

# Razvoj hidrološkog modela otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži

---

Sušanj, Ivana

Doctoral thesis / Disertacija

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Civil Engineering in Rijeka / Sveučilište u Rijeci, Građevinski fakultet u Rijeci**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:157:835002>


Rights / Prava: [Attribution-NonCommercial-NoDerivatives 4.0 International/Imenovanje-Nekomercijalno-Bez prerada 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2024-07-22**



Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Civil Engineering - FCERI Repository](#)



SVEUČILIŠTE U RIJECI  
GRAĐEVINSKI FAKULTET

Ivana Sušanj

**RAZVOJ HIDROLOŠKOG MODELA  
OTJECANJA S MALIH SLIVOVA  
TEMELJEN NA UMJETNOJ  
NEURONSKOJ MREŽI**

DOKTORSKI RAD

Rijeka, 2016



SVEUČILIŠTE U RIJECI  
GRAĐEVINSKI FAKULTET

Ivana Sušanj

**RAZVOJ HIDROLOŠKOG MODELA  
OTJECANJA S MALIH SLIVOVA  
TEMELJEN NA UMJETNOJ  
NEURONSKOJ MREŽI**

DOKTORSKI RAD

Mentorica: Prof. dr. sc. Nevenka Ožanić  
Komentorica: Izv. prof. dr. sc. Barbara Kaleuša

Rijeka, 2016

UNIVERSITY OF RIJEKA  
FACULTY OF CIVIL ENGINEERING

Ivana Sušanj

**DEVELOPMENT OF THE  
HYDROLOGICAL RAINFALL-RUNOFF  
MODEL BASED ON ARTIFICIAL  
NEURAL NETWORK IN SMALL  
CATCHMENTS**

DOCTORAL THESIS

Rijeka, 2016

Mentor rada: **Prof. dr. sc. Nevenka Ožanić**

Komentor rada: **Izv. prof. dr. sc. Barbara Kaleuša**

Doktorski rad obranjen je dana **13. siječnja 2017. godine** u Rijeci pred povjerenstvom u sastavu:

1. **Doc. dr. sc. Dražen Vouk,**  
Sveučilište u Zagrebu, Građevinski fakultet, Hrvatska  
(predsjednik Povjerenstva)
2. **Prof. dr. sc. Nevenka Ožanić,**  
Sveučilište u Rijeci, Građevinski fakultet, Hrvatska  
(članica i mentorica)
3. **Izv. prof. dr. sc. Barbara Karleuša,**  
Sveučilište u Rijeci, Građevinski fakultet, Hrvatska  
(članica i mentorica)
4. **Izv. prof. dr. sc. Marija Šperac,**  
Sveučilište u Osijeku, Građevinski fakultet, Hrvatska  
(vanjska članica)
5. **Doc. dr. sc. Goran Volf,**  
Sveučilište u Rijeci, Građevinski fakultet, Hrvatska  
(član)

## ZAHVALA

U samom vremenu provedenom u izradi ove disertacije i istraživanju mnogo sam puta razmišljala o tome kome se sve trebam zahvaliti te se nadam da neću nikoga izostaviti.

Prvo se želim od srca zahvaliti mentorici *prof.dr.sc. Nevenki Ožanić* čija me je predanost radu neizmjerljivo motivirala za rad u znanosti te uz čiju je sveobuhvatnu pomoć i potporu omogućeno moje istraživanje i nastanak ovog rada. Nadam se da ću ukazanu potporu, povjerenje i razumijevanje, a koje sam dobila od svoje mentorice, u budućnosti opravdati. Svakako se zahvaljujem i svojoj komentorici *izv.prof.dr.sc. Barbari Karleuši* koja je također strpljivo i detaljno čitala svaki redak ovoga rada, te predlagala konstruktivne promjene za njegovo poboljšanje.

Tokom provedenog istraživanja za potrebe izrade rada bilo je mnogo osoba koje su mi neizmjerljivo pomogle navodeći me na pravi put znanstvenog istraživanja. Zato, velika hvala *doc.dr.sc. Ivanu Maroviću* za sva postavljena protupitanja koja su me usmjerila ka kvalitetnijem znanstvenom razmišljanju. Zahvaljujem se i svim kolegama na hidrotehničkoj katedri jer su me svojim primjerom motivirali za rad. Hvala i *prof.dr.sc. Svjetlanu Feretiću* na lektoriranju matematičkih izraza ovoga rada. Za veliku pomoć u istraživanju zahvaljujem i djelatnicima Vinodolske općine i Hrvatskih voda (VGO Rijeka) na ukazanoj pomoći, asistenciji i ustupljenoj dokumentaciji. Također zahvaljujem i svim suradnicima i kolegama koji su me tokom istraživanja podupirali i hrabрили.

