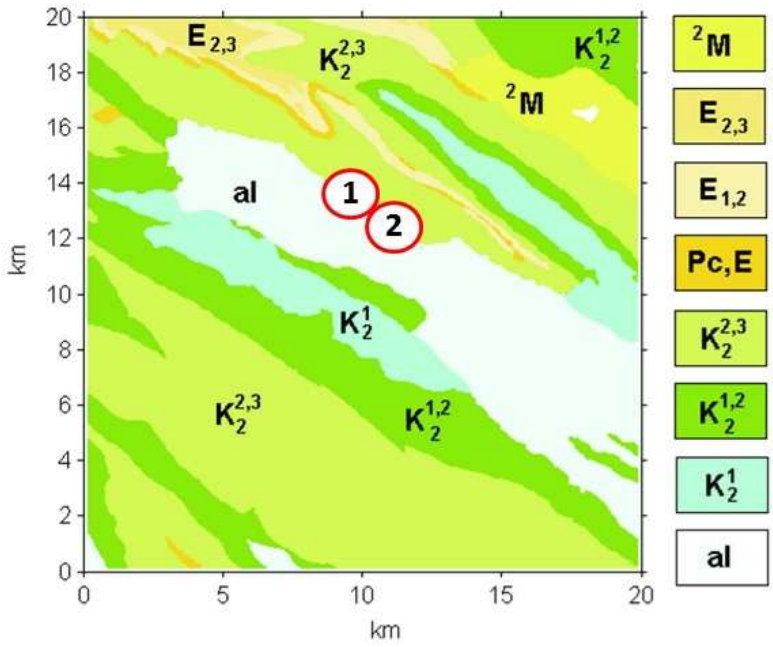
neposrednom okruženju neogenog bazena, Livanjskog polja. Paleogen (Pg) je najviše zastupljen na području listova OGK Sinj, Livno i Imotski. Neogen (N) se javlja kao pratilac paleogena u normalnom superpozicijskom odnosu, a predstavljen je najmarkantnijim geološkim formacijama u prostoru Livanjskog, Duvanjskog i Glamočkog polja. Karakteriziraju ih litološka raznovrsnost u ovisno o zastupljenosti prevladavajuće epohe. Kvartar je zastupljen u dolinskim prostorima površinskih vodotoka, na strmo nagnutim padinama, kao i na prostoru mirnijeg toka te izraženom sedimentacijom (Livanjsko polje, Glamočko polje, Sinjsko polje, prostor oko Cetine prema jezeru Peruča, Kupreško polje i Buško Blato).



Slika 4.6 Granice sliva rijeke Cetine s ucrtanim dokazanim vezama podzemnog toka (Magdalenić, 1971)

4.1.3 Modro i Crveno jezero

Modro i Crveno jezero kao treće područje istraživanja ovog rada predstavljaju krške fenomene poznate u cijelom svijetu. Geološka građa izučavanog područja je tipična za dalmatinsko zaleđe i kao takvu je karakteriziraju vapnenački slojevi gornje krede oko Imotskog polja. U njima su i lokalizirana oba jezera sa sjeverne strane polja. Šire područje zavale Imotskog polja izgrađeno je pretežno od vapnenca i dolomita kredne starosti i od tercijarnih naslaga predstavljenih klastitima (fliš, jezerske slatkovodne naslage i vapnenci). Sedimenti kvartarne starosti dominiraju u geološkom sastavu dna Zavale [R5]. Slika 4.7 prikazuje pojednostavljenu geološku kartu područja istraživanja oko Crvenog i Modrog jezera.



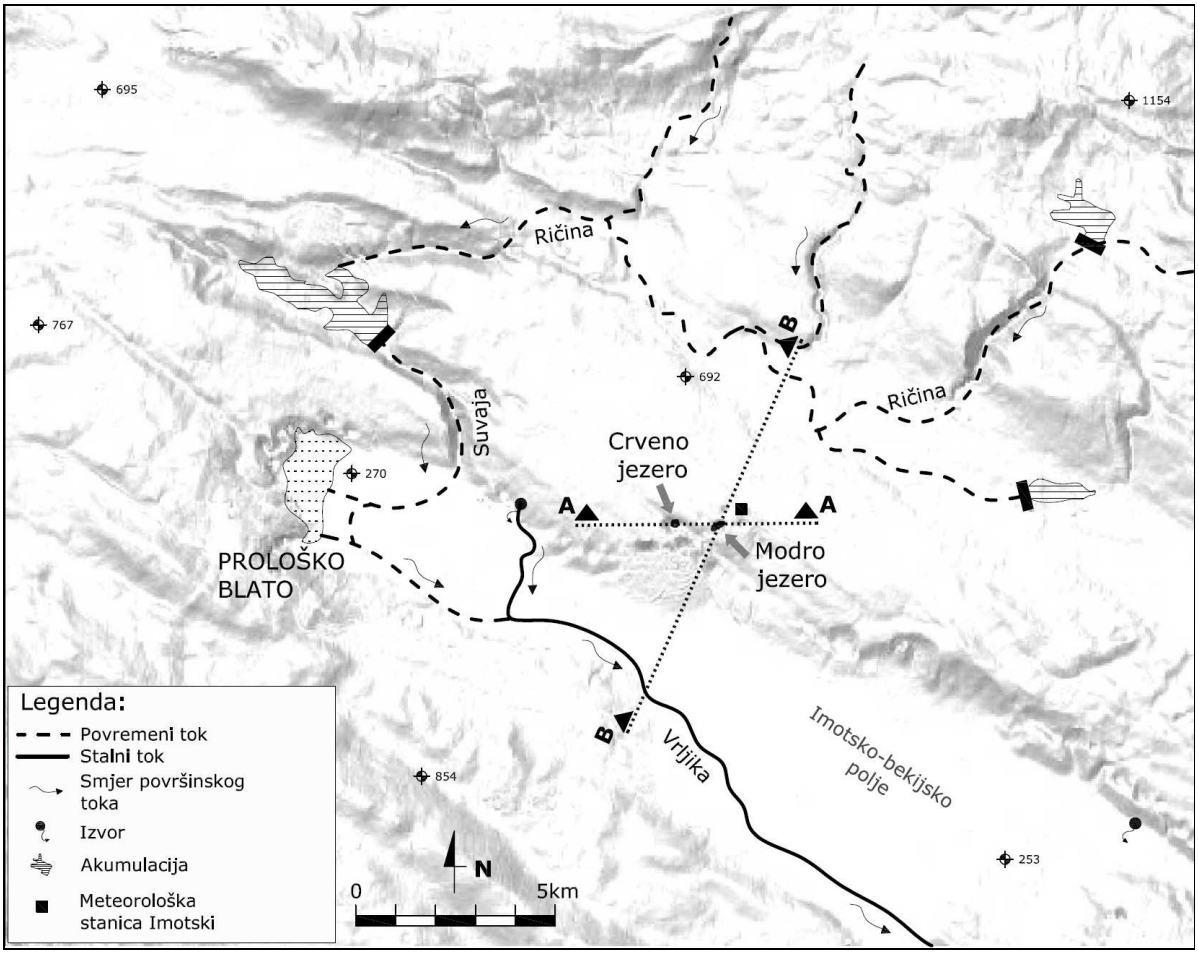
Slika 4.7 Litostratigrafska karta područja istraživanja oko Crvenog (1) i Modrog (2) jezera kod Imotskog. Tumač: (al) – aluvij, (^{2}M) – mastrihtski vapnenci, ($E_{2,3}$), ($E_{1,2}$), (Pc, E) – paleocenski i eocenski vapnenci, a ($K_2^{2,3}$), ($K_2^{1,2}$) – vapnenci gornje krede (OGK 1:100.000, list: Imotski).

Crveno jezero predstavlja impresivnu površinsku formu u Dinarskom kršu ekstremnih dimenzija i kao takvo odjek zbivanja iz geološke prošlosti gdje su u podzemlju zbog urušavanja pokrenuti procesi njegovog nastanka. Crveno jezero je stalno jezero dok Modro jezero povremeno presuši [B20]. Na slici 4.8 nalazi se karta šireg područja na kojoj se nalaze brojni površinski krški oblici i vodni fenomeni.

Crveno, a s njim i Modro jezero su u fokusu znanstvenika više od 100 godina. Znanstvenici koji su ih izučavali čak se ne slažu u tome da li se radi o ponikvama, jamama, cenotama, jezerima

ili nekim drugim krškim oblicima. Većina starijih autora tvrdi da oba jezera predstavljaju urušene ponikve. Mlađi i speleološki orijentirani autori zastupaju tezu da se radi o speleološkom objektu.

Crveno jezero je nedovoljno izučeno prvenstveno zbog teškoća koje se javljaju prilikom njegovih mjerenja. Tijekom rujna 2013. izvršena su mjerenja koja su značajno pridonijela rasvjetljavanju ovog fenomen. Mjerenjima je utvrđeno niz novih činjenica koje se razlikuju od onih navedenih u postojećoj literaturi.

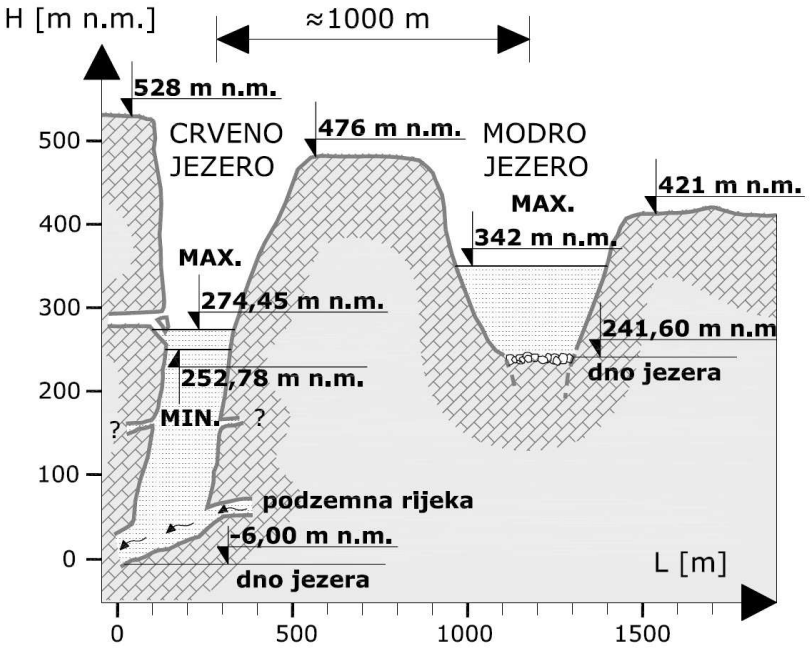


Slika 4.8 Geografski položaj Modrog i Crvenog jezera s naznačenim vodnim fenomenima odabranih za šire Imotsko područje. Poprečni presjek (A-A) prikazan je na slici 4.9, a (B-B) na slici 4.8.

Mnogi autori u literaturi navode prvenstveno morfološka istraživanja oba jezera. Prva sustavna istraživanja vrši Petrik 1958 godine [P8]. On smatra da je ponikva Crvenog jezera od svih ponikvi oko Imotskog, kojih ima desetak, najmlađa. Izmjerio je da najviša kota na obodu iznosi 522,9 m n.m., a najniža 425,4 m n.m. Procijenio je da najniža kotu dna Crvenog jezera iznos 4,1 m n.m. Iz njegovog rada proizlazi da najveća dubina ponikve Crvenog jezera iznosi 518,8 m. Tijekom njegovih mjerenja najviša izmjerena razina vode bila je 274,45 m n.m. (4. lipnja

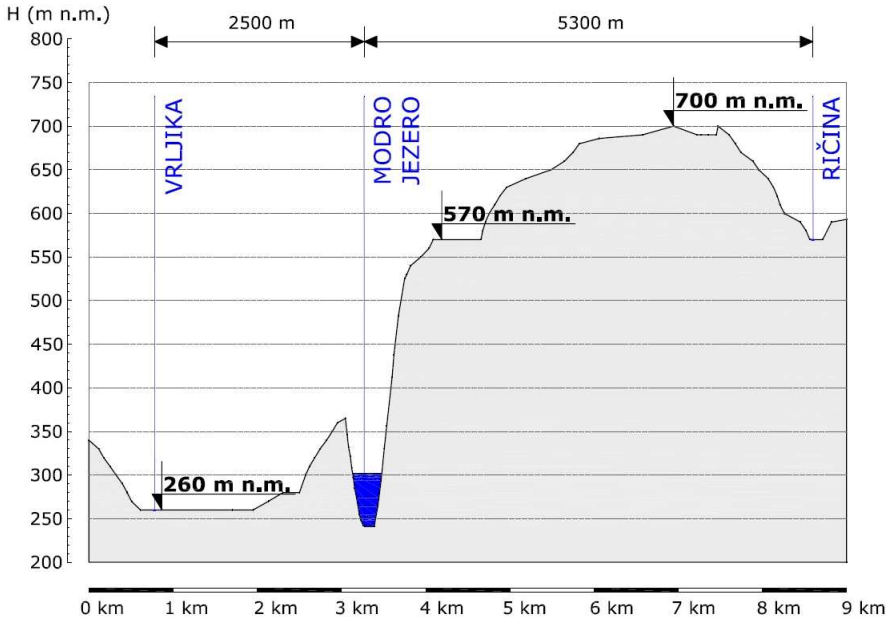
1958.), a najniža je iznosila 252,78 m n.m. (20. srpnja 1955.). Raspon izmjerenih oscilacija razine vode Crvenog jezera iznosio je 21,67 m. Izračunao je da se kod razine vode od oko 254 m n.m. iz Crvenog jezera gubi 89 l/s te da zapremina vode Crvenog jezera kod vodostaja 268 m n.m. iznosi najmanje $6 \cdot 10^6$ m^3. Vodni režim Crvenog i Modrog jezera smatra međusobno odvojenim, te pretpostavlja da nemaju značajnije veze s vodnim režimom ostalog dijela područja Imotskog polja i okolice. Nadalje, navodi nekoliko mogućih lokacija na kojima bi ova podzemna voda mogla izbiti na površinu. Kao najvjerojatnije mjesto navodi uvalu Vrulje na obali Jadranskog mora udaljenu zračnom linijom od Crvenog jezera oko 23 km. U toj uvali postoje brojni i obilni podmorski krški izvori (vrulje).

Međunarodna speleoronilačka ekspedicija u Crveno jezero koja se odvijala tijekom rujna i listopada 1998. donosi nova saznanja vezana za Crveno jezero [G4]. Dobiveni rezultati daju po prvi puta geomorfološke karakteristike dna Crvenog jezera. Slika 4.9 predstavlja poprečni presjek (A-A) Crvenog jezera prema rezultatima speleoronilačke ekspedicije iz 1998. godine.



Slika 4.9 Poprečni presjek (A-A) sa slike 4.7 na osnovu rezultata speleoronilačke ekspedicije iz 1998. godine (Garašić, 1999).

Slika 4.10 prikazuje poprečni presjek (B-B) sa slike 4.8 kroz Modro jezero S-J orijentacije.



Slika 4.10 Poprečni presjek (B-B) sa slike 4.8.

Modro jezero zajedno sa susjednim Crvenim jezerom s aspekta geomorfologije krša predstavlja rijedak i grandiozan oblik. Sadržaj ovog rada sačinjavaju upravo nova znanstvena istraživanja ovih jezera uz uporabu novih tehnologija, čije prednosti prethodni istraživači nisu mogli koristiti. S novim spoznajama doprinos se daje sveopćem znanju o ovim fenomenima krša koja nikad sustavno u znanstvenom smislu nisu bila praćena.

4.1 HIDROGEOLOŠKE I HIDROLOŠKE ZNAČAJKE PODRUČJA ISTRAŽIVANJA

Hidrogeološke uvjete slivnog područja Cetine unutar kojeg se nalazi jama Nevidna voda kao i šireg Imotskog područja karakterizira vodopropusnost stijena, s podjelom na dobro vodopropusne, umjereno vodopropusne i slabo propusne do nepropusne stijene.

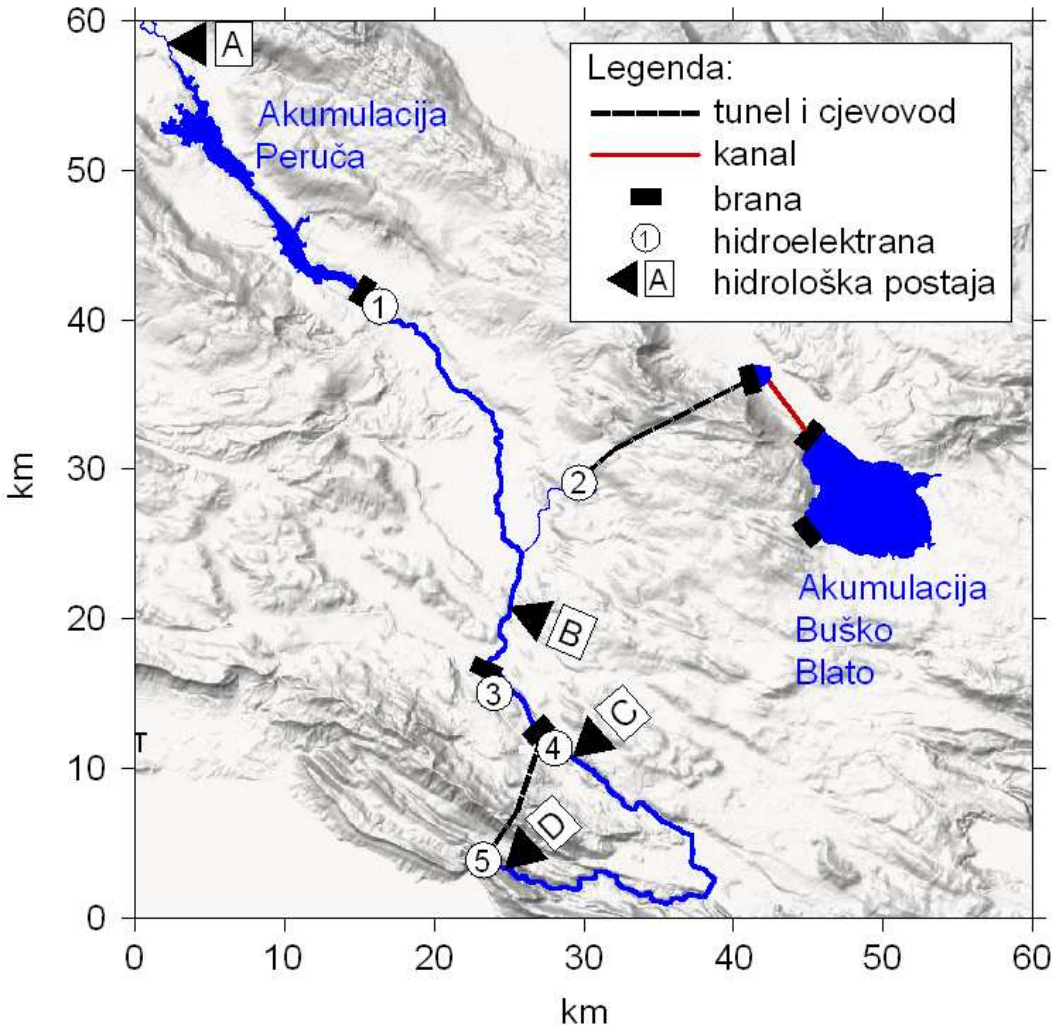
Dobro vodopropusne stijene sastavljene od razlomljenih i okršenih vapnenaca , kao i sedimenata međuzrnate poroznosti. Vodonosnike velike vodopropusnosti čine naslage mezozoika (T_2^1, J_2, $J_3^{1,2}$, K_1^{1-3}, K_2^1, K_2^2, K_2^{2+3}) i eocena ($E_{1,2}$), koji su zastupljeni karbonatnim naslagama sekundarne i tercijalne poroznosti (vapnenci, vapnenačke breče i konglomerati, te vapnenci s proslojcima dolomita). Ipak vapnenci gornje krede (K_2) predstavljaju moćan hidrogeološki kolektor krških obilježja s heterogenom strukturom podzemnih tokova i akumulacija te s relativno

brzom cirkulacijom vode u podzemlju. Kvartar (Q) je zastupljen naslagama međuzrnate poroznosti, od kojih aluvijalne naslage i sipari predstavljaju vodopropusne sedimente.

Umjereno propusne stijene sačinjavaju naslage srednjeg trijasa (T_2^2), srednjeg do gornjeg trijasa ($T_{2,3}$) i gornjeg trijasa (T_3), te mlađe naslage gornje jure ($J_3^{2,3}$). Ovi slojevi imaju svojstva hidrogeološkog izolatora sredine. Ipak, tektonski utjecaji su omogućili tok podzemne vode po pukotinskim pravcima i pravcima većih rasjeda. Naslage donje krede (K_1) imaju bolje akumulacijske osobine samo u području viših horizonata. Okršenost slojeva donje krede je vezana za mlađe karbonatne naslage. U donjim razinama ovog kronostratigrafskog člana prevladavaju masivni dolomiti, koji ipak u ukupnom sklopu terena formiraju zonu s karakteristikama hidrogeološkog izolatora. Srednja vodopropusnost je također karakteristična za slojeve donje i srednje krede ($K_{1,2}$) sačinjene od dolomita, dolomitičnih vapnenaca, vapnenaca i breča. Eocenske naslage (E) pretežno su građene od konglomerata, slojeva laporovitih vapnenaca i lapora. Ovo je srednje razvijen hidrogeološki kolektor pukotinske poroznosti. Tek lokalno moguće je zapaziti izraženiju poroznost koji se vežu za zone intenzivnih tektonskih oštećenja. Kvartar (Q) je unutar sliva zastupljen crvenicom (ts), fluvioglacijalnim (fgl) i glacijalnim materijalom, te deluvijalnim (d) i izvorskim (i) sedimentima. Ove sedimente karakterizira umjerena vodopropusnost.

Slabopropusne do nepropusne stijene su zastupljene su u terenima donjeg i srednjeg trijasa, paleogenih sedimenata, neogena te kvartara. Kolektorska obilježja su im slabo izražena te se duž kontakta slabopropusnih slojeva i vodonosnika pojavljuje veći broj krških izvora.

Hidrološke značajke se pak mogu samo navesti za rijeku Cetinu i njen sliv, jer kod primjera jame Nevidna voda i Imotskih jezera sustavna hidrološka mjerenje ne postoje. Kako se sliv rijeke Cetine dijeli na orografski i hidrološki dio kao što je to prikazano na slici 4.5, hidrološke značajke rijeke Cetine se odnose ponajprije na površinski tok i orografski dio sliva. Na slici 4.11 prikazana je karta s orografskim dijelom sliva Cetine te svim hidrotehničkim zahvatima na slivu. Nadalje, prikazane su lokacije karakterističnih hidroloških postaja za koje postoje višegodišnji nizovi mjerenih podataka.



Slika 4.11 Površinski tok rijeke Cetine s hidrotehničkim objektima unutar sliva gdje su oznake (1) HE Peruča, (2) HE Orlovac, (3) HE Đale, (4) HE Kraljevac i (5) HE Zakučac. Značajne hidrološke postaje su označene sa (A) Vinalići, (B) Gardunska Mlinica, (C) Čikotina Lađa i (D) Tisne Stine.