Svojim roditeljima *Jadranki* i *Darku*, koji su mi kroz cijeli moj život ogromna podrška, glas mudrosti i sila koja me tjera napred, veliko hvala. Nadalje posebnu zahvalu izražavam i mome *Marinu* koji je tokom izrade ovog rada bio moja nemjerljiva potpora i motivator te osoba puna razumijevanja i strpljenja. Mojim sestrama *Mihaeli* i *Barbari* se zahvaljujem na ukazanoj potpori i svim riječima ohrabrljenja kao i mojoj dragoj *Antoniji*.

## SAŽETAK

U nekim je situacijama štetne pojave, koje su uzrokovane djelovanjem vode, moguće umanjiti ili spriječiti posljedice istih uz pomoć sustava za rano uzbunjivanje pravovremenom obznanom obavijesti o mogućnosti nastanka štetne pojave. Motivacija za izradu ove disertacije temelji se na istraživanju mogućnosti predviđanja štetnih pojava uzrokovanih vodom na malim slivovima u cilju implementacije sustava za rano uzbunjivanje.

Istraživanja unutar rada obuhvaćaju uspostavu kontinuiranog mjerenja meteoroloških i hidroloških podataka na istražnom području sliva Slani potok (Vinodolska dolina) koji je povijesno prepoznato hazardno područje, primjenu umjetnih neuronskih mreža pri razvoju hidrološkog modela predviđanja otjecanja, određivanje načina validacije i evalvacije modela te razvoj metodologije implementacije hidrološkog modela predviđanja otjecanja na malim slivovima.

Shodno provedenom istraživanju, a u cilju dokazivanja postavljenih hipoteza razvijen je hidrološki model predviđanja otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži. Prikupljeni podaci korišteni su za treniranje, validaciju te evalvaciju mogućnosti predviđanja hidrološkog modela otjecanja. Model je potom validiran i evalviran vizualnim i numeričkim mjerama kvalitete prilikom čega su utvrđene dostatne mogućnosti predviđanja modela za potrebe implementacije sustava ranog uzbunjivanja. Temeljem razvijenog modela utvrđena je detaljna metodologija za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži.

**KLJUČNE RIJEČI:** sustav ranog uzbunjivanja, hidrološki model, umjetna neuronska mreža, metodologija razvoja modela

## **ABSTRACT**

Occasionally, consequences caused by water induced events can somewhat be reduced or even prevented with the help of an early warning system whose aim is timely notification of local population on potentially upcoming hazardous event. The motivation for this thesis arises from the need to explore the possibilities to foresee such water caused events on small catchments with an aim to mitigate its consequences by implementing an early warning system.

Research and analysis shown in this theses encompasses the establishment of continuous meteorological and hydrological data monitoring, on research area Slani Potok (Vinodol Valley) historically known as potentially hazardous area, the application of the artificial neural network as a means for the development of hydrological rainfall-runoff model, defining the methods for model validation and evaluation, as well as the development of the methodology for the hydrological rainfall-runoff model implementation on small catchments.

Upon on this research a hydrological rainfall-runoff model for small catchments was developed based on artificial neural network. Gathered data was used for training, validation and evaluation of model's accuracy and precision in rainfall-runoff prediction. The model was validated and evaluated using visual and numerical quality measures according to which needed accuracy in model prediction was determined for the implementation of early warning system. Based on this model a detailed methodology for the implementation of rainfall-runoff model on small catchments developed on artificial neural network was established.