Izvor rijeke je na koti od 382 m n.m, što daje prosječan pad korita rijeke od 0,3638 promila. Značajni pritok po protočnom kapacitetu je jedino rijeka Ruda. Četiri hidrološke postaje su značajne za hidrološku analizu. Hidrološka postaja Vinalići (A) mjeri protok iz cjelokupne izvorišne zone, a hidrološka postaja Gardunska Mlinica (B) obuhvaća dodatno i dotok svih voda iz istočnog neizravnog dijela sliva. Hidrološka postaja Čikotina Lađa (C) bilježi protoke voda koje se puštaju iz akumulacije Prančevići, a odnosi se na stanje poslije izgradnje obaju cjevovoda HE Zakučac. Tisne Stine (D) prikazuje srednji dotok Cetine na samom ušću, dakle, poslije ulijevanja voda iz dvaju cjevovoda, to jest njihova prolaska kroz HE Zakučac i spajanjem s vodama Cetine. U tablici 4.1 nalaze se vrijednosti višegodišnjih srednjih protoka za hidrološke postaje.

Tablica 4.1 Hidrološke postaje na rijeci Cetini, s višegodišnjim izmjerenim vrijednostima za srednji protok (Bonacci, 2003).

Oznaka	Ime hidrološke postaje	Nadmorska visina (m n.m.)	Srednji višegodišnji protok Q (m^3/s)	Vrenensko razdoblje
A	Vinalići	366	12,5	1960 - 1998
B	Gardunska Mlinica	284	104	1961 - 1998
C	Čikotina Lađa	240	8	od 1981
D	Tisne Stine	1	118	1963 - 1998

Može se zamijetiti kako hidrološka postaja Čikotina Lađa bilježi stalni protok od 8,0 m^3/s, što zapravo predstavlja vrijednost protoka definiranog kao biološki minimum što se ispušta iz akumulacije Prančević.

Tablica 4.2 daje pregled srednjih mjesečnih vrijednosti protoka za hidrološke postaje Vinalići lociranoj na izvoru i hidrološkoj postaji Gardunska Mlinica lociranoj prije akumulacije Đale. Ove dvije postaje su važne jer prva daje vrijednosti protoka za izvorišnu zonu rijeke Cetine, a druga za integralni sliv sačinjen od indirektnog i direktnog dijela. Kao što se može vidjeti vrijednosti s druge postaje su uvećani za jedan red veličine u odnosu na hidrološku postaju s izvorišne zone.

Tablica 4.2 Značajne hidrološke postaje na rijeci Cetini s vrijednostima za srednji mjesečni protok.

Oznaka	Ime hidrološke postaje	Srednji mjesečni protoci Q (m^3/s)												
		I	**II**	**III**	**IV**	**V**	**VI**	**VII**	**VIII**	**IX**	**X**	**XI**	**XII**	**God.**
A	Vinalići	15,3	15	15,2	19,4	15,4	9,6	5	3,4	4,9	8,7	15,8	20,3	12,3
B	Gardunska Mlinica	132,9	133,5	122,6	123,6	101,3	77,7	54,5	50,4	55,7	74,6	117,6	146,4	99,2

Iz tablice 4.1 i srednje višegodišnje vrijednosti protoka na hidrološkoj postaji Tisne Stine, proizlazi da srednji višegodišnji koeficijent otjecanja za cijeli sliv Cetine iznosi 0,674 uzme li se u obzir cjelokupna površina sliva od 4000 km^2 i srednja godišnja oborina pala na sliv od 1.380 mm, dobivena Thiessenovom metodom. Iz ovog je vidljivo kako je riječ o slivu s izrazito bogatim vodnim resursima. Ipak, raspodjela vodnih količina tijekom godine nije ujednačena te zbog toga u ljetnom sušnom razdoblju dolazi do značajnog smanjenja vodnih količina unutar sliva. Podzemni vodni resursi u slivu Cetine su značajni no isto tako oni predstavljaju veliku nepoznanicu jer su samo dijelom istraženi.

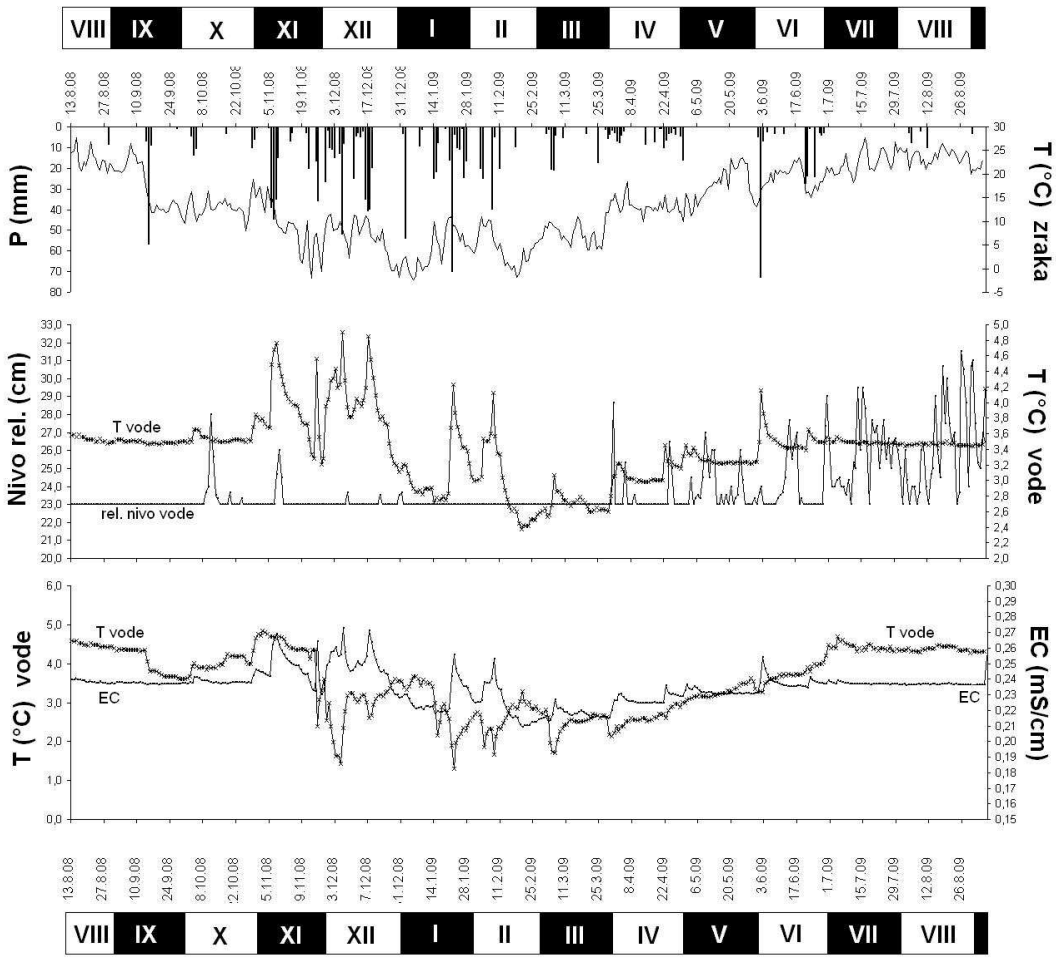
5. LOKALNA I REGIONALNA PREZENTACIJA REZULTATA

U ovom poglavlju predstavljeni su rezultati mjerenja s terena kao i rezultati modeliranja određenih prirodnih procesa kako bi se izučile hidrološke karakteristike područja istraživanja te prezentirale nove spoznaje vezane za hidrološko funkcioniranje na lokalnoj i regionalnoj skali. Nadalje, primjenjivanjem novih obrazaca mjerenja uspoređena je točnost kod mjerenja protoka na uobičajene načine pomoću hidroakustike i nove pristupe temeljene na probabilističkom određivanju srednje brzine i radarskim mjerenjima.

Rezultati su podijeljeni prema lokacijama mjerenja. Sukladno toj podjeli, poglavlje je sačinjeno u cjeline vezane za hidrodinamiku duboke jame Nevidna Voda, probabilistički pristup mjerenja protoka na Cetini, hidrološka i geomorfološka mjerenjima na Crvenom i Modrom jezeru kod Imotskog te diskusiju rezultata.

5.1 HIDRODINAMIKA DUBOKE JAME NEVIDNA VODA

Za potrebe istraživanja hidrodinamičkog odgovora duboke jame na meteorološke ulaze, prikupljeni su dnevne srednje temperature sa klimatološke meteorološke postaje Sinj (308 m n.m.) udaljenoj 18 km zračne linije od predmetnog speleološkog objekta u razdoblju od 13.8.2008. do 5.9.2009. godine kao i dnevne količine oborina sa kišomjera Gornji Bitelić udaljenog 8 km. Kao što je već navedeno, uređaj s automatskim bilježenjem izmjerenih podataka instaliran je unutar jame na dubini od 395 m u nezasićenoj zoni vodonosnika. Podaci o hidrostatskom tlaku, električnoj vodljivosti vode i temperaturi su prikupljani u vremenskom periodu od 10 h (τ = 10h), te su prilagođeni korespondirajućoj vremenskoj skali snimljenog signala s meteorološke i kišomjerne postaje. Na Slici 5.1 su grafički prikazani svi prikupljeni podaci koji su podvrgnuti analizi.



Slika 5.1 Srednje dnevne temperature sa klimatološke meteorološke postaje Sinj, dnevne oborine sa kišomjerne postaje Gornji Bitelić te srednja dnevna temperatura vode, električna vodljivost i relativna razina vode unutar jame Nevidna Voda.

Konstruiran je višestruki linearni regresijski model za simuliranje električne vodljivosti vode i temperature vode unutar jame. Varijable unutar modela predstavljaju srednje dnevne temperature zraka, dnevne oborine te u slučaju modela za simuliranje električne vodljivost dodatnu varijablu temperaturu vode. Tablica 5.1 prikazuje shemu uspostavljenih modela gdje zvjezdica označava vanjske meteorološke parametre.

Tablica 5.1 Shema uspostavljenih linearni regresijskih modelaa EC (električnu vodljivost vode) i Tv (temperaturu vode u jami). Varijable unutar modela su: P (kiša) i Tz (temperatura zraka). Zvjezdica označava vanjske meteorološke parametre

	y_1	x_1	x_2	x_3
(1)	EC	Tv	P*	Tz*
(2)	EC	Tv	P*	
(3)	EC	Tz*	P*	
(4)	Tv	Tz*	P*	

Parametri modela: a_1, a_2 i a_3 se procjenjuju prema MNK metodi, objašnjenoj u 3. poglavlju, a za pripadajuće kombinacije modela (1), (2), (3) i (4) prema prikazu iz tablice 5.1 oni poprimaju vrijednosti prikazane u tablici 5.2:

Tablica 5.2 Prikaz vektorskih parametara za pripadajuće višestruke linearne regresijske modele (1), (2), (3) i (4).

	a_1	a_2	a_3	a_4
(1)	0,001179	0,016238	-0,000605	0,169414
(2)	0,023995	-0,000877	0,160366	
(3)	0,001489	-0,000316	0,21907	
(4)	0,017794	0,019089	3,057962	

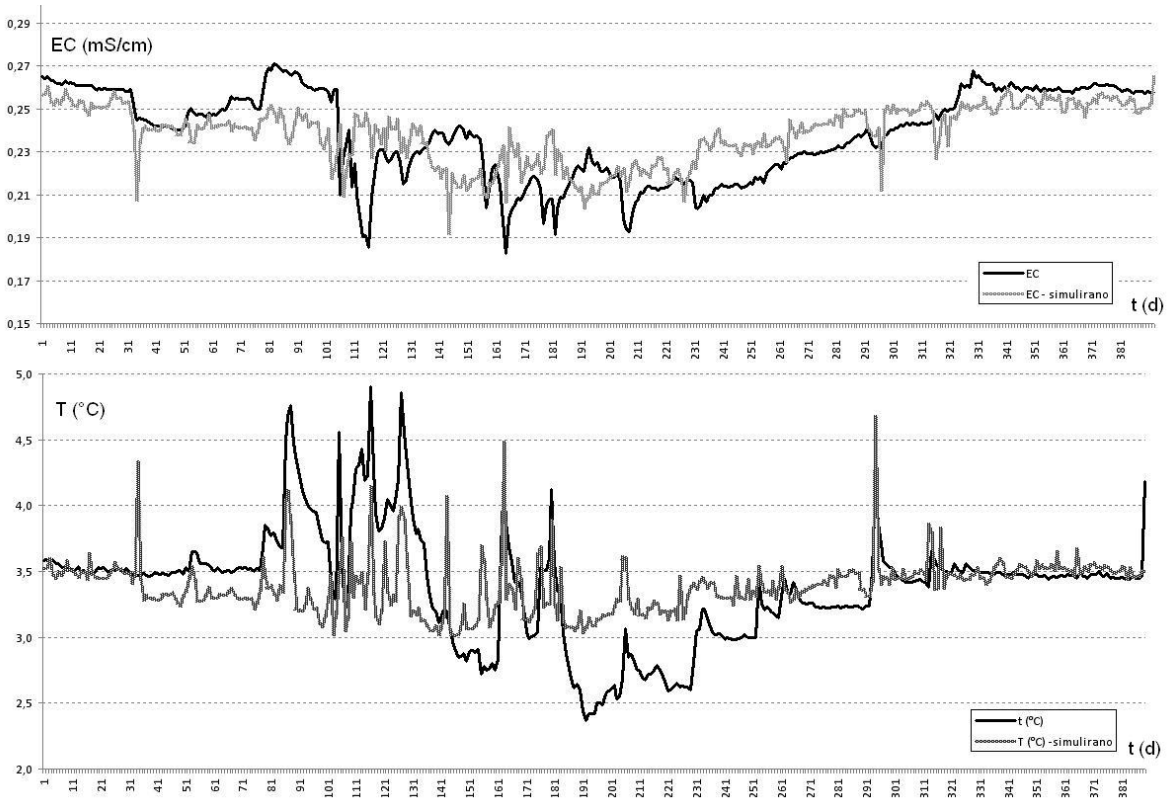
Intervali povjerenja su određeni za uobičajenu pouzdanost $\beta = 0,95$ prema Studentovoj distribuciji, a tablica 5.3 prikazuje pripadajuće intervale povjerenja za svaku kombinaciju pojedinačno.

Tablica 5.3 Prikaz gornjih i donjih granica intervala povjerenja za pripadajuće višestruke linearne regresijske modele (1), (2), (3) i (4).

(1)		(2)		(3)		(4)	
0,00096	0,001397	-0,001063	-0,00069	-0,000484	-0,000148	0,014049	0,024129
0,012184	0,020292	0,145916	0,174817	0,215487	0,222652	2,975795	3,140128
-0,000776	-0,000433	0,01969	0,028299	0,001269	0,001709	0,013949	0,02164
0,156577	0,18225						

Na osnovu dobivenih modela grafički je moguće usporediti simulirane i stvarne vrijednosti. U ovom radu uzeti su na daljnje razmatranje modeli za električnu vodljivost vode - EC (1) i temperaturu vode – Tv (4). Na slici 5.2 su uspoređeni stvarni mjereni podaci sa simuliranim. Uočljiva su područja gdje simulirani podaci jako dobro opisuju stvarne, ali i područja gdje za model nije moguće dovoljno dobro opisati realno stanje.

Za potrebu ocjenjivanja modela potrebno je izračunati razliku između modela i stvarnih podataka (reziduale) te provjeriti njihovu prisutnost unutar prethodno dobivenih intervala povjerenja.

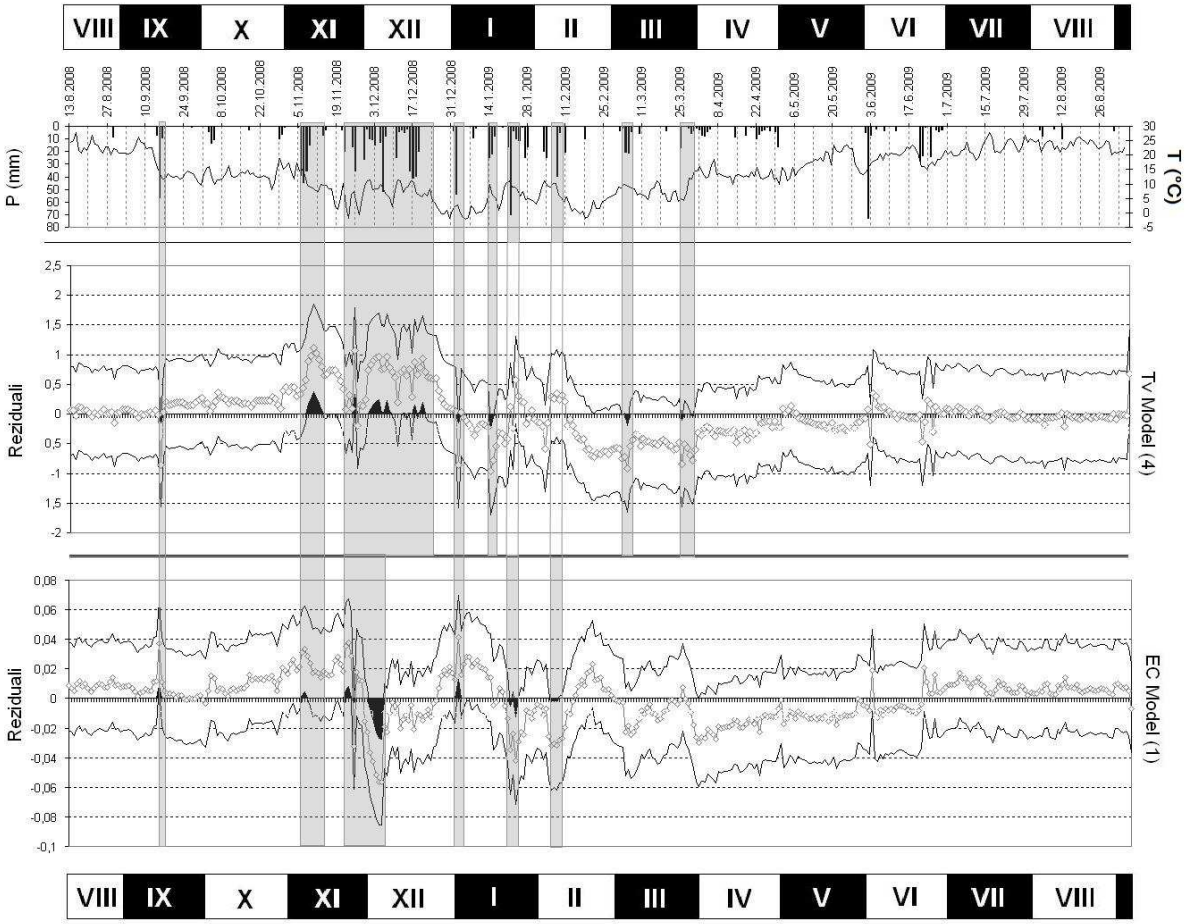


Slika 5.2 Grafički prikaz simuliranih i stvarnih (mjerenih) vrijednosti za višestruke linearne regresijske modele EC (1) i Tv (4).

Na slici 5.3 su grafički prikazane razlike između simuliranih vrijednosti dobivenih višestrukim linearnim regresijskim modelima za električnu vodljivost i temperaturu vode (EC (1) i Tv (4)) i stvarnim mjerenim vrijednostima kroz promatranu hidrološku godinu. Područja gdje ostaci prelaze intervale određene pouzdanošću $\beta = 0,95$ su označene crnim površinama te su uspoređene s glavnim ulaznim veličinama u sustav, oborinama i vanjskoj temperaturi.

Model EC (1) u 17 slučajeva (4,37 %), a model Tv (4) u 31 slučaj (7,97 %) ne ispunjava zadanu pouzdanost. Nepouzdanost se u većini slučajeva snažno poklapa s izrazitim kišnim

događajima. Kod simuliranih vrijednosti temperature vode unutar jame nepouzdanost modela se može uočiti tijekom travnja iako značajnije količine oborina nisu zabilježene u navedenom razdoblju. Razlog tome može biti različiti mehanizam pronosa toplinske energije u vodi koji se aktivira u tom razdoblju, a veže se za otapanje snijega.

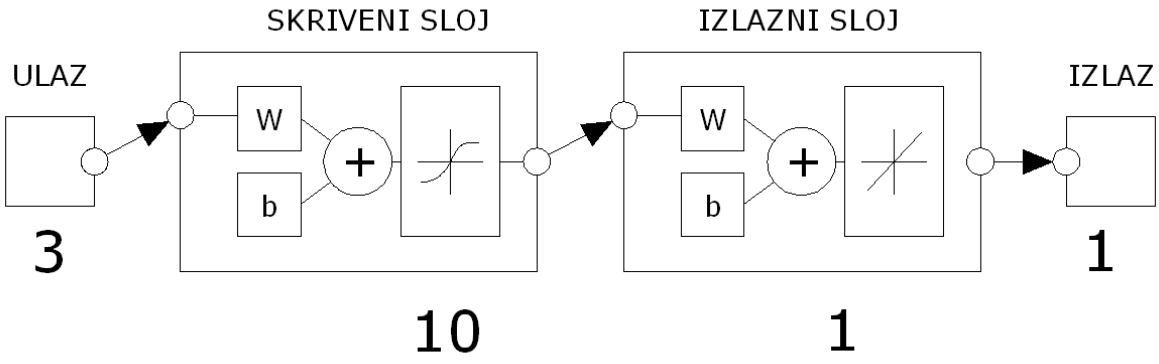


Slika 5.3 Grafički prikaz reziduala za višestruke linearne regresijske modele EC (1) i Tv (4) te izravna usporedba nepouzdanosti s ulaznim oborinama i vanjskom temperaturom.

Nadalje, potrebno je naglasiti kako u svim promatranim slučajevima nagle promjene praćenih parametara linearni višestruki regresijski model nije u stanju opisati te u tim slučajevima nastaju velike pogreške. Razdoblja s kišnim događajima manjeg intenziteta, samim time relativno i s malim promjenama unutar fizikalnog i kemijskog režima vode unutar jame, isti model dobro opisuje realno stanje na terenu.

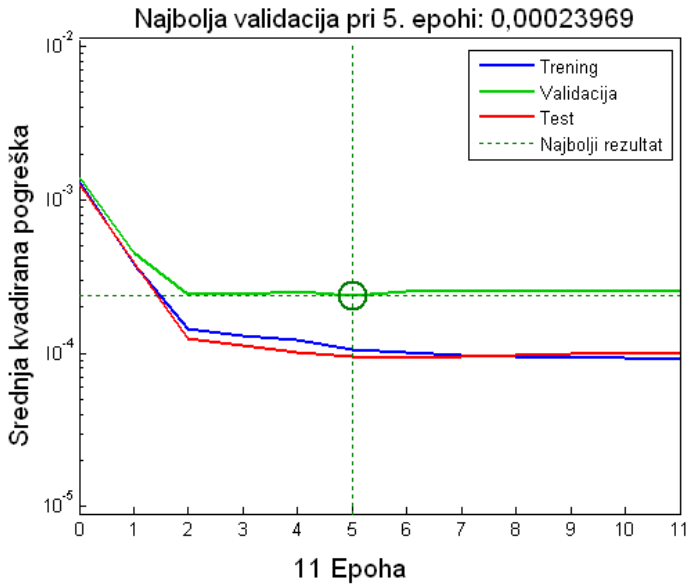
Kod modeliranja mjerenih parametara neuralnim mrežama mora se unaprijed definirati struktura mreže kojom se žele postići najbolji rezultati. Na primjeru parametara mjerenih u jami

Nevidna voda, za modeliranje serije neuralnim mrežama, odabran je model (1) opisan u tablici 5.1. Struktura neuralne mreže je prikazana na slici 5.4.