**KEYWORDS:** early warning system, hydrological model, artificial neural network, Methodology for model implementation

# SADRŽAJ

	<i>str.:</i>
<b>1. UVOD</b> .....	1
1.1. Problemski okvir i predmet istraživanja.....	1
1.2. Ciljevi i hipoteza rada.....	3
1.3. Struktura rada.....	4
1.4. Potpora znanstvenom istraživanju.....	6
<b>2. PRETHODNA ISTRAŽIVANJA</b> .....	7
2.1. Hazard.....	8
2.1.1. <i>Hidrotehnički hazard</i> .....	8
2.1.2. <i>Rizik i ranjivost</i> .....	12
2.2. Mjere za umanjenje štetnih pojava.....	12
2.3. Sustav ranog uzbunjivanja.....	13
2.3.1. <i>Identifikacija rizika</i> .....	14
2.3.2. <i>Praćenje i služba uzbunjivanja</i> .....	14
2.3.3. <i>Diseminacija i komunikacija</i> .....	15
2.3.4. <i>Mogućnost odziva</i> .....	15
2.4. Hidrološki modeli.....	15
2.4.1. <i>Sliv i čimbenici otjecanja</i> .....	17
2.4.2. <i>Mali sliv</i> .....	21
2.4.3. <i>Povijesni razvoj hidroloških modela</i> .....	22
2.4.4. <i>Klasifikacija hidroloških modela</i> .....	27
2.4.5. <i>Metodologija za razvoj hidroloških modela</i> .....	30
2.5. Umjetne neuronske mreže.....	32
2.5.1. <i>Biološka osnova i definicija umjetne neuronske mreže</i> .....	32
2.5.2. <i>Struktura umjetne neuronske mreže</i> .....	33
2.5.3. <i>Svojstva umjetne neuronske mreže</i> .....	35
2.5.4. <i>Treniranje (učenje), validacija i evalvacija umjetnih neuronskih mreža</i> .....	37
2.5.5. <i>Razvoj i upotreba umjetnih neuronskih mreža</i> .....	39
2.5.6. <i>Klasifikacija umjetnih neuronskih mreža</i> .....	45
2.5.7. <i>Metodologija za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži</i> .....	46
2.6. Istražno područje.....	49
2.6.1. <i>Geografski položaj analiziranog područja</i> .....	49
2.6.2. <i>Geološka građa istražnog područja Slanog potoka</i> .....	52
2.6.3. <i>Klimatološke značajke istražnog područja</i> .....	57
2.6.4. <i>Biološka obilježja istražnog područja</i> .....	60
2.6.5. <i>Fizičke osobine sliva</i> .....	61
2.6.6. <i>Stanje, istraživanja i zahvati na slivu Slanog potoka</i> .....	64

<b>3. METODOLOGIJA RAZVOJA MODELA</b> .....	70
3.1. Metodologija razvoja modela umjetne neuronske mreže.....	70
3.2. Hidrološka i meteorološka mjerenja na istražnom području Slanog potoka.....	71
3.2.1. Hidrološka mjerenja.....	73
3.2.2. Meteorološka mjerenja.....	74
3.2.3. Praćenje štetnih pojava na slivu Slanog potoka.....	76
3.3. Višeslojni perceptron i treniranje umjetne neuronske mreže.....	81
3.3.1. Višeslojni perceptron.....	81
3.3.2. Treniranje umjetnih neuronskih mreža i algoritmi za izračun mjere promjene $\Delta w$ u sklopu optimizacijskog parametara $w_k$ .....	82
3.3.3. Lokalni algoritmi prvoga reda.....	83
3.3.4. Algoritmi drugoga reda.....	85
3.3.5. Levenberg-Marquardt algoritam za treniranje umjetne neuronske mreže višeslojnog perceptrona.....	87
3.4. Programiranje višeslojnog perceptrona i Levenberg-Marquardt algoritma.....	89
3.5. Mjere kvalitete umjetne neuronske mreže.....	91
3.5.1. Apsolutne mjere kvalitete modela.....	93
3.5.2. Relativne mjere kvalitete.....	95
3.5.3. Odabir mjera kvalitete te granice mjera kvalitete za ocjenu modela umjetne neuronske mreže.....	99
<b>4. HIDROLOŠKI MODEL PREDVIĐANJA OTJECANJA S MALIH SLIVOVA TEMELJEN NA UMJETNOJ NEURONSKOJ MREŽI</b> .....	101
4.1. Razvoj hidrološkog modela predviđanja otjecanja sa sliva Slanog potoka temeljen na umjetnoj neuronskoj mreži.....	101
4.1.1. Odabir i obrada ulaznih varijabli hidrološkog modela predviđanja otjecanja.....	101
4.1.2. Odabir i obrada izlaznih varijabli hidrološkog modela predviđanja otjecanja.....	107
4.1.3. Arhitektura hidrološkog modela predviđanja otjecanja: Aktivacijske funkcije, skriveni sloj, podjela podataka i broj iteracija.....	108
4.2. Treniranje hidrološkog modela predviđanja otjecanja.....	115
4.3. Validacija hidrološkog modela predviđanja otjecanja.....	121
4.4. Evalvacija hidrološkog modela predviđanja otjecanja.....	124
4.5. Diskusija rezultata razvoja hidrološkog modela predviđanja otjecanja s sliva Slani potok temeljenog na umjetnoj neuronskoj mreži.....	129