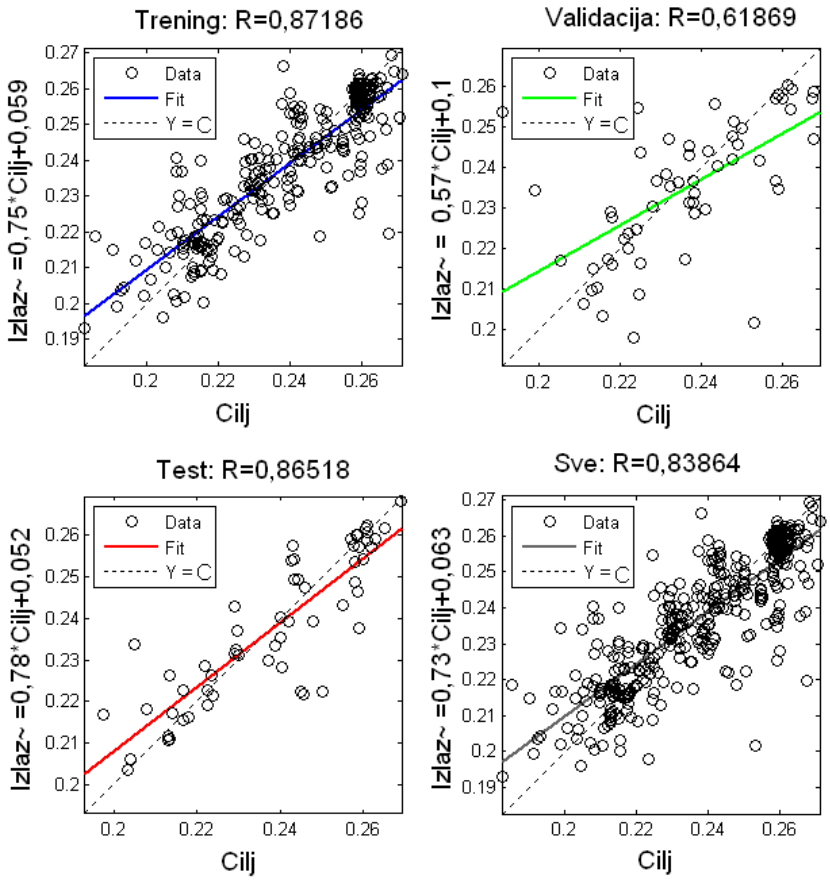
Slika 5.4 Dijagram feed forward MLP neuralne mreže za model EC unutar jame Nevidna voda s tri ulaza, 10 neurona unutar skrivenog sloja i jednim izlazom.

Najbolje performanse procesa validacije konstruirane mreže se dobiju kod 5. epohe treniranja mreže. Slika 5.5 prikazuje srednju kvadratnu grešku pri svakoj epohi za postupke treniranja, validacije i testiranja mreže.



Slika 5.5 Performanse treniranja neuralne mreže s prikazom standardne kvadrirane pogreške za feed forward MLP mrežu.

Nakon 11 epoha treniranja mreže, treniranje se u ovom slučaju prekida jer kod daljnjeg treniranja mreže, rezultati simulacije se ne poboljšavaju. Slika 5.6 prikazuje regresiju između ciljanih i simuliranih vrijednosti.

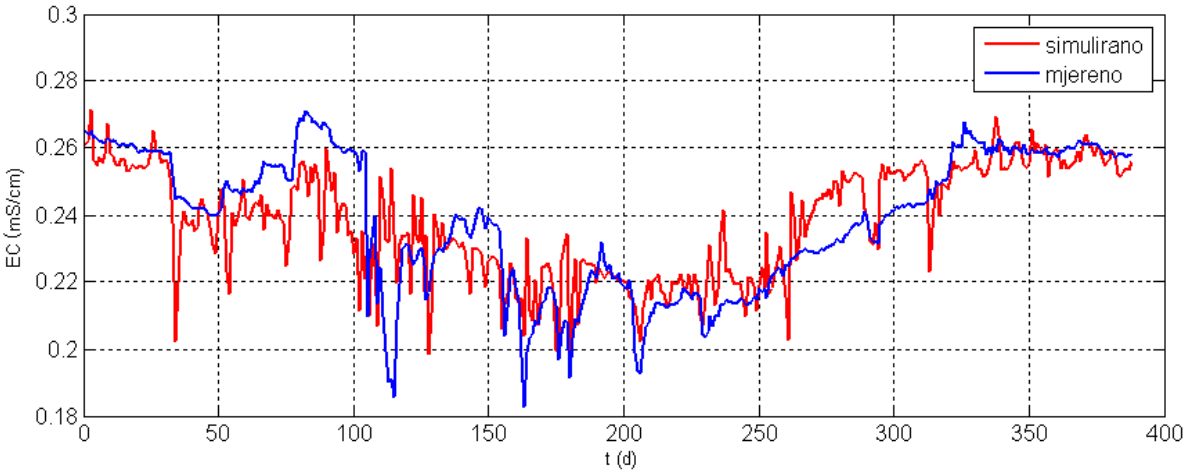


Slika 5.6 Regresijske veze između izlaza FF MLP neuralne mreže te vrijednosti ciljeva za trening, validaciju i testiranje mreže.

Na ovaj način istrenirana neuralna mreža može ponuditi predviđanje mjerenih parametara unutar jame na osnovu meteoroloških podloga. Slika 5.7 daje prikaz simuliranih i mjerenih podataka za vrijednosti EC, prikupljenih u razdoblju promatranja. Kao i kod linearnog višestrukog regresijskog modela, feed forward MLP neuralna mreža nije u stanju simulirati precizno ciljane parametre kod naglih promjena praćenih parametara. Najveća odstupanja kod modela se upravo događaju kod značajnih oborina tijekom vremena promatranja baš kao i kod višestrukog linearnog regresijskog modela.

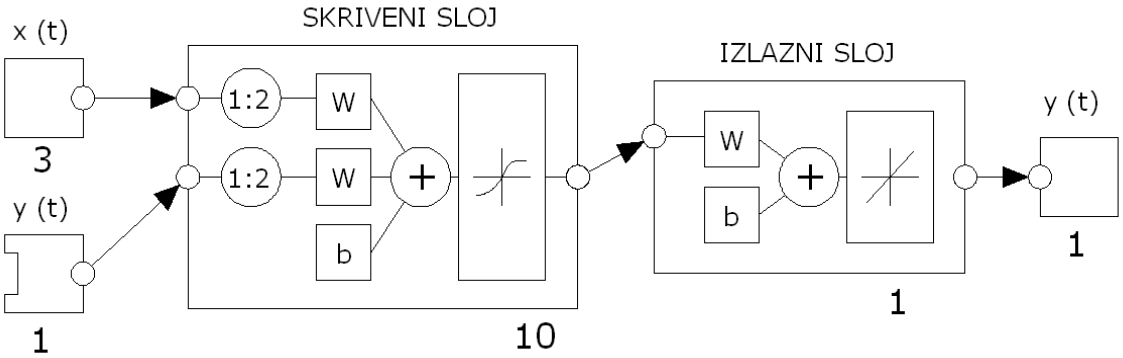
Poboljšanje modela može se dobiti primjenom neuralne mreže zasnovanoj na nelinearnom autoregresivnom modelu s egzogenim ulazom (Nonlinear AutoRegressive models with eXogenous Inputs –NARX). Kao što je već opisano u 3. poglavlju, NARX neuralne mreže imaju

formulaciju oblika y(t) = f(x(t), x(t-1),…x(t-d), y(t), y(t-1),…y(t-d)) gdje x(t) i y(t) predstavljaju vremenske serije ulaza i izlaza, f predstavlja mapiranje uspostavljeno višeslojnim perceptorom (MLP), a d zakašnjenje vremenskog koraka (delay).



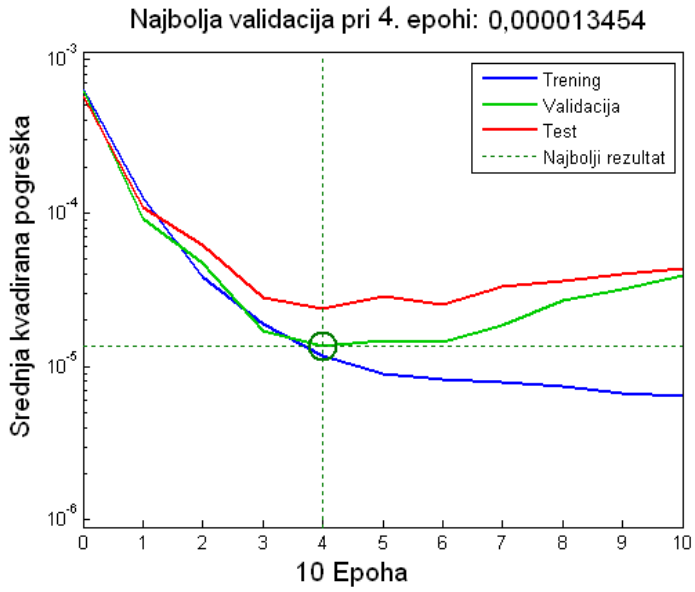
Slika 5.7 Grafički prikaz simuliranih i stvarnih (mjerenih) vrijednosti za model EC (1) na temelju feed forward MLP neuralne mreže.

Primjenom NARX neuralne mreže potrebno je unaprijed definirati vremensko kašnjenje d, koje u ovom primjeru iznosi 2 dana. U konačnici to znači da poznavanjem mjerenih podataka za prethodna dva dana unutar perioda praćenja, primjena NARX neuralne mreže može ponuditi znatno bolje rezultate. Struktura NARX neuralne mreže je prikazana na slici 5.8.

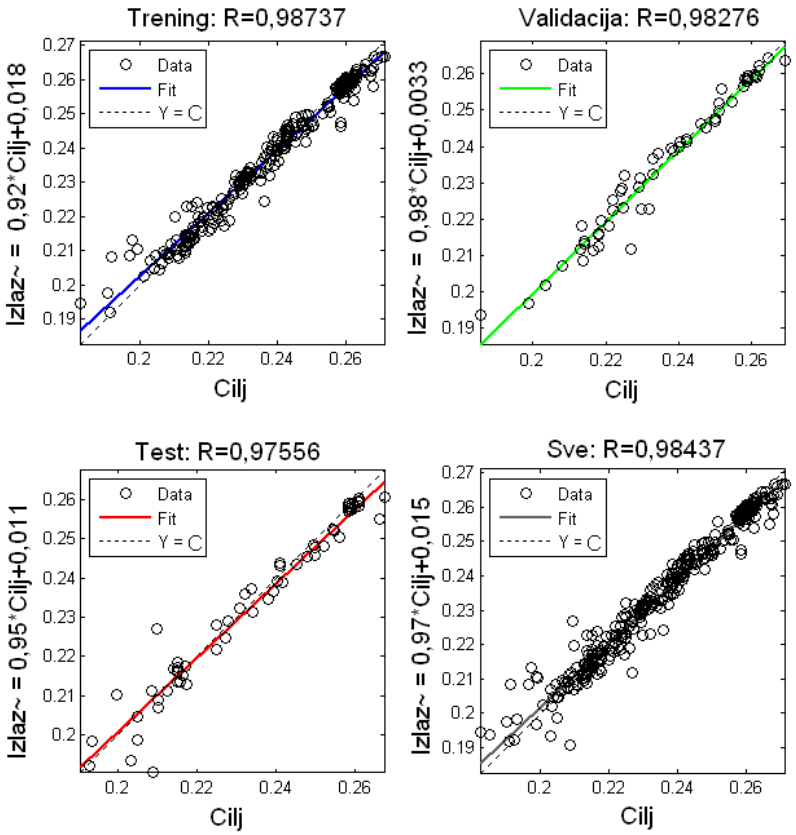


Slika 5.8 Dijagram NARX neuralne mreže za model EC u jami Nevidna voda s tri ulaza, zakašnjenjem d=2, 10 neurona unutar skrivenog sloja i jednim izlazom.

Za razliku od FF MLP neuralne mreže, NARX mreža kod 4. epohe postiže najbolje rezultate treninga, validacije i testiranja što je prikazano na slici 5.9. Svako dodatno treniranje ne doprinosi poboljšanju simulacije jer se događa slučaj kada mreža postaje pretrenirana.

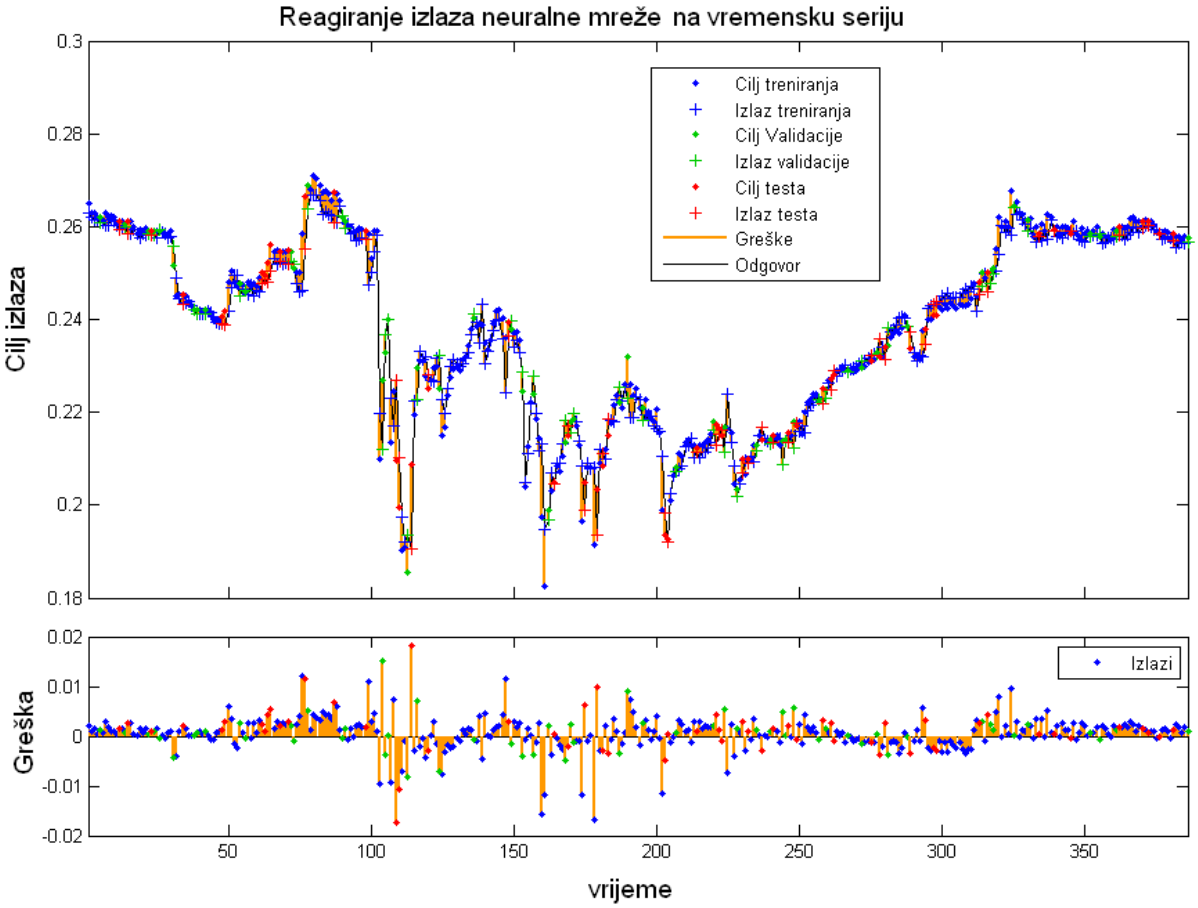


Slika 5.9 Performanse treniranja NARX neuralne mreže s prikazom standardne kvadrirane pogreške.



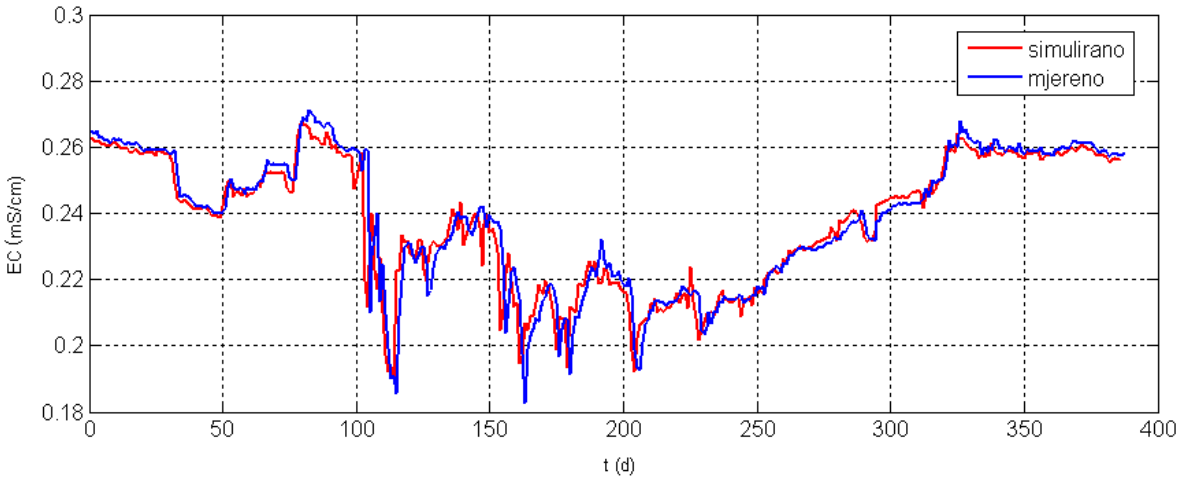
Slika 5.10 Regresijske veze između izlaza NARX neuralne mreže te vrijednosti ciljeva za trening, validaciju i testiranje mreže.

Prikaze sa slike 5.10 regresije između ciljanih i simuliranih vrijednosti kod procesa treninga, testiranja i validacije NARX neuralne mreže pokazuje značajna poboljšanja u odnosu na FF MLP mrežu. Slika 5.11 prikazuje reagiranje izlaza NARX neuralne mreže na vremensku seriju. Može se primijetiti da se i pri ovoj simulaciji maksimalne pogreške pojavljuju upravo kod velikih oborina zabilježenih na meteorološkoj postaji.



Slika 5.11 Reagiranje izlaza NARX neuralne mreže ma vremensku seriju s obzirom na ciljeve za procese treniranja, validacije i testiranja mreže.

Ipak, rezultati potvrđuju kako NARX neuralna mreža ima potencijal simuliranja nelinearnih dinamičkih sustava, kao što je to hidrodinamički odgovor duboke jame na vanjske meteorološke uvjete. To se temelji i na visokim korelacijskim koeficijentom procijenjenim za izmjerenu i simuliranu vremensku seriju (R>0,98). Na slici 5.12 su usporedno prikazane simulirane vrijednosti EC NARX neuralnom mrežom i izmjerena vremenska serija, prikupljene tijekom praćenja vadozne zone unutar jame Nevidna voda. Usporedi li se slika 5.7 sa slikom 5.12, dolazi se do zaključka kako su u ovom slučaju simuliranje vrijednosti puno bliže realnim.



Slika 5.12 Grafički prikaz simuliranih i stvarnih (mjerenih) vrijednosti za model EC (1) na temelju NARX neuralne mreže.

Višestruki linearni regresijski modeli kao i umjetne neuralne mreže mogu ponuditi način modeliranja hidrodinamičkog sustava speleološkog objekta. Svaki od prikazanih načina ima svoje mane i prednosti, a točnost modela uvelike ovisi o varijabilnosti ulaznih parametara što u ovom slučaju predstavljaju vrijednosti za oborine i temperaturu zraka. Ipak, prikazani rezultati ipak daju prednost umjetnim neuralnim mrežama zasnovanim na nelinearnom autoregresivnom modelu s egzogenim ulazom jer kod njihove primjene se postižu najbolji rezultati simuliranja vremenskih serija.

5.2. PROBABILISTIČKI PRISTUP MJERENJA PROTOKA NA CETINI

Kako bi se provelo mjerenje protoka probabilističkim pristupom, odabran je pogodni profil koji je omogućio ADCP i ADV mjerenje te mjerenje radarom s više profila uz dozvoljenu inklinaciju radarske zrake i horizontalnu devijaciju. To je bilo moguće na profilu Čikotina Lađa zbog neposredne blizine mosta, a činjenica da protok na tom profilu je uvijek poznat omogućila je validaciju rezultata. Pokusna mjerenja su vršena 27.07.2012. u vremenskom razmaku od dva sata.

Za određivanje geometrija profila korišten je ADCP, a za mjerenje maksimalne brzine na profilu korišten je ADCP i ADV uređaj. Slika 5.13 prikazuje fotografije odabrane lokacije na Cetini s naznačenim profilom mjerenja.



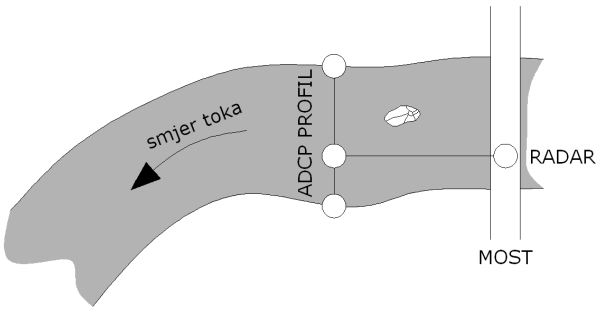
(a) (b)

Slika 5.13 Mjerenje protoka ADCP uređajem na lokaciji Čikotina Lađa

Vidljivo je iz slike 5.13a kako postoji kontrakcija poprečnog presjeka što kod mjerenja protoka sukladno ISO 748 i ISO 9196 čini ovaj odabir profila neprihvatljivim. Ipak, kako metode probabilističkog određivanja protoka mogu biti od velike pomoći kod ekstremnih hidroloških situacija kao što su izlijevanje toka te formiranje upravo novih kontrakcija presjeka i internih otoka.

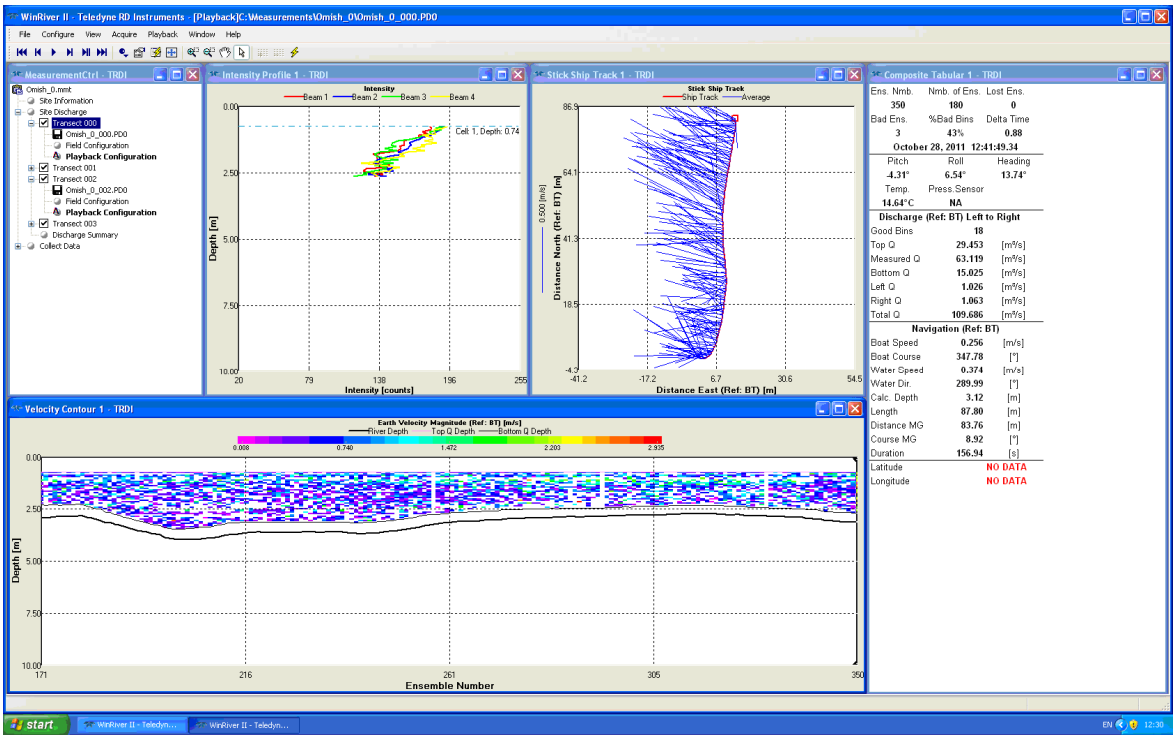
Za primjer određivanja protoka i geometrije ADCP uređajem, nategnuto je uže s jedne obale na drugu, a ADCP uređaj je pričvršćen za gumeni brod koji se upravo duž užeta kretao. Snimanje radarom se vršilo tako da se uređaj pomicao duž mosta i opažao sedam brzinski vertikala, to jest sedam površinskih brzina na određenoj stacionaži. Sam ADCP uređaj Workhorse Monitor zahtjeva eksterno napajanje što je postignuto s olovnim akumulatorom od 36 Ah i potrebnim

pretvaračem. Zbog ovakve konfiguracije napajanja, unutrašnjost brod s kojeg se mjeri, mora imati dovoljno prostora za smještaj mjeritelja, računala, napajanja i konstrukcije što nosi potopljeni transduktor. Shema izvođenja mjerenja prikazana je na slici 5.14.



Slika 5.14 Shema izvođenja mjerenja ADCP uređajem i radarom.

ADCP uređaj instantno šalje podatke prema povezanom računalu koje je zaduženo za procesiranje primljenih podataka. Kod Teledyne RD Workhorse ADCP uređaja, program koji procesira podatke zove se WinRiver. Slika 5.15 je prikaz zaslona tijekom mjerenja u programu WinRiver.



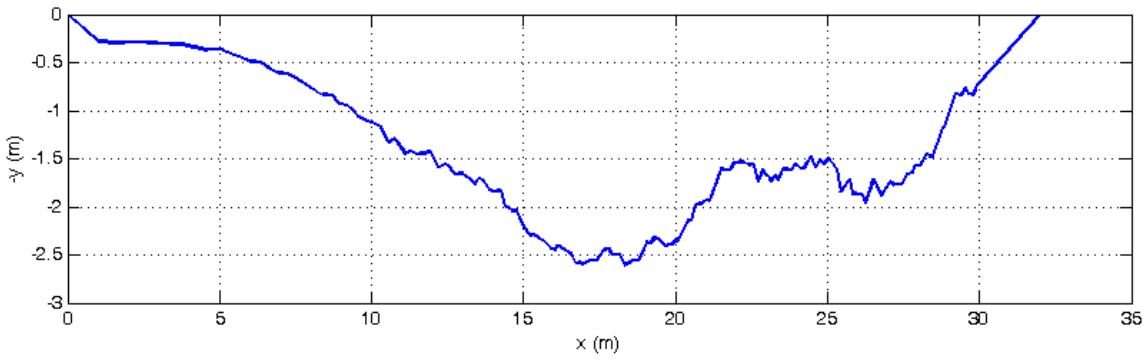
Slika 5.15 Prikaz zaslona pri mjerenju protoka ADCP uređajem (WinRiver Teledyne RD).

Tijekom mjerenja, snimatelj ima uvid u relativni položaj broda, brzinske vektore i stanje svake zvučne zrake zasebno. Na snimatelju je da odluči u kojem se trenutku podaci počinju bilježiti. Tablica 5.4 prikazuje tablični izvještaj snimanja protoka za profil Čikotina Lađa. On sadrži sve bitne informacije prikupljene tijekom mjerenja kao u i konačnu vrijednost protoka na cijelom profilu.

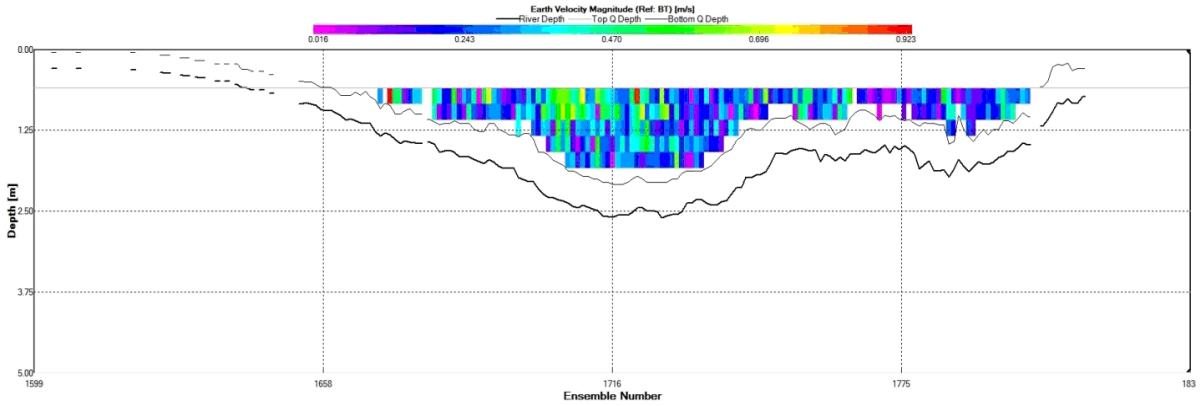
Tablica 5.4 Prikaz završnog izvještaja snimanja protoka ADCP uređajem (WinRiver Teledyne RD).

Station Number:			Meas. No: 0
Station Name: cikota6			Date: 07/27/2012
Party:	Width: 29.0 m	Processed by:	
Boat/Motor:	Area: 47.9 m²	Mean Velocity: 0.152 m/s	
Gage Height: 0.000 m	G.H.Change: 0.000 m	Discharge: 7.40 m³/s	
Area Method: Avg. Course	ADCP Depth: 0.100 m	Index Vel.: 0.00 m/s	Rating No.: 1
Nav. Method: Bottom Track	Shore Ens.:10	Adj.Mean Vel: 0.00 m/s	Qm Rating: U
MagVar Method: None (0.0°)	Bottom Est: Power (0.1667)	Rated Area: 0.000 m²	Diff.: 0.000%
Depth Sounder: Not Used	Top Est: Power (0.1667)	Control1: Unspecified	
		Control2: Unspecified	
		Control3: Unspecified	
Screening Thresholds:		ADCP:	
BT 3-Beam Solution: YES	Max. Vel.: 0.923 m/s	Type/Freq.: Workhorse/1200 kHz	
WT 3-Beam Solution: NO	Max. Depth: 2.68 m	Serial #: 14771	Firmware: 51.40
BT Error Vel.: 0.10 m/s	Mean Depth: 1.65 m	Bin Size: 25 cm	Blank: 25 cm
WT Error Vel.: 1.07 m/s	% Meas.: 30.76	BT Mode: 5	BT Pings: 1
BT Up Vel.: 0.30 m/s	Water Temp.: None	WT Mode: 1	WT Pings: 1
WT Up Vel.: 0.50 m/s	ADCP Temp.: 17.9 °C	WV : 175	
Use Weighted Mean Depth: YES			

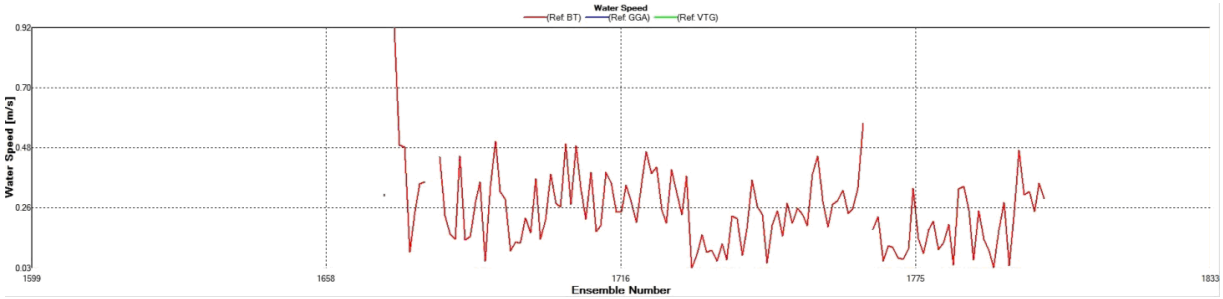
Na slikama 5.16, 5.17 i 5.18 prikazana je geometrija presjeka snimljena ADCP uređajem, profil brzina i srednje brzine.



Slika 5.16 Geometrija poprečnog presjeka snimljena ADCP uređajem (WinRiver Teledyne RD).



Slika 5.17 Profil brzina poprečnog presjeka snimljena ADCP uređajem (WinRiver Teledyne RD).



Slika 5.18 Srednje brzine po brzinskim vertikalama određene procesiranjem ADCP podataka (WinRiver Teledyne RD).

Zabilježeni protok na profilu iznosio je 7,40 m^3/s uz maksimalnu brzinu od 0,923 m/s. Biološki minimum koji se ispušta iza brane Prančević iznosi 8,0 m^3/s što se i poklapa s mjerenjima na profilu Čikotina Lađa. Bitno je naglasiti osnovne postavke mjerenja, a to su dimenzije mjernog segmenta (bin size) koji ima visinu od 25 cm, te temperaturu vode od 17,9°C o kojoj ovisi brzina propagirajućeg zvuka kroz vodu.

Kod mjerenja brzine radarom sukladno shemi prikazanoj na slici 5.13 odabrano je sedam brzinskih profila, tj. točaka na kojima se odredila površinska brzina. Raspored je utvrđen tako da se kontrakcija poprečnog presjeka uzela u obzir na način da su odabrana četiri točke lijevo od otoka, a tri točke desno od otoka. Iskolčenje stacionaža poprečnog presjeka i položaja mjernih točaka je izvedeno tako da su se na nategnuti konop naznačile upravo odabrane udaljenosti između brzinskih vertikala. Radarski uređaj je pozicioniran na 15 m udaljenom mostu te se preko optičkog ciljnika usmjeravala radarska zraka. Uz pomoć optičkog ciljnika odabire se željena lokacija na vodotoku s koje se površinska brzina mjeri. Tablica 5.5 prikazuje zapis s interne memorije radarskog uređaja koji sadrži u sebi vrijeme mjerenja, interval osrednjavanja, oznaku brzinske vertikale i izmjerenu brzinu. Pozicija brzinske vertikale se unosi manualno.

Tablica 5.5 Prikaz površinski brzina izmjerenih radarom za sedam brzinskih vertikala.

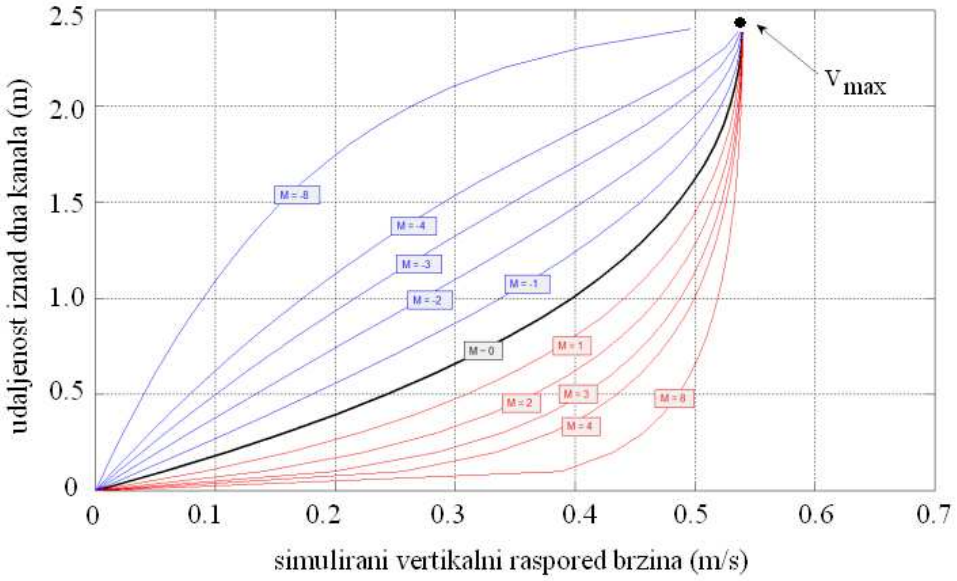
1				2			
Stacionaža: 5,0 m				Stacionaža: 7,5 m			
Vrijeme snimanja	Brzinska vertikala	Interval osrednjivanja (s)	Brzina v (m/s)	Vrijeme snimanja	Brzinska vertikala	Interval osrednjivanja (s)	Brzina v (m/s)
15:09	1	20	0,46	15:16	2	20	0,44
15:10	1	20	0,42	15:16	2	20	0,24
15:10	1	20	0,34	15:16	2	20	0,38
15:10	1	20	0,46	15:17	2	20	0,44
15:11	1	20	0,44	15:17	2	20	0,39
15:11	1	20	0,45	15:19	2	20	0,62
15:11	1	20	0,51	15:19	2	20	0,48
15:12	1	20	0,48	15:20	2	20	0,5
15:12	1	20	0,4	15:20	2	20	0,53
				15:20	2	20	0,54
Srednja vrijednost v (m/s):			**0,44**	Srednja vrijednost v (m/s):			**0,46**

3				4			
Stacionaža: 10,0 m				Stacionaža: 12,5 m			
Vrijeme snimanja	Brzinska vertikala	Interval osrednjivanja (s)	Brzina v (m/s)	Vrijeme snimanja	Brzinska vertikala	Interval osrednjivanja (s)	Brzina v (m/s)
15:23	3	20	0,43	15:28	4	20	0,51
15:24	3	20	0,62	15:28	4	20	0,4
15:24	3	20	0,56	15:29	4	20	0,37
15:24	3	20	0,51	15:29	4	20	0,45
15:25	3	20	0,58	15:29	4	20	0,48
				15:30	4	20	0,44
				15:30	4	20	0,49
Srednja vrijednost v (m/s):			**0,54**	Srednja vrijednost v (m/s):			**0,45**

5				6			
Stacionaža: 20,0 m				Stacionaža: 22,5 m			
Vrijeme snimanja	Brzinska vertikala	Interval osrednjivanja (s)	Brzina v (m/s)	Vrijeme snimanja	Brzinska vertikala	Interval osrednjivanja (s)	Brzina v (m/s)
15:32	5	20	0,44	15:37	6	20	0,36
15:33	5	20	0,3	15:37	6	20	0,45
15:33	5	20	0,26	15:37	6	20	0,29
15:33	5	20	0,25	15:38	6	20	0,32
15:34	5	20	0,32	15:38	6	20	0,29
15:34	5	20	0,45	15:38	6	20	0,42
15:34	5	20	0,41	15:39	6	20	0,45
				15:39	6	20	0,31
				15:39	6	20	0,36
Srednja vrijednost v (m/s):			**0,35**	Srednja vrijednost v (m/s):			**0,36**

7			
Stacionaža: 25,0 m			
Vrijeme snimanja	Brzinska vertikala	Interval osrednjivanja (s)	Brzina v (m/s)
15:41	7	20	0,3
15:41	7	20	0,36
15:43	7	20	0,26
15:43	7	20	0,31
15:43	7	20	0,4
Srednja vrijednost			**0,33**

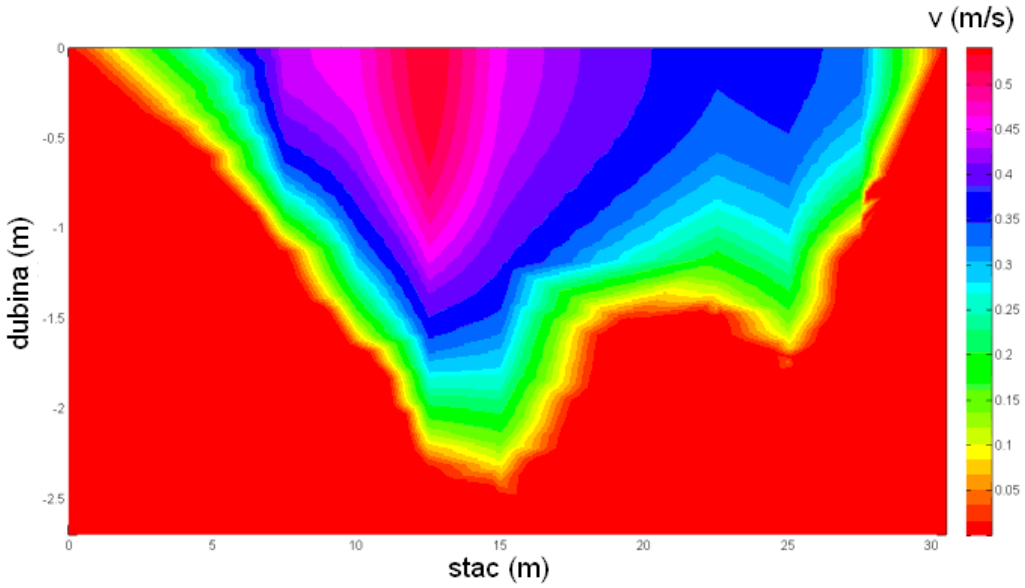
Kod probabilističkog pristupa određivanja protoka, osnovna zadaća je u određivanju parametra entropije M, kao što je to i opisano u 3. poglavlju. Kako kod ovog mjerenja nije bilo višegodišnjeg zapisa koji bi odredio maksimalnu i srednju brzinu na odabranom profilu. Korišteni su podaci dobiveni in situ mjerenjima ADCP i ADV uređajem. Slika 5.19 nudi prikaz mijenjanja brzinskog profila prema ovisnosti o odabranom parametru entropije M za maksimalnu brzinu izmjerenu radarom od 0,54 m/s i pripadajućoj dubini od 2,48 m.



Slika 5.19 Srednje brzine po brzinskim vertikalama određene procesiranjem ADCP podataka (WinRiver Teledyne RD).

Za maksimalnu brzinu od 0,923 m/s izmjerenu ADCP uređajem kao i srednju brzinu na profilu od 0,152, Φ(M) se određuje deterministički što dovodi do znatnih nedostataka pri proračunu. Ipak, u nedostatku dugogodišnjih nizova, određeni parametar M na osnovu ADCP mjerenja nudi način za određivanje raspodjele brzina po vertikali na osnovu površinske brzine.

Ako se raspored brzina po vertikali prostorno interpolira na cjelokupni presjek (linearna interpolacija) gdje geometrija profila ujedno predstavlja i nulte vrijednosti brzine (v_{dno} = 0 m/s), ploha koja se na takav način dobije preko cijelog presjeka ujedno definira i raspored izotaha. Određivanje volumena ispod takve plohe predstavlja vrijednost protoka. Kod unaprijed definirane mreže s rezultatima brzina potrebno je izvršiti numeričku integraciju plohe prema već definiranim Δx i Δy dimenzijama. Rezultati integracije predstavljaju protok prema metodi srednjeg presjeka. Rezultat linearne interpolacije vertikalnih brzina na cjelokupan presjek prikazane su u slici 5.20.



Slika 5.20 Raspored brzina na cjelokupnom poprečnom presjeku prema probabilističkom pristupu određivanja vertikalnog rasporeda i linearne interpolacije rezultata.

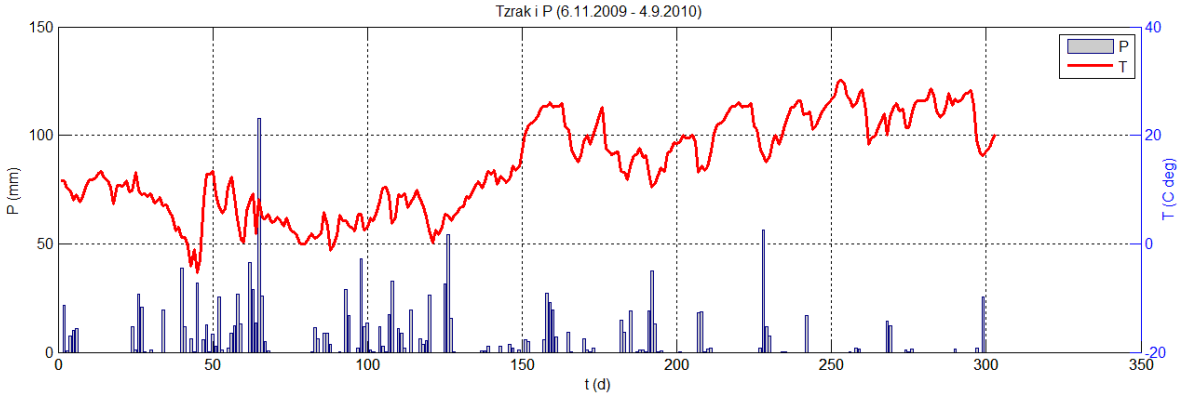
Za mrežu $\Delta x = 0{,}01$ i $\Delta y = 0{,}01$ m ukupni protok dobiven kao volumen ispod interpolacijske plohe iznosi: $Q = 7{,}7036$ m^3/s. Usporedi li se taj rezultat s izmjerenim protokom ADCP uređajem, može se odrediti relativna pogreška koja iznosi 3,94 % što predstavlja značajan rezultat u smislu točnosti mjerenja..

Rezultati usporednih mjerenja hidroakustikom i radarskim uređajem na otvorenom vodotoku su potvrdili potencijal primjene probabilističke metode određivanja protoka. Kako se za potrebe ovog eksperimenta uveo odabir i dodatnih brzinskih vertikala kao novina pri proračunu u kontrahiranom presjeku, dobiveni rezultati ohrabruju i potvrđuju metodu kako u znanstvenom, tako i u ekonomskom pogledu.

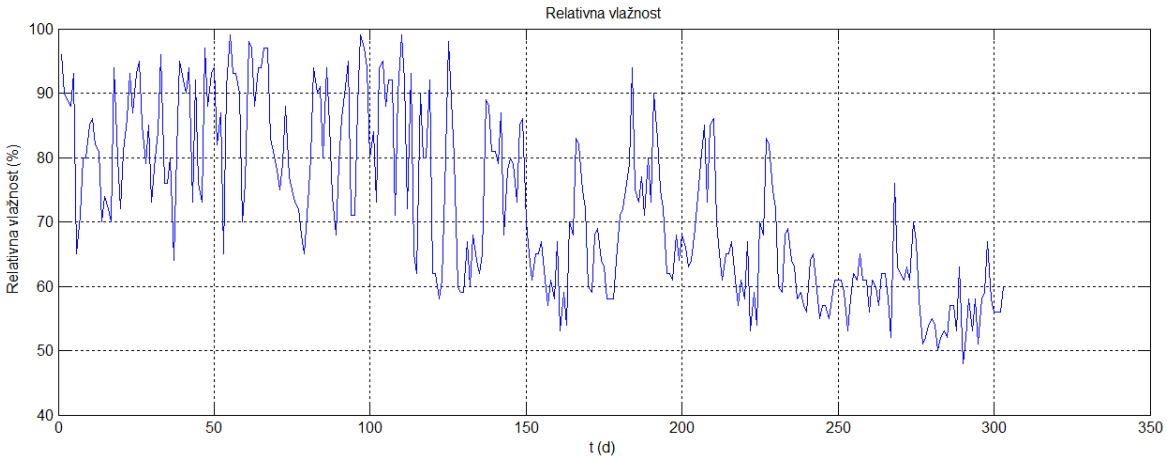
5.3 HIDROLOŠKA I GEOMORFOLOŠKA MJERENJA NA MODROM I CRVENOM JEZERU KOD IMOTSKOG

Terenska istraživanja vezana za Modro jezero su se zasnivala od tri komponente: prikupljanje meteoroloških podataka, prikupljanje fizikalno kemijskih podataka vode jezera te geodetsko snimanje jezera.