---

<b>5. METODOLOGIJA ZA IMPLEMENTACIJU HIDROLOŠKOG MODELA OTJECANJA NA MALIM SLIVOVIMA TEMELJENOG NA UMJETNOJ NEURONSKOJ MREŽI</b> .....	134
5.1. Mjerenje za potrebe razvoja hidrološkog modela predviđanja otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži.....	136
5.1.1. Prikupljanje dostupnih povijesnih podataka.....	136
5.1.2. Uspostava kontinuiranog mjerenja i spremanja meteoroloških i hidroloških podataka.....	136
5.1.3. Prepoznavanje pokretača štetnih pojava.....	137
5.2. Modeliranje predviđanja otjecanja s malih slivova temeljem umjetne neuronske mreže.....	137
5.2.1. Određivanje ulaznih i izlaznih podataka modela.....	137
5.2.2. Prethodna obrada podataka.....	138
5.2.3. Postojanje dodatnih pogrešaka u podacima.....	138
5.2.4. Podjela podataka u skupove.....	138
5.2.5. Implementacija umjetne neuronske mreže.....	139
5.3. Validacija hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži.....	139
5.3.1. Procedura validacije modela umjetne neuronske mreže.....	139
5.3.2. Odabir adekvatnih vizualnih i numeričkih mjera kvalitete.....	139
5.3.3. Kriterij validacije.....	140
5.4. Evalvacija hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži.....	141
5.4.1. Procedura evalvacije modela umjetne neuronske mreže.....	141
5.4.2. Odabir adekvatnih vizualnih i numeričkih mjera kvalitete.....	141
5.4.3. Kriterij evalvacije.....	141
5.5. Implementacija umjetne neuronske mreže za potrebe razvoja hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži.....	143
<b>6. ZAKLJUČCI</b> .....	146
<b>7. LITERATURA</b> .....	149
<b>POPIS TABLICA</b> .....	154
<b>POPIS SLIKA</b> .....	155
<b>POPIS KRATICA</b> .....	159
<b>POPIS SIMBOLA</b> .....	161
<b>ŽIVOTOPIS</b> .....	163
<b>POPIS OBJAVLJENIH RADOVA</b> .....	164

---

# 1. UVOD

## 1.1. Problemski okvir i predmet istraživanja

Modeli hidroloških sustava predstavljaju svojevrsnu pojednostavljenu aproksimaciju stvarnog sustava, a izrađuju se u svrhu istraživanja hidroloških procesa, predviđanja određenih hidroloških varijabli te kao alati pri donošenju odluka u domeni planiranja i upravljanja. Unutar ove disertacije istraživanje je usmjereno prema modelima hidroloških sustava u svrhu predviđanja hidroloških varijabli. U današnje vrijeme istraživanje u domeni razvoja hidroloških modela, u svrhu predviđanja hidroloških varijabli, dolazi dijelom iz potrebe za implementacijom sustava ranog uzbunjivanja na područjima koji su pod utjecajem hidrotehničkog hazarda.

Disertacija naslova „Razvoj hidrološkog modela otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži,“ nastala je kao odgovor na uočene nedostatke u području razvoja hidroloških modela otjecanja s malih slivova temeljenih na umjetnoj neuronskoj mreži te nedostatka pripadne metodologije za implementaciju istih. U disertaciji je razvijen hidrološki model predviđanja otjecanja s malih slivova na primjeru sliva Slani potok (Vinodolska dolina), a koji svojim svojstvima predviđanja upućuje na mogućnost implementacije sustava ranog uzbunjivanja. Procedure korištene pri izradi modela poslužile su kao temelj za razvoj metodologije za implementaciju hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži.

U istraživanju, otkrivanju i sustavnoj obradi znanstvenih činjenica, za potrebe izrade disertacije korišten je cijeli niz različitih znanstvenih metoda, a koje podrazumijevaju skup postupaka ispitivanja i istraživanja neke pojave s ciljem dolaska do znanstvenih spoznaja i istina. U nastavku će biti prikazan metodološki opis ustroja disertacije te opisane korištene znanstvene metode pri istraživanju za potrebe disertacije.

Zajednički naziv za skup primjenjenih metoda u procesu istraživanja naziva je metoda dokazivanja, a koja je ujedino i glavna znanstvena metoda primjenjena unutar disertacije. Ovom metodom želi se dokazati postavljena hipoteza rada. Da bi se potvrdila postavljena hipoteza, disertacija je podijeljena u četiri osnovne

logičke cijeline: (i) Prethodna istraživanja te postavljanje ciljeva i hipoteze rada, (ii) Temeljne metode i materijali za potrebe istraživanja, (iii) Rezultati istraživanja i (iv) Dokazivanje hipoteze.