Prvi dio terenskog istraživanja zasniva se na službenim podacima DHMZ-a za klimatološku meteorološku postaju Imotski (N 43°27'; E 17°13') na nadmorskoj visini od 435 m n. m. Podaci sačinjavaju srednje dnevne temperature zraka, relativnu vlažnost zraka, te oborine na navedenoj postaji. Slika 5.21 i 5.22 prikazuju srednje dnevne temperature zraka, oborine te relativnu vlažnost za promatrano razdoblje od 6.11.2009. do 4.9.2010.



Slika 5.21 Prikaz srednjih dnevnih temperatura Tzrak i dnevnih oborina P za promatrano razdoblje.



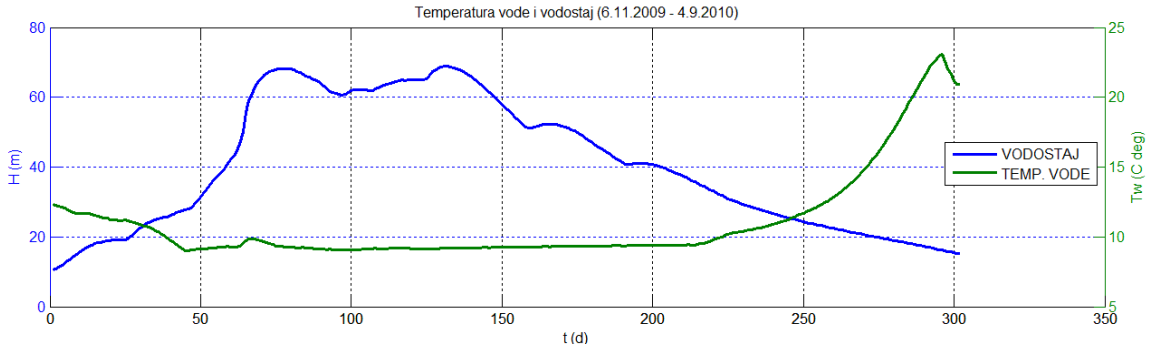
Slika 5.22 Prikaz relativnih dnevnih vlažnosti zraka RELH za promatrano razdoblje.

Drugi dio istražnih radova sastojao se u instaliranju CTD divera (Schlumberger Water Services) na dno jezera (241,6 m n. m.). Uređaj je montiran na betonsko postolje, kontrolirano je potopljen te je prikupljao podatke u razdoblju od 6. studenog 2009. g. u 22 h i 26 min. do 4. rujna 2010. g. u 3 sata i 26 min. (ukupno 7.230 satnih podataka ili 302 kompletnih dnevnih podataka). Slika 5.23 prikazuje instaliranje CTD divera na dno Modrog jezera.

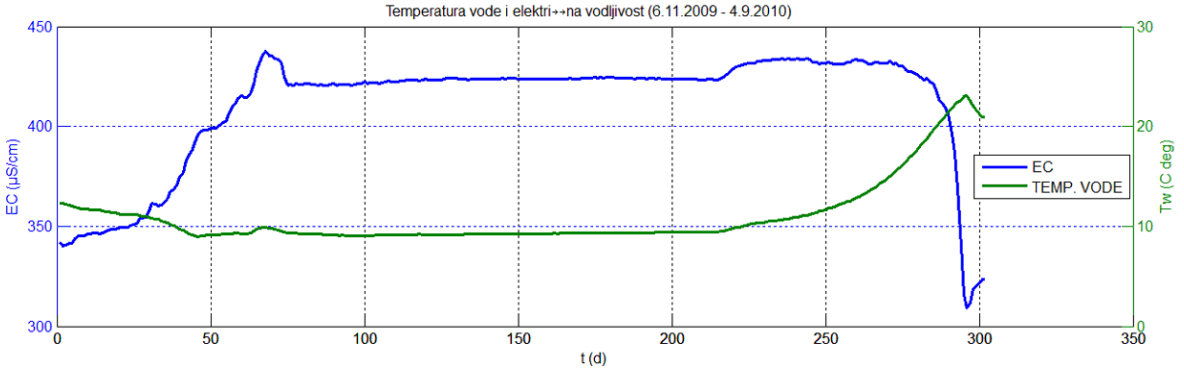


Slika 5.23 Instaliranje CTD divera na dno jezera (06.11.2009.) na dno Modrog jezera.

Mjereni su sljedeći parametri: 1) Dubina vode, H; 2) Temperatura vode, Tvoda; 3) Električna vodljivost, EC. Slike 5.24 i 5.25 prikazuju vremenske serije prikupljenih podataka.



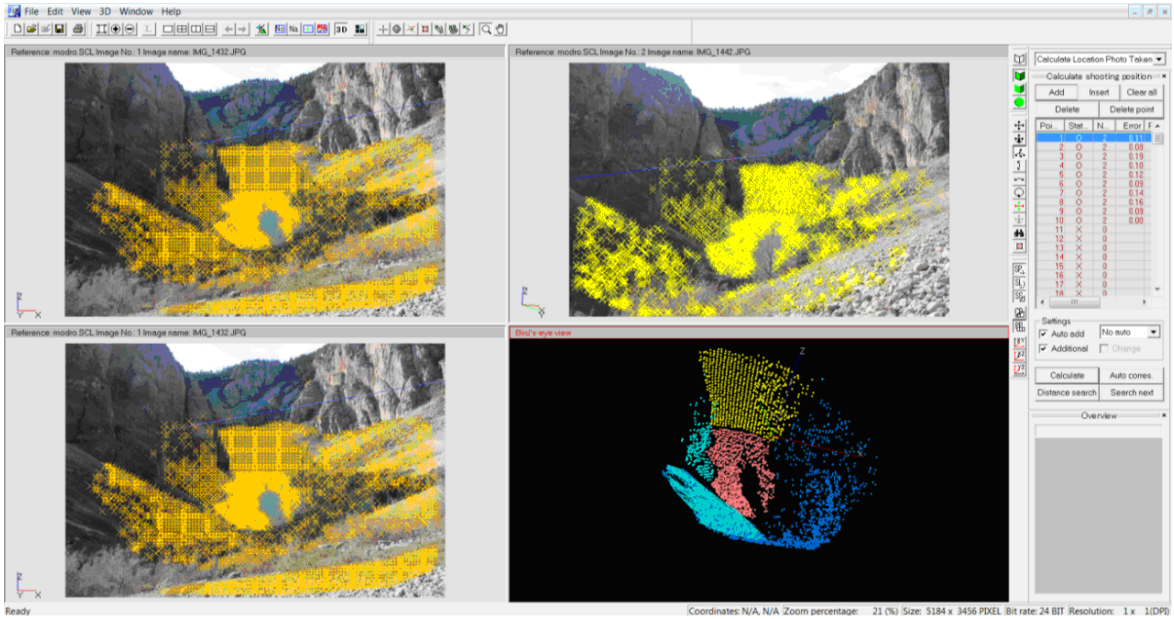
Slika 5.24 Prikaz srednjih dnevnih temperatura vode Tw i srednjih dnevnih vodostaja H.



Slika 5.25 Prikaz srednjih dnevnih temperatura vodeTw i električne vodljivosti vode EC.

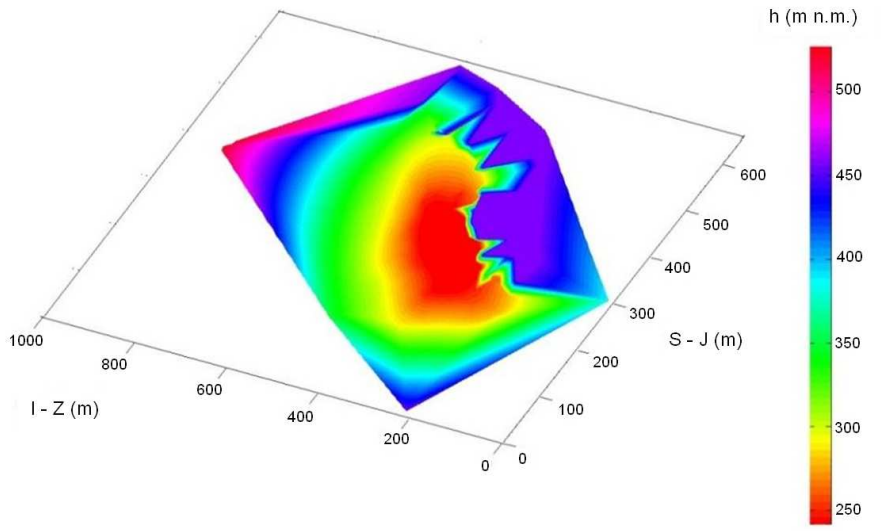
Mora se napomenuti da su podaci točkasti, to jest da se odnose na konstantno mjerenje temperature vode i EC vrijednosti u jednoj točki.

U posljednjoj fazi terenskih istraživanja, pristupilo se izrađivanju računalnog geometrijskog modela jezera. U tu su svrhu izvođeni terenski geodetski radovi snimanja s totalnom stanicom te fotogrametrijska mjerenja. Geodetskim snimanjem iz 2011. g. utvrđena je kota dna Modrog jezera na 241.6 m n. m. Pred više od pedeset godina izmjerena je kota dna [P1] od 239,0 m n. m., dakle niža za oko 2,6 m od utvrđene. Ovu značajnu razliku u kotama dna moguće je objasniti pogreškom pri mjerenju i/ili procesom zatrpavanja jezera nanosom tijekom posljednjih pedesetak godina. To potvrđuje i činjenica da su sa sjeverne strane padinski procesi i dalje aktivni. S južne su se strane isti procesi počeli jače uočavati tek nakon potresa 29. prosinca 1942. [U1]. Geodetsko snimanje korišteno je u svrhu kalibriranja fotogrametrijskog mjerenja. Pri tom je upotrijebljen komercijalni sustav sačinjen od softverskog paketa KURAWES-2G i stereo fotografija načinjenih digitalnom SLR kamerom [K3]. Slika 5.26 prikazuje obradu stereo snimka uz pomoć KURAWES-2G programa.



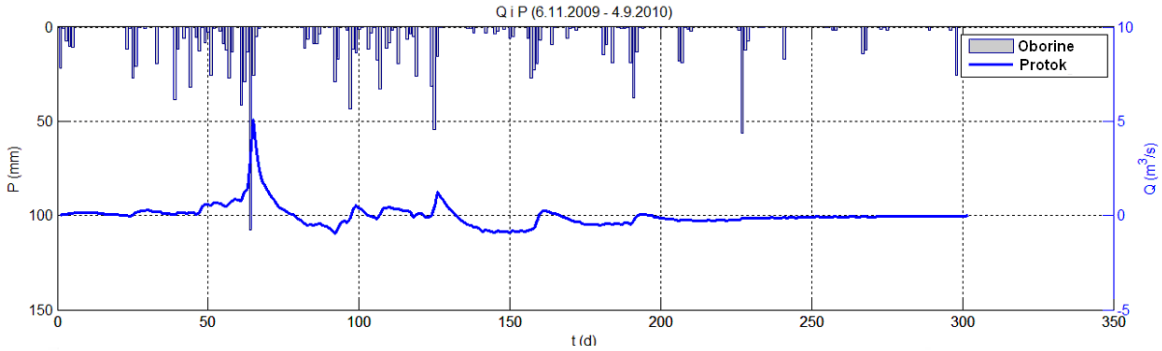
Slika 5.26 Fotogrametrijska obrada podataka u računalnom programu KURAWES-2G.

Krajnji rezultat posljednje faze terenskih mjerenja računalni je model geometrije jezera koji služi za određivanje srednjih dnevnih protoka i istjecanja u jezero, temeljenih na nizu zapisanih razina vode. Slika 5.27 daje računalni model geometrije Modrog jezera. Takav model omogućava vrlo precizno određivanje morfometrije jezera.



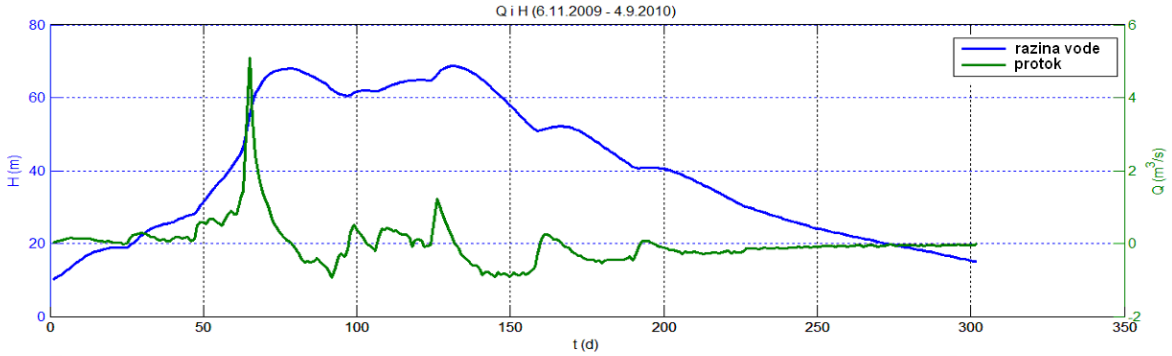
Slika 5.27 Računalni model geometrije Modrog jezera.

Model geometrije jezera korišten je kako bi se odredile razlike zapremine jezera, a samim time i otjecanje, odnosno dotjecanje u jezero. Hidrogram Modrog jezera i oborine zabilježene na meteorološkoj postaji Imotski prikazani su na slici 5.28.



Slika 5.28 Hidrogram Modrog jezera s korespondirajućim oborinama za promatrano razdoblje.

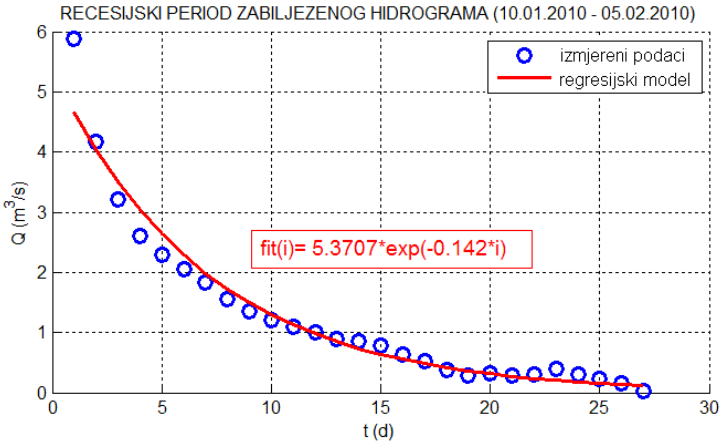
Iz slike 5.28 može se zaključiti da dotok u jezero reagira u većini slučajeva na oborine pale unutar sliva, osim u sušnim periodima. Također se vidi da sustav punjenja jezera većim dijelom ovisi o kretanju podzemnih voda. Na slici 5.29 prikazani su usporedno hidrogram i nivogram za Modro jezero. Temeljem slike 5.28 i slike 5.29 može se primijetiti da reagiranje dotjecanja u jezero puno više ovisi o oborinama kada je razina vode u jezeru veća od 35 m. Kad je razina manja od 35 m, razina vode u jezeru ovisi o podzemnim vodama.



Slika 5.29 Hidrogram Modrog jezera s korespondirajućim nivogramom za promatrano razdoblje.

Zapažanja na osnovi mjerenih podataka mogu olakšati modeliranje promatranog hidrološkog sustava, no mnoštvo potrebnih parametara i dalje ostaje nepoznato. Krški sustav možemo promatrati u hidrološkom smislu kao otvoreni sustav omeđen rubovima sliva te s ulazom, prolazom/zadržavanjem i izlazom vode. Određivanje granica sliva u kršu predstavlja iznimno tešku zadaću koja zahtijeva mnoge istražne radove (trasiranje, bušenje piezometara, hidrometrijske i hidrogeološke istražne radove). Jedan od osnovnih parametara kod hidrološkog modeliranja je površina sliva A, koja u slučaju Modrog jezera nažalost nije poznata.

Pri modeliranju hidrološkog režima Modrog jezera i simuliranja otjecanja iz jezera i dotjecanja u jezero potrebno je poznavanje koeficijenta recesije α što je vidljivo iz opće jednadžbe rješenja za sustav linearnog rezervoara prikazanoj u jednadžbi (3.40).

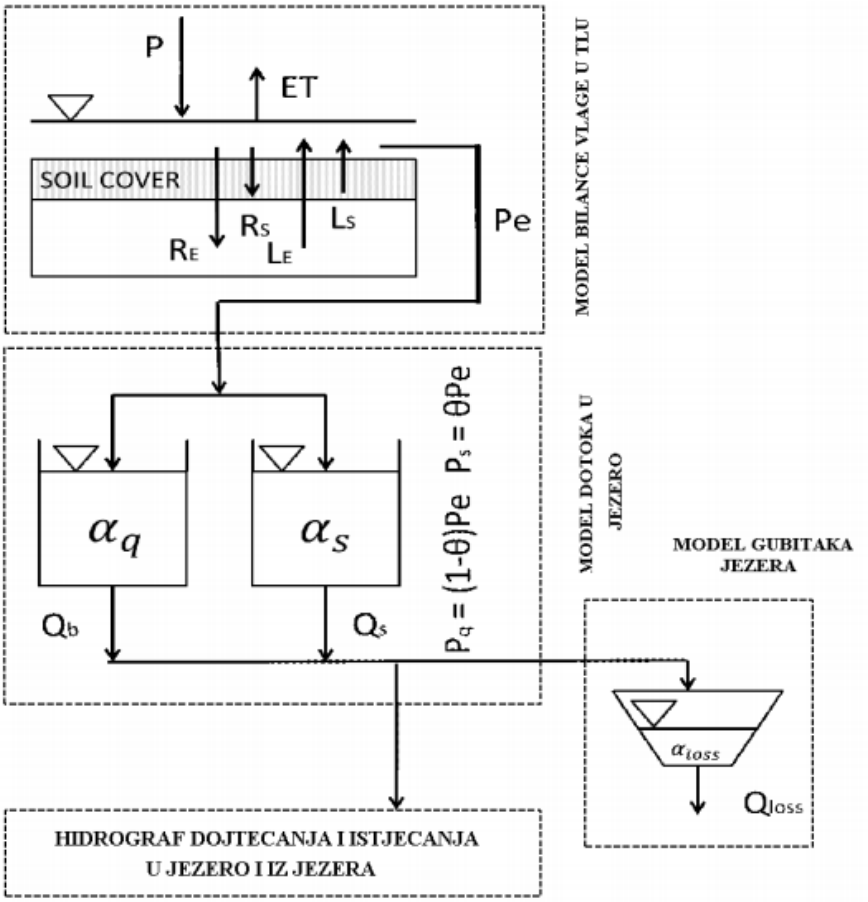


Slika 5.30 Recesijski period hidrograma s regresijskim modelom.

U literaturi su poznate mnoge metode koje određuju koeficijent recesije α [P7], no u ovom slučaju gdje je poznat hidrogram za jednu hidrološku godinu pruža se mogućnost interpoliranja linearnog regresijskog modela na recesijskom dijelu hidrograma eksponencijalnog oblika

prikazanog na slici 5.30. Izraz odabranog oblika dobije se metodom najmanjih kvadrata, a eksponent u jednadžbi predstavlja koeficijent recesije α u jedinici 1/d.

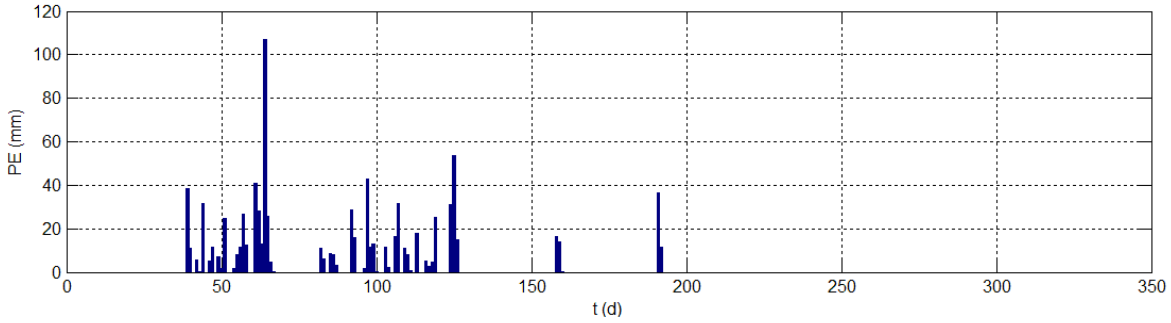
Model Modrog jezera karakteriziraju komponente brzog i sporog otjecanja te izravnih gubitaka iz jezera. Shematski prikaz tipa odabranog modela sa slike 5.31 sastoji se od dva paralelno spojena rezervoara. Linearni rezervoari u modelu simuliraju brzu i sporu komponentu otjecanja, a nelinearni rezervoar za simuliranje gubitaka iz jezera serijski je spojen na komponente brzog i sporog otjecanja. Efektivne oborine su dobivene modelom vlage u tlu prema Palmerovoj metodi. Parametar Θ predstavlja omjer brzog i sporog otjecanja te je predmet kalibracije modela.



Slika 5.31 Konceptualni hidrološki modeli Modrog jezera.

Problem pojavljivanja vrhova u hidrogramu kroz sušno razdoblje veže se uvijek za modeliranje efektivne oborine PE. Palmerova metoda upravo razlaže komponente bilance na prihranjivanje vodonosnika R i efektivnu oborinu PE te omogućuje vjernije modeliranje otjecanja

u sušnom razdoblju. Slika 5.32 predstavlja upravo modeliranu efektivnu oborinu prema Palmerovoj metodi.



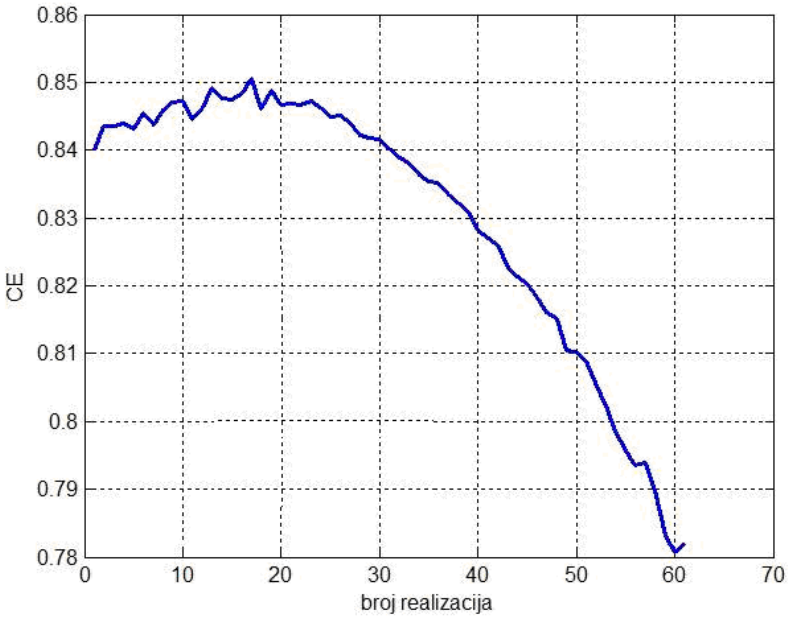
Slika 5.32 Efektivne oborine prema Palmeru za vrijednosti S1MAX = 1,0; S2MAX = 200,0; S1FST = 0,1 i S2FST = 66,5 (mm).

Matematički model je konstruiran prema konceptualnom modelu prikazanom na slici 5.31 sa svojim parametrima je podložan kalibraciji. U prvoj je varijanti transformacija bruto oborine provedena u efektivnu linearno s koeficijentom otjecanja (C = 0,5). Koeficijent efikasnosti, opisan u 3. poglavlju izrazom (3.42), prikazan je kao funkcija ovisna o parametrima modela i broju simulacija. Preko globalnog maksimuma funkcije odabiru se idealni parametri te se na taj način kalibrira cjelokupni model. Sljedeći parametri modela se kalibriraju preko koeficijenta efikasnosti:

- A - površina sliva
- ALAKE - površina koja doprinosi gubicima jezera
- ALPHAR - koeficijent recesije za brzo otjecanje
- ALPHAS - koeficijent recesije za sporo otjecanje
- ALPHAL - koeficijent recesije za gubitke iz jezera
- Θ - težinski parametar za odnos brzog i sporog otjecanja
- S1MAX- maksimalna vlaga u gornjem sloju tla
- S2MAX – maksimalna vlaga u donjem sloju tla
- S1FST- početna vlaga u gornjem sloju tla
- S2FST – početna vlaga u donjem sloju tla

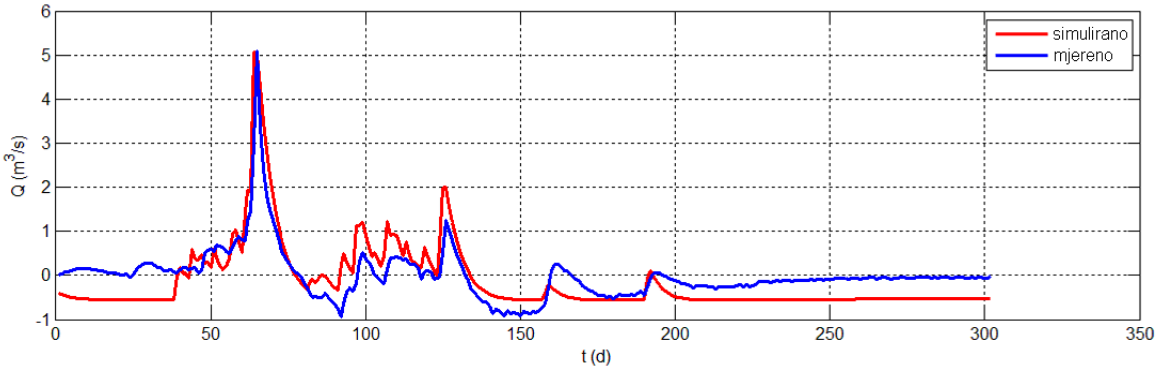
Funkcija koeficijenta efikasnosti ima svoj globalni maksimum, kao što je to prikazano na slici 5.33, za vrijednosti parametara: A = 37 km^2 i efektivnom oborinom za vrijednosti S1MAX =

2 mm, S2MAX = 200 mm, S1FST= 1 mm i S2FST = 100 mm. Osjetljivost modela na ostale parametre nije značajna s usporedbom na navedene.



Slika 5.33 Ovisnost CE koeficijenta o broju realizacija definiranim različitim vrijednostima parametara modela podložnim kalibraciji.

Slika 5.33 prikazuje vrijednosti simulirane modelom, usporedno s mjerenim rezultatima. Vidljivo je da simulirane vrijednosti puno bolje prate stvarno stanje za vrijeme kišne sezone. U recesijskom dijelu nastaju puno veće razlike što upućuje na dodatna prihranjivanja vodonosnika.



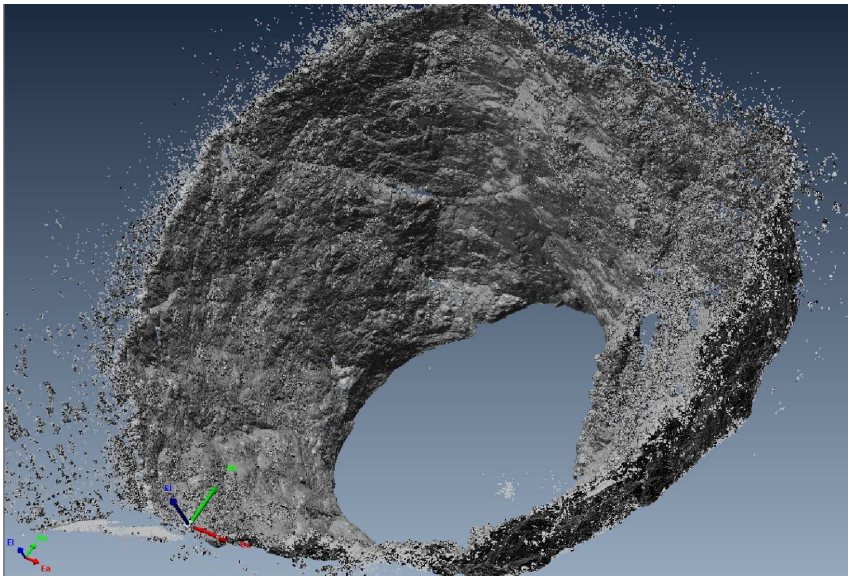
Slika 5.34 Simulirani i zabilježeni hidrogram s gubicima generiranim modelom nelinearnog rezervoara i efektivnim oborinama PE modeliranim Palmerovim postupkom.

Model Modrog jezera se ne može zasebno promatrati odvojeno od Crvenog jezera koje je u neposrednoj blizini. No kod pokušaja usporednih mjerenja, CTD diver instaliran u Crveno jezero

je pretrpio nepopravljivo oštećenje tako da su mjereni podaci izgubljeni. Drugi uređaj je naknadno instaliran u rujnu 2013. godine s memorijom i baterijom kapacitiranima na tri godine samostalnog rada.

Izrada neophodnog računalnog modela geometrije Crvenog jezera znatno je zahtjevnija zadaća nego je to bio slučaj kod Modrog jezera. Prilikom najnovijih hidroloških i geomorfoloških istraživanja Crvenoj Jezera kod Imotskog korištene su nove tehnologije temeljene na LiDAR (Light Detection And Ranging) metodi i hidroakustici. Kako bi se odredio računalni model geometrije Crvenog jezera za dio iznad razine vode jezera, upotrijebljen je terestrialni 3D laserski skener (TLS) s unaprijed zadanom rezolucijom od 30 x 30 cm.

Kao rezultat snimanja TLS uređajem, dobio se kao konačni set podataka „oblak točaka“ gdje svaka točka ima definiranu poziciju u prostoru. Brojna računalna rješenja nude mogućnosti manipulacije s oblakom točaka kako bi se dobile i obradile potrebne informacije iz prikupljenih podataka. Da bi model bio što vjerodostojniji, oblak točaka se filtrira s obzirom na očite greške i buku. Podaci prikupljeni Lidar metodom daju precizan digitalni elevacijski model koji se dalje može koristiti u dodatnim analizama i modeliranju. Slika 5.35 prikazuje model „oblak točaka“ za površinski dio Crveno jezera.



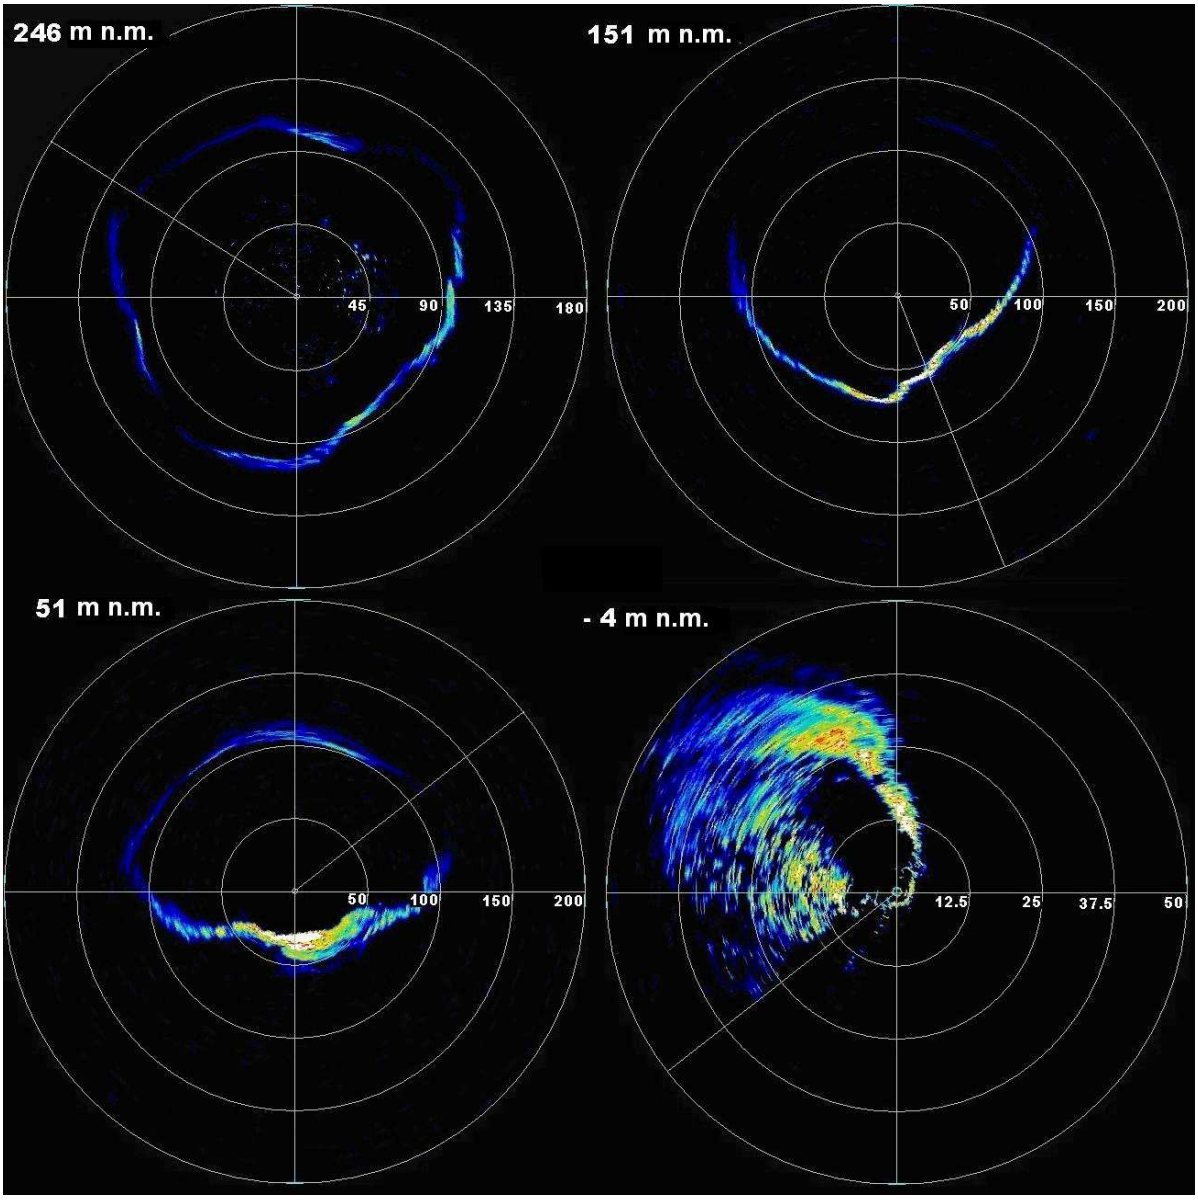
Slika 5.35 Oblak točaka s rezolucijom 30 x 30 cm u vektorskom prostoru (snimak načinjen TLS uređajem) što predstavlja 3D model Crvenog jezera iznad razine vode.

Za potrebe snimanja pod vodom jezera korištena je ronilica na daljinsko upravljanje - ROV (Remotely Operated Vehicle) opremljena sa kamerom HD rezolucije, preciznim kompasom i žiroskopom te sonarom za hidroakustička snimanja (slika 5.36).



Slika 5.36 ROV ronilica SEAEYE FALCON korištena za profiliranje dna Crvenog jezera.

Kota površine vode pri istražnim radovima te potrebne točke za vezivanje relativnog koordinatnog sustava u globalni model, snimljene su totalnom stanicom. Vodostaj na dan istraživanja je snimljen na koti od 251 metara nad morem. Sam ROV precizno mjeri dubinu zarona i geometriju horizontalnog presjeka dna u sfernim koordinatama. Slika 5.37 prikazuje četiri zasebne snimke načinjene hidroakustičnim uređajem smještenim na ROV-u pri različitim dubinama. Radna frekvencija sonara iznosi 670 kHz, a snaga odaslanog signala 23 dB. Takva konfiguracija uređaja pri idealnim uvjetima jamči registriranje odjeka pri udaljenostima i do 600 m. Snaga odjeka je prikazana rasponom boja od crvene prema ljubičastoj gdje se crvenom prikazuje najjači odjek, a ljubičastom najslabiji. Na odjek mogu utjecati različiti čimbenici kao što su temperatura vode, gustoća, suspendirane čestice, udaljenost izvora od snimanog objekta, kut pod kojim zvuk dolazi do prepreke te gustoća materijala od kojeg se zvuk odbija. Na primjeru slike 4, može se vidjeti da je kod kote 246 m n.m. (dubina zarona od 5 m) odjek snimljen preko cijelog horizontalnog presjeka jezera s relativno slabim povratnim signalom što se može pripisati velikom operativnom radijusu, nepravilnim stjenkama jezera te različitoj gustoći materijala od kojeg su rubovi jezera sačinjeni. Snimljeni odjek na koti 151 m n.m. pak registrira nedostatak povratnog signala na sjeveroistočnoj strani jezera što se može protumačiti na više načina. Jedno od objašnjenja može biti pretpostavljena pozicija krškog provodnika koji zbog sjene ne odašilje povratni signal. No ipak treba biti oprezan s zaključivanjem o iznesenim pretpostavkama jer nedostatak povratnog signala može ležati u refrakciji zvučnih valova uslijed geometrije stjenke i rasipanja zvučnog intenziteta uslijed karakteristika materijala.



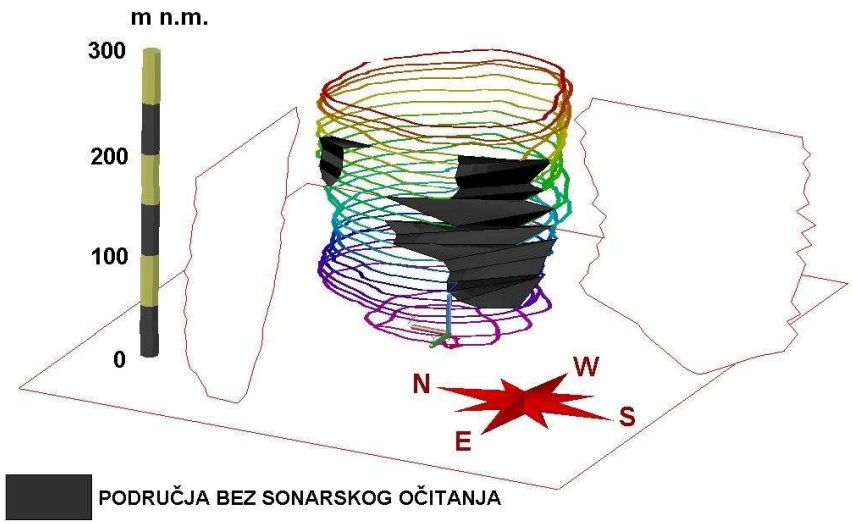
Slika 5.37 Karakteristične snimke horizontalnog sonarskog profiliranja Crvenog jezera načinjene na različitim dubinama zarona.

Daljnja geomorfološka istraživanja Crvenog jezera trebaju svakako ići u tom smjeru kako bi se rasvijetlio opisani nedostatak odjeka pri hidroakustičnim snimanjima na sjeveroistočnoj strani jezera. Ipak, slika 5.37 nudi odgovor na oblik dna jezera jer je vidljivo da na koti od -4 m n.m., dno jezera poprima elipsasti oblik s dimenzijama 20 x 10 m. Obilje registriranog odjeka sugerira na sužavanje dna uslijed urušenog materijala što je potvrđeno i načinjenim snimkama uz pomoć instalirane kamere HD rezolucije na samoj ronilici. Kamera ujedno odaje i prisutnost urušenog materijala uslijed antropogenih utjecaja te potvrđuje glasine kako se Crveno jezero godinama koristi kao ilegalno odlagalište krupnog otpada. Zbog opasnosti oštećenja vrijedne opreme uslijed

kontakta ronilice s oštrim predmetima sa dna (razni metalni limovi, školjke automobila itd.), daljnji zaron od kote -4 m n.m. nije bio moguć iako samo dno jezera seže ispod navedene razine vjerojatno do dubine od -6 m n. m., možda i koji metar dublje.

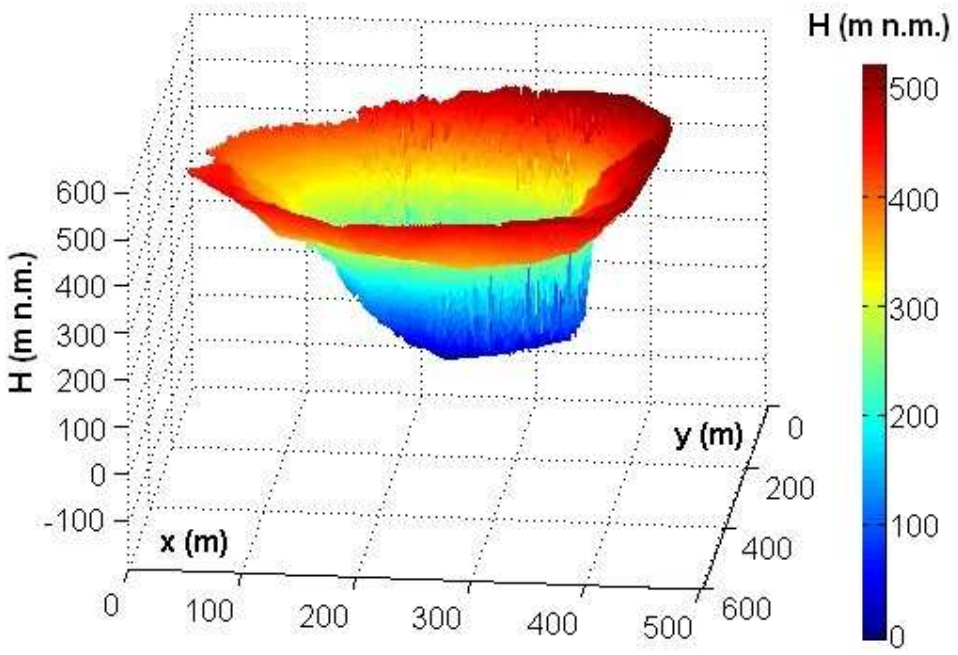
Video snimka u HD rezoluciji pak otkriva prisutnost suspendiranih čestica na dnu koje miruju i samo se gibaju uslijed rada propelera ronilice. To navodi na zaključak da ranije pretpostavke o aktivnim strujanjima kroz krške provodnike na dnu nisu točne i da se voda u jezeru uglavnom ne miješa uslijed toka kroz provodnike.

Kako bi se dobio potpuni model morfologije dna, snimci načinjeni sonarom su vektorizirani te prostorno raspoređeni prema poziciji i dubini njihovog snimanja. Slika 5.38 prikazuje računalni oblik geometrije dna Crvenog jezera prema podacima dobivenim hidroakustičnim snimanjima. Mjesta na snimkama gdje je odjek izostao su naznačena sivom bojom i predstavljaju nedefiniranu stjenku jezera.



Slika 5.38 Wire frame model geometrije dna Crvenog jezera s naznačenim karakterističnim profilima.

Spajanjem geometrije jezera snimljene iznad i ispod razine vode Crvenog jezera dobiva se cjelina koja nudi precizne podatke o zapremini jezera u odnosu na vodostaj. Pri provedenim mjerenjima je instaliran CTD diver na dubini od 40 m koji kontinuirano bilježi svaki sat razinu vode, temperaturu i električnu vodljivost. Ti će podaci u budućnosti dati uvid u gubitke i prihranjivanje jezera (hidrološko-hidrogeološko ponašanje) s obzirom na određenu geometriju definiranu najnovijim mjerenjima opisanim u ovom radu. Slika 5.39 prikazuje kompletni računalni model Crvenog jezera s obzirom na podatke dobivene LiDAR metodom i podvodnim istražnim radovima.

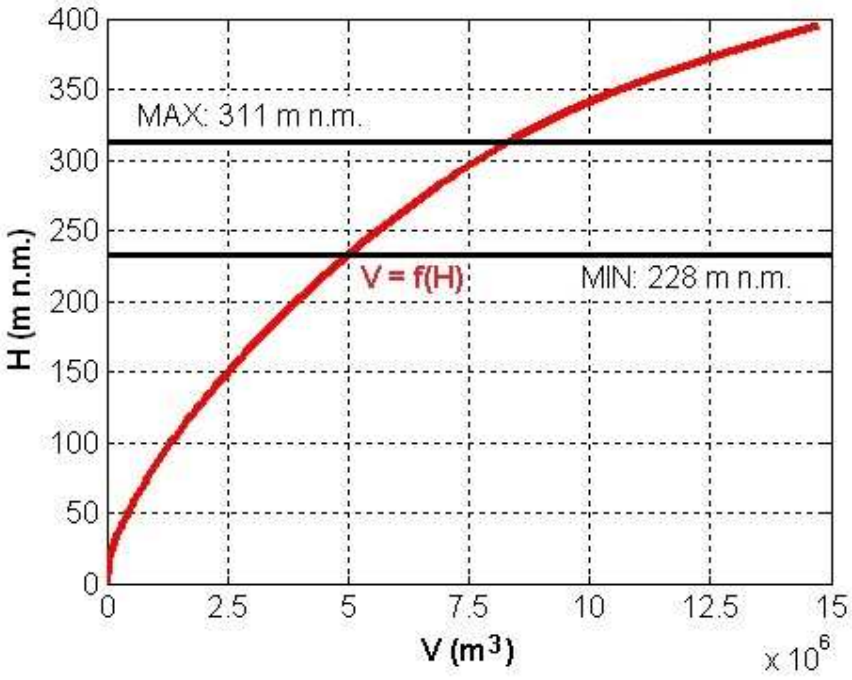


Slika 5.39 Cjelokupni računalni model geometrije Crvenog jezera.

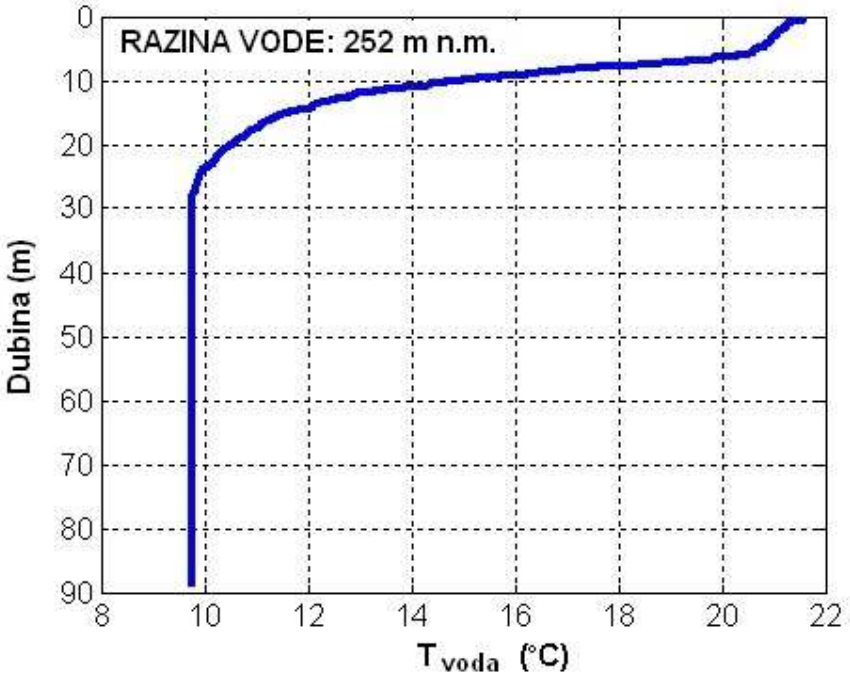
Iako su neke od špilja u stjenkama registrirane i istražene od strane HPD SO Imotski, njihov prikaz je zanemaren pri izradi modela geometrije Crvenog jezera. Na Osnovu dobivenog modela, dobivena je i volumetrijska krivulja Crvenog jezera koja daje odnos između vodostaja i zapremine Crvenog jezera. Taj odnos je iznimno važan kod hidroloških analiza uslijed promatranja dugoročnih vremenskih nizova vodostaja Crvenog jezera. Slika 5.40 prikazuje volumetrijsku krivulju Crvenog jezera.

Imajući na umu zabilježene kote minimalnog i maksimalnog vodostaja, može se reći da se zapremina vode Crvenog jezera mijenja od 5 x 10^6 m^3 do 8 x 10^6 m^3.

Temperaturni profil jezera do dubine od 90 m, načinjen je po sredini jezera uz pomoć CTD divera. Snimanje se vršilo tijekom pripremnih radnji za spuštanje ROV ronilici 8. rujna 2013 godine. Slika 5.41 prikazuje temperaturni profil iz kojeg je vidljivo kako je temperatura od 30 do 90 m ispod površine vodnog lica konstantna i iznosi 10 °C, a pri samoj površini 22 °C. Izoterma na dubinama ispod 30 m također sugerira izostanak strujanja kroz velike provodnike samim time i transmisiju temperaturnog signala uslijed miješanja vode.



Slika 5.40 Funkcijska veza između vodostaja i zapremine Crvenog jezera.



Slika 5.41 Temperaturni profil Crvenog jezera snimljen 8. rujna 2013 godine.

S obzirom na dostupnost novih tehnologija hidroloških i geomorfoloških mjerenja, otvaraju se nove mogućnosti u istraživanju i praćenju krškog vodonosnika kao i krških fenomena kao što je to Crveno jezero. Činjenica je da svaki novi znanstveni i istraživački rad temeljen na mjerenjima korištenjem suvremenih tehnologija obogaćuje i upotpunjuje cjelokupna saznanja o hidrologiji krša. To je osobito potrebno imati na umu prilikom izučavanja funkcioniranja Crvenog i Modrog jezera kod Imotskog.

5.4 DISKUSIJA

U svjetlu prikazanih rezultata proizašlih ovom disertacijom, nameće se sama po sebi diskusija o relevantnosti istih i mogućnosti njihove daljnje inkorporacije u globalne i distributivne hidrološke modele. Pritom se registrira najveći izazov, a to je odabir načina na koji se predstavljaju kompleksni dinamični sustavi u međusobnoj interakciji s uključivanjem povratne veze između komponenti sustava [B3]. Svaki vodonosnik, svaka rijeka pa čak i svaka hidrološka epizoda, bilo to oluja, poplava ili suša posjeduje osobnosti koje se detaljno ne mogu opisati. Svako terensko istraživanje je po prirodi jedinstveno u prostoru i vremenu i kao takvo se ne može ponoviti pod u potpunosti istim početnim i rubnim uvjetima [B4].

S jako malim brojem izuzetaka, sva mjerenja u hidrologiji su točkasta mjerenja te zbog toga mali broj mjernih tehnika može ponuditi izravnu informaciju o prostornim karakteristikama neke hidrološke pojave. Imajući u vidu probleme prostorne distribucije mjerenih hidroloških veličina, neizbježne mjerne pogreške te jedinstvenost prostora i vremena u kojem se mjerenja odvijaju, nedostatci svakog modela i analize mogu se okarakterizirati upravo izazovima definiranja skale, lokacije mjerenja te mjerne pogreške [B4]. Zbog ovih razloga, čak i konceptualno savršen model je podložan nepouzdanosti te je ograničen u smislu procjene i realistične prezentacije svojih rezultata.

Kako bi se modeli približili realističnim rezultatima, uvodi se parametrizacija koja s druge strane nameće ograničenja principima modela te se udaljava od fizike opisivanih prirodnih procesa. U literaturi se problemu heterogenosti vodonosnika pristupa pretpostavkama statističke strukture prostorne heterogenosti [D1]. Ovaj veliki napredak u teoriji ide na uštrb realizma modela, upravo uslijed nužne parametrizacije koja se mora primijeniti za svaku jedinstvenu lokaciju [B3]. Budućnost mjernih tehnika u hidrologiji zasigurno leži u sposobnosti prevladavanja problema skale, lokacije i pogreške, a razvijanje modela u sve većim mogućnostima što vjernijih simulacija fizikalnih procesa u prirodi uslijed porasta i razvijanja računalne snage.

Modeli su uvijek nesavršeni i podložni nepouzdanosti, ali ne smiju biti zanemareni kao alat i sredstvo pri upravljanju vodnim resursima unutar znanstvene zajednice i kod društvenih procesa vezanih za donošenje odluka i odredbi. Zbog prethodno navedenih potreba, nameće se pitanje sinteze u hidrologiji koja nužno mora pomiriti naizgled oprečne stavove vezane za modeliranje i mjerenje te primijeniti znanja i metode kroz različite procese, lokacije i skale. Sinteza se ne mora nužno materijalizirati u vidu zajedničkog modela unutar teorije u hidrologiji, ali moguće je njeno materijaliziranje u vidu usuglašenih obrazaca hidroloških predviđanja i pomoći u izgradnji konsenzusa među hidrolozima [B4].

Imajući u vidu znanstveni napredak unutar mjerenja i modeliranja hidroloških procesa, jedinstveni rezultati ove disertacije predstavljaju informacije koje u budućnosti mogu poboljšati daljnje analize. Nezanemariva druga strana rezultata iznesenih u ovom radu, predstavlja uvid koji oni nude u kompleksne hidrološke procese na lokalnoj i regionalnoj razini.

Mjerenja fizikalno-kemijskih parametara vode unutar jame Nevidna voda nisu zasigurno po tehnici ili tehnologiji jedinstvena mjerenja, ali uzimajući u obzir jedinstvenost lokacije te promatrani vremenski period (epizodu), važnost ovih mjerenja postaje značajna u razumijevanju kompleksnih hidroloških procesa unutar krškog terena.

Na temelju prikupljenih podataka u jami Nevidna voda i primjeni višestrukog regresijskog modela kao i neuralnih mreža, pokazalo se kako modeli koji zanemaruju principe i prirodu fizikalnih procesa mogu ponuditi dobar odgovor na pitanja vezana za predviđanje i prognoziranje budućih stanja. Ipak, velika opasnost kod primjene globalnih modela leži upravo u izraženoj parametrizaciji i udaljavanju od prirodnih zakonitosti i principa. Prikupljanjem većeg broja podataka i kalibriranjem postojećih modela te novim treniranjem neuralnih mreža uslijed novih informacija, greške se smanjuju.

Ovakva mjerenja su izrazito skupa i zahtjevna jer za jedno spuštanje u duboku jamu, potreban je cijeli tim iskusnih speleologa te puno resursa i vremena. Veliki broj ljudi je volonterski sudjelovao i nesebično stavio na raspolaganje svoje zdravlje, vrijeme i novac kako bi se mjerni uređaji instalirali na željene lokacije unutar jame te ponovno demontirali zbog prikupljanja podataka. Takva mjerenja često predstavljaju sigurnosni rizik zbog same prirode speleološke aktivnosti kao i zbog izrazito opasne okoline uslijed odrona materijala, iznenadnih poplava kanala i značajne dubine speleološkog objekta. I trivijalne tjelesne ozljede postaju značajan zdravstveni rizik ako se one dogode na velikim dubinama unutar speleoloških objekata. Jama Nevidna voda speleološki je istraživana u tri navrata 2005, 2006 i 2008, a u tome su sudjelovali: SO HPD Mosor - Split, SO PDS Velebit - Zagreb, SO HPK Mihovil – Šibenik, SO

PK Split - Split, SO HPD Imber - Omiš, SO PD Profunda - Selca, Brač, HBSD - Zagreb, SD Špiljar - Split, SO HPD Željezničar - Zagreb, SO PD Dubovac - Karlovac, PD Cincar – Livno i Komisija za speleologiju HPS.

Mjerenja morfometrije Crvenog i Modrog jezera te mjerenja vezana za vodostaj i fizikalno-kemijske parametre vode u Modrom jezeru također su bila prožeta sigurnosnim rizicima zbog nepristupačnosti terena, prvenstveno u slučaju Crvenog jezera. Kako bi upravljanje ROV-om bilo moguće, potrebno je bilo konstruirati platformu na površini jezera te osigurati funkcionalnu žičaru za prijevoz tereta. Ovakvi pripremni radovi iziskuju veliki broj ljudi, a mjerenja zbog iznimno skupe znanstvene opreme i znatne financijske napore. Ipak, zbog volontera kao i u slučaju istraživanja jame Nevidna voda, ova mjerenja su bila moguća, prvenstveno zahvaljujući članovima speleoloških društava SO HPD Imotski i SO HPD Mosor iz Splita te donacijama tvrtke Neptun Sub d.o.o. iz Šibenika koja je ustupila svoje stručnjake i opremu za morfološka mjerenja Crvenog jezera.

Rezultati mjerenja su iznimne vrijednosti jer po prvi puta se može govoriti argumentirano o volumetriji Crvenog jezera te morfologiji samog dna. Ovi podaci će se koristiti u daljnjim znanstvenim radovima te uz pomoć prikupljenih podataka o vodostajima u Crvenom jezeru ponuditi jedinstvenu sliku o kompleksnom hidrološkom režimu svjetski poznatog krškog fenomena.

Za Modro jezero koje uz Crveno jezero čini možda i najpoznatija krška jezera, uspostavljeni model u ovom radu je ponudio odgovore vezane za površinu sliva vezanu za direktno otjecanje te mehanizme hidrološke bilance.

Kao što je već opisano, model grubo opisuje kompleksne procese, no zaključci koji slijede iz simulacija i analiza mogu pomoći u boljem razumijevanju. Tako u slučaju Modrog jezera primjećuje se prihranjivanje u ljetnim mjesecima koje se ne može simulirati modelom. Model simulira komponente bilance kao što su dotok, gubitci i vlažnost tla zanemarujući pritom gubitke uslijed evaporacije s površine te kao takav u kišnim razdobljima jako dobro simulira prirodno stanje. Značajne razlike između simuliranih i mjerenih vrijednosti nastaju pak tijekom ljetnih mjeseci. U tom periodu model simulira opadanje srednjih dnevnih protoka, dok se preko mjerenih podataka registrira prihranjivanje jezera. Odgovori na ovakvo ponašanje hidrološkog režima jezera se ne mogu naći na osnovu provedenih istraživanja. Nagađanja o ovom fenomenu mogu ići u više pravaca, ipak pretpostavka o mogućoj vezi Crvenog i Modrog jezera najviše zaokuplja pažnju znanstvene zajednice. Eventualna veza i mogući dotok iz Crvenog jezera u Modro jezero bi mogao objasniti porast protoka i vodostaja u sušnim mjesecima.

Vezano za tehniku i tehnologiju mjerenja, znanstveni doprinos ove disertacije leži u uvođenju novog protokola pri mjerenju protoka uz pomoć radarskog uređaja. Probabilistički pristup [C3] se dokazao kao izvrstan način raspodjele brzina unutar otvorenog toka na osnovu površinske brzine.

Kako radar nudi određivanje površinske brzine, nameće se pitanje: koja je to brzina na površini reprezentativna u smislu određivanja svake druge brzine unutar promatranog presjeka? Odgovor na ovo pitanje leži u rasporedu mreže površinskih brzina na promatranom presjeku te određivanju brzinskih vertikala prema probabilističkom pristupu. Takav način mjerenja nudi velike mogućnosti kod ekstremnih hidroloških situacija jer mjeritelj nije izravno u doticaju s tokom. Mjeritelju je omogućeno sa sigurne udaljenosti očitati površinske brzine što u konačnici povećava sigurnost, brzinu i ekonomičnost mjerenja. Kako predmetni profil sadržava i kontrahirane dijelove, dokazana je mogućnost primjene ove metode kod izrazito nepravilne geometrije korita što je u pravilu slučaj kod izlijevanja vodotoka uslijed poplava.

Iako zbog postojanja ograničavajućih čimbenika kao što su to boranje površine vode uslijed vjetra i pulsacija površinske brzine koji uvelike utječu na točnost rezultata mjerenja radarom, probabilistički pristup treba razmotriti kao alternativni način mjerenja protoka na vodotocima s obzirom na sve prednosti što ga isti nudi. Kontinuirano prikupljanje podataka i telemetrija otvaraju nove opcije za sve dionike involvirane u prikupljanje i analizu podataka vezanih za protoke otvorenih vodotoka.

Svi rezultati ovog rada moraju biti subjekt diskusiji, jer bez suprotstavljanja razmišljanja, ideja i različitih paradigmi napredak u teoriji i praksi hidrologije nije moguć. Budućnost nosi sa sobom i daljnji tehnološki razvoj, koji će omogućiti i drugačiji pristup u mjerenjima u hidrologiji. Daljinsko očitavanje podataka uz pomoć satelita se sve više razvija, ali mjerenja in situ neće nikada moći biti u potpunosti zamijenjena. Tehnološki napredak može ponuditi budućnost u vidu sve gušćih mreža mjernih točaka raznih parametara, sve manje mjerne pogreške i sve veću dostupnost podataka uslijed razvoja podatkovnog prijenosa i potrebne infrastrukture.

Izazov u hidrologiji ostaje analiza i interpretacija sve većih količina podataka. Zbog toga interakcija između modela i mjerenja mora slijediti nadolazeće trendove i tim putem nedvosmisleno osigurati realistične reprezentacije kompleksnih prirodnih pojava.

6. ZAKLJUČCI I PRAVCI DALJNJIH ISTRAŽIVANJA

6.1 ZAKLJUČCI

U okviru ovog rada, provedena su hidrološka i geomorfološka istraživanja unutar krškog terena na nekim od najvažnijih hidrološko aktivnih oblika krškog reljefa kao što su to duboke jame, površinski tokovi te krška jezera. Pri tom je korištena najnovija dostupna tehnologija kao što su to ADCP, ADV, CTD diver, radar, GPS antene, sonar i LiDAR uređaji.

Naglasak ovog rada leži na eksperimentalnoj komponenti hidroloških istraživanja, koja se često zanemaruje, no jedino podaci proizašli iz terenskih mjerenja mogu doprinijeti boljim analitičkim, numeričkim i stohastičkim modelima te u konačnici i boljem razumijevanju kompleksne prirodne pojave kao što je to kretanje vode u kršu.

S novom tehnologijom, mogućnosti mjerenja se povećavaju, a troškovi smanjuju. Vremenska rezolucija mjerenja se značajno povećala s obzirom na razvoj računalne tehnologije, a prostorna rezolucija se povećava s investiranjem u grananje mreže mjernih uređaja.

Na primjeru analize hidrodinamičkog odgovora duboke jame u kršu na vanjsku pobudu u vidu praćenih meteoroloških parametara, može se zaključiti da se gušćom mrežom mjerenja, samim time i većim brojem podataka, mogu uspostaviti modeli temeljeni na umjetnim neuralnim

mrežama koji su u stanju dobro pratiti i predviđati hidrološke situacije. Primjenom NARX neuralne mreže vidljivo je značajno poboljšanje u kvaliteti modela, a da bi NARX mreža uopće mogla biti korisna, potrebno je uspostavljanje telemetrijskih sustava mjerenja i centralne obrade podataka. Današnja tehnologija nudi veliku autonomiju mjernih stanica u vidu energijske opskrbe i pohrani podataka. GPRS sustavi nude telemetrijsku nadogradnju mreža. S obzirom na sve tehnološke prednosti novo uspostavljenih mjernih sustava, modeli koji za cilj imaju opisivanje nelinearnih dinamičkih pojava, svakodnevno se unaprjeđuju i poboljšavaju.

U konačnici, zaključak vezan za praćenje osnovnih fizikalno kemijskih parametara vode unutar vadozne zone u dubokoj krškoj jami, svodi se na razumijevanje važnosti kvalitetne i guste mreže mjernih postaja koja može jamčiti kvalitetu primijenjenih modela. Krški vodonosnik i površinski sliv se integralno promatraju kao cjeloviti sustav, stoga povećanje mjerenja unutar područja istraživanja vodi ka kvalitetnijim alatima nužnim kod donošenja odluka i novih strategija vezanih za upravljanje vodnim resursima.

Probabilistički pristup kod hidrometrijskih mjerenja je u sve široj primjeni. Provedeni eksperimenti u ovom radu potvrđuju mogućnosti koje ova nova metoda nudi te kod povećanja brzinskih vertikala čak i unutar kontrahiranog presjeka nude novi protokol za mjerenje protoka upravo na nepristupačnim dionicama i ekstremnim situacijama. Prednosti mjerenja radarom se vežu za ekonomičnost i sigurnost, a problemi se detektiraju uglavnom kod određivanja parametra entropije, snimanja geometrije profila i dostupnosti dugih vremenskih nizova. Ipak, uz sve navedeno, ova metoda ima perspektivu kod standardiziranih mjerenja protoka, a da bi njena primjena ušla u široku upotrebu, nužna je suradnja s državnim agencijama. Izlasci na teren, upravo kod ekstremnih hidroloških situacija s ciljem primjene ove metode, mogu dovesti do značajnih pomaka u kvaliteti i mogućnostima hidrometrijskih mjerenja.

Hidrološka i morfološka mjerenja Modrog i Crvenog jezera kod Imotskog su značajan doprinos u lokalnom i regionalnom smislu razumijevanja kompleksnog hidrološkog sustava krškog vodonosnika. Kako se jezera smatraju prirodnim pijezometrima unutar krškog terena praćenje oscilacije razina vode u njima dovodi do zaključaka vezanih za regionalna kretanja vode i hidrološku bilancu promatranih krških fenomena. Morfološka istraživanja nude odgovore za prirodne procese usko vezane za lokacije, kao što su to padinski procesi i povećavanje taloga na dnu. Bitno je naglasiti kako promatranje hidroloških parametara nosi najveći značaj pri mjerenjima barem jedne hidrološke godine. Naravno vremenske serije za više godina nude odgovore funkcioniranja jednog i drugog jezera pri različitim klimatskim i hidrološkim uvjetima, no nažalost takva se mjerenja do sada nisu provodila. Mjerenja koja su ipak dostupna zahvaljujući

prvenstveno entuzijazmu i volonterskom sudjelovanju amaterskih udruga kod terenskih istraživanja, ponudila su fascinantne odgovore na morfometriju izučavanih krških jezera pa i na hidrološku funkciju.

Zahvaljujući najnovijim mjerenjima na Crvenom i Modrom jezeru, po prvi puta je detaljno snimljena morfometrija oba jezera, što u konačnici predstavlja velik rezultat i polaznu točku za sva druga hidrološka istraživanja.

Dno Modrog jezera pokriveno je finim muljem na kojem se jasno uočavaju lijevci kroz koje voda ponire u krško podzemlje [P8]. Dno jezera nalazi na koti 241,6 m n. m. što je utvrđeno najnovijim geodetskim mjerenjima 2011. godine. Prethodna mjerenja su vršena pred više od pedeset godina, a kota dna je izmjerena na 239,0 m n. m., dakle niža za oko 2,6 m od one koja je utvrđena 2011 godine.. Ovu značajnu razliku u kotama dna moguće je objasniti na dva načina. Prvi je da se radi o grešci, a drugi je da je tijekom posljednjih pedesetak godina došlo da zatrpavanja jezera sedimentom koji je rezultat padinskih procesa (urušavanja, osipanja i sapiranja rastresitog materijala s okolnih strmaca).

Analize izvršene na mjerenim podacima tijekom jedne nepotpune hidrološke godine na Modrom jezeru, bacile su svjetlo na funkcioniranje ovog jezera, a donekle i na procese cirkulacije vode u širem prostoru. Hidrološki model Modrog jezera sugerira da je slivna površina odgovorna za direktno dotjecanje manja od 40 km^2. Činjenica je da najnovija mjerenja i na osnovi njih doneseni zaključci nisu omogućili detaljno i konačno razumijevanje hidrogeološko-hidroloških procesa koji se zbivaju u slivu Modrog jezera, ali su omogućili bolji uvid u složene procese dotoka i istjecanja vode iz jezera. Mjerenja su omogućila uspostavljanje znanstveno zasnovanih i pouzdanih pretpostavki za organiziranje učinkovitog monitoringa bitnog za vršenje bilance voda ovog impresivnog krškog fenomena.

Geomorfološka istraživanja Crvenog jezera kao glavni rezultat nude odgovore vezane za morfometriju i oblik jezera te opovrgavaju prijašnje teorije o postojanju podzemne rijeke na dnu jezera. Obilje registriranog odjeka registriranog na koti -4 m n.m. sugerira na sužavanje dna uslijed urušenog materijala što je potvrđeno i načinjenim snimkama uz pomoć instalirane kamere HD rezolucije na korištenoj ronilici. Kamera ujedno odaje i prisutnost urušenog materijala uslijed antropogenih utjecaja te potvrđuje glasine kako se Crveno jezero godinama koristi kao ilegalno odlagalište krupnog otpada.

Video snimka zarona otkriva prisutnost suspendiranih čestica na dnu koje miruju te se samo uslijed propelera ronilice gibaju. Iz toga se da izvući zaključak kako ranije pretpostavke o

aktivnim strujanjima kroz krške provodnike na dnu nisu u potpunosti točne, podzemna rijeka na dnu ne postoji, a voda se u jezeru uglavnom ne miješa uslijed toka kroz provodnike nego uslijed razlika temperaturnih gradijenata.

Temperaturni profil iz kojeg je vidljivo kako je temperatura od 30 do 90 m ispod površine vodnog lica Crvenog jezera konstantna i iznosi 10 °C, a pri samoj površini 22 °C. Izoterma na dubinama ispod 30 m također potvrđuje izostanak strujanja kroz velike provodnike samim time i transmisiju temperaturnog signala uslijed miješanja vode.

Navedena nova saznanja o Modrom i Crvenom jezeru su značajna te otvaraju prostor za nova istraživanja koja predstavljaju strateški cilj, ne samo za znanstvenu zajednicu nego i ostale elemente društva koji su dionici u procesima odlučivanja i upravljanja.

6.2 MOGUĆI PRAVCI DALJNJIH ISTRAŽIVANJA

Moguće primjene analiza o hidrološkoj aktivnosti duboke jame leže u potencijalnom razvoju telemetrijskih mreža mjernih točaka koje unutar određenog krškog sliva prikupljaju informacije unutar jama, bušotina i otvorenih vodotoka te u kombinaciji s mrežom meteoroloških postaja čine cjelinu koja u svakom trenutku daje na uvid korespondirajuće podatke o ulazu i izlazu sustava. Uspostavljanjem takvih sustava praćenja te temeljem primjene umjetnih neuralnih mreža, pogotovo kod sustava što podatke bilježi bez vremenskog odmaka („data collection in real time"), rezultirajući modeli moraju donositi korist široj zajednici. Takvi sustavi imaju za cilj koristi u područjima prirodnih nepogoda i katastrofa, zdravlja, energije, klime, vode, meteorologije, ekosustava, poljoprivrede i bioraznolikosti.

Razvoj metode mjerenja protoka radarom i probabilističkim pristupom mora ići u smjeru da njena primjena nalazi mjesto upravo kod poplava i izlijevanja riječnih korita. To je jedino moguće u suradnji s Državnim hidrometeorološkim zavodom. Ova metoda zbog svojih karakteristika može u potpunosti dosegnuti svoj potencijal upravo kod ekstremnih situacija kao što su poplave. Nužno je napomenuti kako poradi kvalitetnog snimanja geometrije povećanog profila uslijed izlijevanja vode, snimci LiDAR tehnologijom iz zraka mogu biti od velike pomoći. Nadalje, nizovi mjerenja ADCP uređaja na velikim rijekama mogu itekako pomoći kod određivanja nužnog parametra entropije za promatrane slučajeve.

U sklopu daljnjih istraživanja na Crvenom i Modrom jezeru, planira se redovito skeniranje jezera iznad površine vode kako bi se utvrđivale količine urušenog materijala između dva

snimanja. Periodično snimanje temperaturnih profila, profila otopljenog kisika kao i kontinuirano praćenje mutnoće vode se planira vršiti kroz naredno vrijeme monitoringa hidroloških i fizikalno-kemijskih parametara vode. Evidentno je kako postoji potreba proširenja opsega budućih mjerenja. Neophodno je istovremeno mjeriti hidrološke parametre na Modrom i Crvenom jezeru, a možda i na još nekom od vodnih fenomena u tom području, kao što su Galipovac jezero, Knezovića jezero, Lokvičko jezero i izvor rijeke Vrljike. Svakako, piezometri u blizini Modrog i Crvenog jezera bi dali uvid u regionalne smjerove cirkulacije podzemnih voda. U planu su mjerenja temperature vode i električne provodljivosti u više vertikalnih stupaca kako Crvenog jezera tako i Modrog, u sredini i na bokovima, pri raznim vodostajima i u raznim razdobljima godine (sezonama) kao i kontinuirano praćenje vodostaja.

Prikupljanjem novih podataka otvaraju se i nove mogućnosti kod modeliranja krškog vodonosnika čije ponašanje velikim dijelom reflektiraju upravo hidrološki režimi Crvenog i Modrog jezera. Pristup modeliranja bi jednim pravcem mogao ići ka globalnim modelima kao što su to kombinacije linearnih i nelinearnih rezervoara, primjena umjetnih neuralnih mreža te razni regresijski modeli. Drugi pravac modeliranja koji je svakako vrijedan truda vodi ka distributivnim modelima. Distributivni model krša mora inkorporirati fiziku transporta kroz sva tri tipa poroznosti krškog vodonosnika. Kako takvi modeli diskretiziraju domenu u mrežu homogenih cjelina za koje moraju biti definirani hidraulički parametri i rubni uvjeti, što bolje poznavanje geometrije provodnika i njihova distribucija u prostoru kao i poznavanje distribucije pukotina unutar krške matrice je od esencijalne važnosti. Kako to nije uvijek moguće, bitno je osloniti se na postojeće informacije, kao što je to distribucija istraženih speleoloških objekata, traser testovi te pretpostavke vezane za evoluciju krša koje mogu ponuditi odgovore o distribuciji neistraženih krških provodnika. Zbog svojih konstruktivnih zahtjeva, distributivni modeli iziskuju znatno veće terenske istražne radove i veću količinu informacija od globalnih modela.

Nove tehnologije pružaju nove mogućnosti u istraživanju i praćenju krškog vodonosnika. Činjenica je da svaki novi znanstveni i istraživački rad temeljen na mjerenjima korištenjem suvremenih tehnologija obogaćuje i upotpunjuje cjelokupna saznanja o hidrologiji krša. Važnost mjerenja ne smije biti podcijenjena. Izravni doprinosi koji proizlaze iz mjerenja imaju aplikativnu vrijednost kako kod daljnjih modeliranja, tako i kod budućih odlučivanja i praćenja vezanih za proučavane procese.

7. LITERATURA

[A1] Andrić, I.; Bonacci, O.; Jukić, B., (2013): Rezultati najnovijih hidroloških i geomorfoloških istraživanja Crvenog jezera kod Imotskog. Hrvatske vode 21, 86; 344-348.

[A2] Atkinson, T.C. (1977): Diffuse flow and conduit flow in limestone terrain in the Mendip Hills, Somerset (Great Britain) Journal of Hydrology 35: 93-100.

[B1] Bahun, S. (1991.): O postanku Crvenog i Modrog jezera kod Imotskog. Geološki Vjesnik 44:275-280.

[B2] Bakalowicz, M., Mangin, A. (1980.): L'aquifère karstique. Sa définition, ses caractéristiques et son identification. Mém. h. sér. Soc. géol. France 11: 71-79.

[B3] Bögli, A. (1980.): Karst hydrology and physical speleology. Springer Verlag, Berlin.

[B4] Beaven, K. J. (2000.): Uniqueness of place and process representations in hydrological modelling. Hydrology and Earth System Sciences. 4(2), 203-323, EGS.

[B5] Blöschl, G. (2006.): Hydrologic synthesis: Across processes, places, and scales. Water Recourses Research, Vol. 42, W03S02.

[B6] Bojanić, L., Ivičić, D., Batić, V. (1981.): Hidrogeologija Imotskog polja s osvrtom na značaj u regionalnom smislu. Geološki Vjesnik 34: 127-135.

[B7] Boiten, W., (2002.): Flow measurement structures. Flow Measurement and Instrumentation. 13(5-6): 203-207.

[B8] Boiten, W., (2003.): Hydrometry. Swets & Zeitlinger B.V., Lisse.

[B9] Bonacci, O. (1995.): Ground water behaviour in karst: Example of the Ombla Spring (Croatia). Journal of Hydrology. 165: 113-134.

[B10] Bonacci, O. (1987.): Karst hydrology with special references to the Dinaric karst, Springer Verlag, Berlin, Germany.

[B11] Bonacci, O. (2006.): Crveno i Modro jezero kod Imotskog. Hrvatske Vode 14(54): 45-54.

[B12] Bonacci, O., (2003.): Ekohidrologija vodnih resursa i otvorenih vodotoka .Split : Građevinsko-arhitektonski fakultet sveučilišta u Splitu, Split.

[B13] Bonacci, O., Roje Bonacci, T. (2000.a): Posebnosti krških vodonosnika, Hrvatske Vode 8(30): 35-42.

[B14] Bonacci, O. (2004.): Hazards caused by natural and anthropogenic changes of catchment area in karst. Natural Hazards and Earth System Sciences 4: 655-661.

[B15] Bonacci, O., Andrić, I., Yamashiki, Y. (2014): Hydrology of Blue Lake in the Dinaric karst. Hydrol. Process., 28: 1890–1898.

[B16] Bonacci, O., Roje Bonacci, T. (2000.b): Interpretation of groundwater level monitoring results in karst aquifers: examples from the Dinaric karst. Hydrological Processes 14(14): 2423-2438.

[B17] Bonacci, O., (1979.):Influence of turbulence on the accuracy of discharge measurements in natural streamflows, Journal of Hydrology, Vol.42, 3–4, 347-367.

[B18] Bonacci, O., (1994.): Oborine glavna ulazna veličina u hidrološki ciklus .Split : Geing.

[B19] Bonacci, O., Andrić, I. (2O08.a): Sinking karst rivers hydrology: case of the Lika and Gacka (Croatia). Acta Carsologica 37(2-3), 185-196.

[B20] Bonacci, O., Andrić, I. (2010): Impact of an inter-basin water transfer and reservoir operation on a karst open streamflow hydrology regime: an example from the Dinaric karst (Croatia). Hydrological Processes 24, 3852-3863.

[B21] Bonacci, O., Roje Bonacci, T. (2008.): Water losses from the Ričice reservoir built in the Dinaric karst. Engineering Geology 99(3-4): 121-127.

[B22] Bonacci, O. (1999.): Water circulation in karst and determination of catchment areas: example of the River Zrmanja. Hydrological Sciences Journal 44(3), 373-386.

[B23] Bruckner, A. et al., (2008.): Durchflussmesstechnik. Oldenbourg Industrieverlag GmbH, München.

[B24] Buzjak, N., Trpčić, M. (2005.): Mjerenje tvrdoće vode u odabranim krškim pojavama Žumberačke gore. Geoadria, Vol. 10, No. 2, 157-169.

[C1] Cavalera, T., Gilli, E. (2009.): The submarine river of Port Miou (France), A karstic system inherited from the Messinian deep stage. Geophysical Research Abstracts Vol. 11, EGU 2009-5591.

[C2] Chantasut, N., Charoenjit, C. and Tanprasert, C. (2004.): Predictive Mining of Rainfall Predictions Using Artificial Neural Networks for Chao Phraya River, 4th International Conference of The Asian Federation of Information Technology in Agriculture and The 2nd World Congress on Computers in Agriculture and Natural Resources, August 9-12.

[C3] Chiu, C.-L., (1989.) Velocity distribution in open channel flow.Journal of Hydraulic Engineering 115, 576–594.

[C4] Chiu, C.-L., Chen, Y.-C., (1999.) Efficient methods of measuring discharge and reservoir-sediment inflow. In: Kuo, J.-T., Yen, B.-C. (Eds.), Risk Analysis in Dam Safety Assessment. Water Resources Publications, Inc., Colorado, pp. 97–116.

[C5] Chiu, C.-L., Hsu, S.H., Tung, N.-C., (2005.) Efficient methods of discharge measurements in rivers and streams based on the probability concept. Hydrological processes 19, 3935–3946.

[C6] Chiu, C.-L., Tung, N.-C., (2002.) Maximum velocity and regularities in open-channel flow. Journal of Hydraulic Engineering 128, 390–398.

[C7] Culver, D. and White W., (2005) Encyclopediaof Caves, Elsevier Academic Press. 293-300.

[C8] Cvijić, J. (1896.): Das Karstphänomen. Geograph. Abh. Wien 5. H. 3: 215-329.

[C9] Cvijić, J. (1926.): Geomorfologija II. Srpska akademija nauka i umetnosti, Beograd.Cvijić, J. (1960.) : La géographie de terrains calcaires. Naučno Delo, Beograd.

[D1] Dagan, G. (1986.): Statistical theory on groundwater flow and transport: pore to laboratory; laboratory to formation and formation to regional scale. Water Recourses Research, Vol. 22, 120-234.

[D2] Daneš, J. V. (1906.) : La région de la Neretva inferieure. La Géographie Paris 13 : 91-102.

[D3] Dreybrodt, W. (1990): The role of dissolution kinetics in the development of karst aquifers in limestone: A model simulation of karst evolution. Journal of Geology 98, no. 5: 639–655.

[E1] Eagleman. J. R. (1967): Pan evaporation, potential and actual evapotranspiration. J. Appl. Meteorology, 6, 482-1188.

[F1] Feng, L. and Hong, W., (2008.): On hydrologic calculation using artificial neural networks, Applied Mathematics Letters, Vol.21, 5, 453-458.

[F2] Field, M. S. (2002.): A lexicon of cave and karst terminology with special reference to environmental karst hydrology. USEPA, Washington, DC, USA.

[F3] Fleming S.W., Lavenue A.M., Aly A.H., Adams A. (2002.) Practical applications of spectral analysis to hydrologic time series. Hydrological Processes 16, 565-574.

[F4] Ford, D., Williams, P. (2007.): Karst hydrogeology and geomorphology. Wiley, Chichester.

[F5] Fukushima, Y. (1988.): A model of river flow forecasting for a small forested mountain catchment. Hydrol. Process., 2: 167–185.

[F6] Fulton, P. and Ostrowski J., (2008) Measuring real-time streamflow using emerging technologies: Radar, hydroacoustics, and the probability concept, Journal of Hydrology, Volume 357, 1–2, 1-10. Hydrological Processes, 2, 167-185.

[G1] Gabrovsek, F. and Turk, J., (2010.): Observations of stage and temperature dynamics in the epiphreatic caves within the catchment area of the Ljubljanica River Slovenia. Geologia Croatica 63.2.

[G2] Gabrovšek, F. and Dreybrodt, W., (2000): Role of mixing corrosion in calcite-aggressive H_2O-CO_2-$CaCO_3$ solutions in the early evolution of karst aquifers in limestone. Water Resources Research 36, no. 5: 1179–1188.

[G3] Gams, I. (2005.): Tectonics impact on poljes and minor basins (case studies of Dinaric karst). Acta Carsologica 34(1): 25-41.

[G4] Garašić, M. (1999): Međunarodna speleoronilačka ekspedicija u Crveno jezero kraj Imotskog. Hrvatska Vodoprivreda VIII (78), 40-42.

[G5] Garbrecht, J., Fernandez, G. P. (1994.): Visualization of trends and fluctuations in climatic records. Water Resources Bulletin 30(2), 341 -357.

[G6] Gavazzi, A. (1903./1904.): Die Seen des Karstes. 1. Teil: Morphologisclies Material. Wien, Abh. Geogr. Ges. 5.

[G7] Geyer T. et al., (2008.): Quantification of temporal distribution of recharge in karst systems from spring hydrographs, Journal of Hydrology, Vol. 348, 3–4, 452-463. [G7] Grund, A. (1903.): Die Karsthydrographie. Studien aus Westbosnien. Geogr. Abhandl. herausgegeben von Penck, VII, 3. Leipzig.

[H1] Herak, M., (1990.): Geologija. Školska knjiga, Zagreb.

[H2] Herschy, R. W., (2009): Streamflow Measurement. Taylor & Francis, London.

[H3] Horiba, Ltd, (2008.): Operational Manual, Multi-Probe W-22XD.23XD, Kyoto.

[H4] Huang, S.L., Young, C., Abdul-Aziz, O.I., Dahal, D., Feng, M., Liu, S.G. (2013): Simulating the water budget of a Prairie Potholes complex from LiDAR and hydrological models in North Dakota, USA. Hydrological Sciences Journal 58, 7, 1434-1444.

[J1] Jayawardena, A., Achela, D., Fernando, K. (1998): Use of Radial Basis Function Type, Artificial Neural Networks for Runoff Simulation, Computer-Aided Civil and Infrastructure Engineering, 13, 91–99.

[J2] Jukić D., Denić-Jukić V. (2004): A frequency domain approach to groundwater recharge estimation in karst. Journal of Hydrology 289, 95-110.

[J3] Jukić, D. and Denić-Jukić, V. (2008.): Estimating parameters of groundwater recharge model in frequency domain, Water and Energy Abstracts. 18, 3; 322-327.

[J4] Jukić D., Denić-Jukić V. (2009): Groundwater balance estimation in karst by using a conceptual rainfall-runoff model, Journal of Hydrology, 373, 302-315.

[J5] Jukić D. (2006): Kontinuirane wawelet-transformacije i njihova primjena na sliv Krčića i izvora Krke. Hrvatske vode (1330-1144) 50, 39-52.

[J6] Julien, P. Y., (2002): River Mechanics. Cambridge University Press, Cambridge.

[K1] Kaufmann, G., (2003.): A model comparison for karst aquifer evolution for different matrix-flow formulations. Journal of Hydrology 283, no. 1–4: 281–289.

[K2] Kresic N. and Stevanovic Z., (2010): Groundwater Hydrology of Springs, Elsevier Inc., Burlington USA, 62-80.

[K3] Kurabo Industries Ltd., (2010.): Kuraves-G2 3D Photogrammetry, Version 3.0., Osaka.

[L1] Lihua F., Weihu H. (2008): On hydrologic calculation using artificial neural networks, Applied Mathematics Letters, 21(5), 453-458.

[M1] Magdalenic A. 1971. Hidrogeologija sliva Cetine. Krš Jugoslavije 7(4): 89–169.

[M2] Maillet, E. 1905. Essai d'Hydraulique Souterraine et Fluviale. Librairie scientique A. Hermann, Paris.

[M3] Mangin, A., (1994.): Karst hydrogeology. Groundwater Ecology. Academic press, Orlando, Florida, USA. 43-67.

[M4] Milanović, P. T. (1979.): Hidrogeologija karsta i metode istraživanja. Hidroelektrane na Trebišnjici Institut za korištenje voda na kršu, Trebinje.

[M5] Moramarco T., Saltalippi C, Singh V.P. (2004). Estimation of mean velocity in natural channels based on Chiu's velocity distribution equation. Journal of Hydrologic Engineering, 9(1), 42-50.

[M6] Mulec, J, Mihevc, A., Pipan, T. (2005.): Presihajoča jezera na Pivškem. Acta Carsologica 34(3): 543-565.

[N1] Nikitin, I.K. (1963.): Turbulentnyj ruslovoj potok i processy v pridonnoj oblasti, Akademija Nauk Ukrainskoj SSR, Kijev.

[N2] Nikmehr, S., Farhoudi, J. (2010): Estimation of Velocity Profile Based on Chiu's Equation in Width of Channels, Journal of Applied Sciences, Engineering and Technology 2(5): 476-479.

[P1] Padilla A.and Pulido-Bosch A., (1995.): Study of hydrographs of karstic aquifers by means of correlation and cross-spectral analysis, Journal of Hydrology, 168, 73-89.

[P2] Palandačić, A., Bonacci, O., Snoj, A. (2012.): Molecular data as a possible tool for tracing groundwater flow in karst: Example of Delminichthys adspersus in Dinaric karst system. Ecohydrology.

[P3] Palmer, W. C. (1965.): Meteorological Drought US Weather Bureau Tecnical Paper No.45, Washington D.C., 58.

[P4] Pandžić, K. (1985): Water Balance on the Eastern Adriatic Coastal Region, DHMZ, RASPRAVE 2O, Zagreb str. 21 -29.

[P5] Pedersen J.T., Peters J.C, Helweg O.J. Hydrographs by single linear reservoir model, USACF, TP-74, 1980.

[P6] Pedololški institut, (1984): Pedološke karte SR Hrvatske; Fakultetpoljoprivrednih znanosti, Zagreb.

[P7] Petras I. (1996): An approach to the mathematical expression of recession curves, Water SA, Vol. 12., N3.

[P8] Petrik, M. (1960.): Hidrografska mjerenja u okolici Imotskog. Ljetopis JAZU 64: 266-286.

[P9] Plant, W.J., Keller, W.C., Hayes, K., (2005.) Measurement of river surface currents with coherent microwave systems. IEEE Transactions on Geoscience and Remote Sensing 43 (6), 1242–1257.

[P10] Prelovšek, M., Turk, J., Gabrovšek, F. (2008.): Hydrodynamic aspect of caves. International Journal of Speleology 37(1), 11-26.

[P11] Pouri, S, Aureli, A. (2009.): Atlas of Transboundary Aquifers. UNESCO-IHP, Paris.

[R1] Rantz, S.E., (1982.) Measurement and computation of streamflow: volumes I and II. US Geological Survey Water-Supply Paper 2175.

[R2] Ravbar, N., Šebela, S. (2004.): The karst periodical lakes of Upper Pivka, Slovenia. Acta Carsologica 33(1): 159-173.

[R3] RD Instruments, (2003.) WinRiver User's Guide, USGS Version P/N957-6096-00.

[R4] Roche, M. (1963.): Hydrologie de Surface. Gauthier-Villars Éditeur, Paris.

[R5] Roglić, J. (1938.): Imotsko polje (Fizičko-geografske osobine). Posebno izdanje geografskog društva 21, Beograd.

[R6] Roglić, J (1974.), Reljef (središnje Hrvatske), Geografija Hrvatske (knjiga 1.), Školska knjiga, Zagreb.

[S1] Schlumberger Water Services, (2010): Product Manual for Mini-Diver, Micro-Diver, Cera-Diver, Baro-Diver and CTD-Diver, Delft.

[S2] Schoeller, H. (1962.): Les Eaux Souterraines. Masson Éditeur, Paris.

[S3] Siegelmann, H.T.; Horne, B.G.; Giles, C.L. (1997): Computational capabilities of recurrent NARX neural networks, Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE 27, (2), 208-215.

[S4] Slingerland, R. and Kump, L., (2011.): Mathematical Modeling of Earth's Dynamical Systems:A Primer. Princeton University Press, New Jersey.

[S5] SonTek/YSI Inc., (2007.): FlowTracker® Handheld ADV® Technical Manual., San Diego.

[S6] Steidl J., Dorfmann C., (2013) ADCPtool reference Manual, TU Graz, Graz.

[Š1] Šestanović, S., (2001.): Osnove geologije i petrografije. Građevinski fakultet sveučilišta u Splitu, Split.

[T1] Tišljar K, (2001.): Sedimentologija karbonata i evaporita. IGI, 3, Zagreb.

[T2] Trauth M, (2010.): MATLAB® Recipes for Earth Sciences. Springer Verlag , Berlin.

[U1] Ujević, A. (1991.): Imotska krajina. Matica hrvatska, Imotski

[W1] Werner, P. W. and Sundquist, K. J. (1951.): On the groundwater recession curve for large watersheds, IAHS General Assembly, Brussels, IAHS Publ., 33, 202-212

[W2] White, W. B., (1988.): Geomorphology and Hydrology of Karst Terrains, Oxford University press, Oxford and New York

[W3] Williams P. (1983.): The role of subcutaneous zone in karst hydrology. Journal of Hydrology, 61: 45-67.

[W4] Williams P. (2004.): Dolines. In Encyclopedia of Caves and Karst Science, Gunn, J (ed.). Fitzroy Dearborn, New York; 304-310.

[W5] Wittenberg, H. (1999.): Baseflow recession and recharge as nonlinear storage processes. Hydrological Processes 13(13): 715-726.

[W6] Worthington, S.R.H. and Ford, D.C. (2009) Self-Organized Permeability in Carbonate Aquifers, Groundwater Volume 47, Issue 3, 326–336.

[Y1] Yokogawa Electric Corporation Ltd., (2011.): User's Manual WJ7661 type RYUKAN, Japan.

[Y2] Yonaba, H., Anctil, F., Fortin, V. (2010): Comparing Sigmoid Transfer Functions for Neural Network Multistep Ahead Streamflow Forecasting. J. Hydrol. Eng., 15(4), 275–283.

Životopis

Ivo Andrić dipl. ing. građ. rođen je 4. studenog 1979. godine u Vinkovcima. Osnovnu školu završio je u Heilbronnu u Njemačkoj te nakon nje pohađa tehničku gimnaziju Wilchelm Maybach, također u Heilbronnu. Završnu godinu srednje škole pohađa u Tourbotville, PA u Sjedinjenim Američkim Državama gdje i maturira. Na Građevinskom fakultetu Sveučilišta u Splitu, 23. veljače 2007. godine diplomira kod prof. dr. sc. Ognjena Bonaccia na temu „Proračun mjesečnih i godišnjih koeficijenata otjecanja za sliv Rybarik, Slovačka“ te stječe stručni naziv diplomirani inženjer građevinarstva.

1. studenog 2007. godine na istom fakultetu zasniva radni odnos u svojstvu znanstvenog novaka, pri Katedri za hidrologiju, te sudjeluje u nastavi održavajući vježbe iz predmeta Hidrologija na Preddiplomskom sveučilišnom studiju građevinarstva te Inženjerska hidrologija, Uređenje vodotoka i Odvodnja i navodnjavanje na Diplomskom studiju građevinarstva.

Akademske godine 2008./2009. upisao je Poslijediplomski znanstveni studij iz znanstvenog područja Tehničkih znanosti, znanstveno polje Građevinarstvo, smjer Hidrotehnika.

U proteklom periodu objavio je u koautorstvu 20 znanstvenih radova u časopisima i zbornicima znanstvenih skupova u zemlji i inozemstvu.