Prethodno istraživanje u sklopu disertacije ima za zadatak definiranje ciljeva i postavljanje hipoteze rada dok ostatak rada vodi ka dokazu hipoteze. Prethodno istraživanje je provedeno upotrebom više znanstvenih metoda, a koje su: metoda analize, povijesna metoda te metoda klasifikacije. Stoga je prethodnim istraživanjem obuhvaćena sva relevantna terminologija iz područja hidrotehnike u domeni štetnih pojava prilikom čega su opisane mjere za umanjenje štetnih pojava te sustavi za rano uzbunjivanje. Detaljno su opisani povijest te dostignuća razvoja, klasifikacija i metodologija za razvoj hidroloških modela te uže hidroloških modela temeljenih na umjetnoj neuronskoj mreži. Prethodno istraživanje u okviru disertacije se također sastoji od preglednog opisa te analize postojećih istraživanja predmetnog područja sliva Slanog potoka. Analizom prethodnih istraživanja definiran je smjer daljnjeg istraživanja koje vodi ka znanstvenom doprinosu disertacije pa su stoga postavljeni ciljevi i hipoteza rada.

Nastavak istraživanja temelji se na opisu temeljnih metoda i prikupljanju materijala za potrebe ostvarivanja ciljeva i dokazivanja hipoteze rada. Unutar ovoga dijela istraživanja uspostavljena su mjerenja kako bi se prikupili meteorološki i hidrološki podaci s istražnog područja sliva Slani potok prilikom čega se pratio nastanak i posljedice štetnih pojava. Detaljno je opisana procedura mjerenja te prikupljanje relevantnih podataka koji čine temelj za razvoj hidrološkog modela predviđanja otjecanja. U nastavku je opisan ustroj arhitekture modela umjetne neuronske mreže koji će činiti osnovu razvoja modela, algoritmi treniranja umjetnih neuronskih mreža te procedura validacije i evalvacije modela.

Rezultati istraživanja u sklopu disertacije obuhvaćaju detaljan prikaz arhitekture razvijenog hidrološkog modela. Prikupljeni mjereni podaci, koji su implementirani u model, prethodno su obrađeni i analizirani osnovnom statističkom metodom čiji su rezultati prikazani grafički i tablično. Model je razvijen uz pomoć programskog paketa MATLAB R2012b (MathWork), koji je potom, s obzirom da se radi o modelu temeljenom na umjetnoj neuronskoj mreži treniran, validiran i evalviran. Rezultati sva tri postupka su ocijenjeni vizualnim i numeričkim metodama analize.

Temeljem razvijenog hidrološkog modela otjecanja s malih slivova primjenom generalizacije ustanovljena je metodologija implementacije hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži. Rezultati cjelokupnog istraživanja su analizirani u sklopu diskusije rezultata čime se utvrđuje razina ispunjenja ciljeva istraživanja.

Sve navedene primjenjene znanstvene metode u procesu istraživanja primjenjene su u sklopu glavne znanstvene metode dokazivanja. Dokazivanje hipoteze i doprinosa rada proizlazi iz diskusije rezultata istraživanja koji upućuju na ispunjenje ciljeva zadanih ovom disertacijom. Dokazivanje hipoteze temelji se na objektivnom, pouzdanom, preciznom i sustavnom pristupu procesu znanstvenog istraživanja i zaključivanja.

## **1.2. Ciljevi i hipoteza rada**

Korištenjem znanstvenih metoda istraživanja u provedenom prethodnom istraživanju disertacije ustanovljeni su ciljevi te hipoteze rada, a koji će u nastavku biti detaljnije opisani.

U sklopu istraživanja očekuje se ispunjenje četiri cilja. S obzirom da je analizom postojećih istraživanja na slivu Slani potok utvrđen nedostatak mjerenja meteoroloških i hidroloških podataka, prvi cilj je uspostava kontinuiranog mjerenja istih. U domeni primjene hidroloških modela predviđanja otjecanja temeljenih na umjetnoj neuronskoj mreži utvrđen je izostanak primjene takve vrste modela na malim slivovima pa je drugi cilj u sklopu disertacije ispitati mogućnost razvoja, na temelju rezultata mjerenja meteoroloških i hidroloških podataka, hidrološkog modela predviđanja otjecanja na malom slivu, a koji je temeljen na umjetnoj neuronskoj mreži. Treći cilj istraživanja u sklopu disertacije je definiranje postupaka validacije i evalvacije mogućnosti predviđanja hidrološkog modela otjecanja u svrhu implementacije sustava ranog uzbunjivanja. Prethodnim istraživanjem utvrđena je potreba za detaljnijim razvojem metodologije implementacije hidrološkog modela otjecanja s malih slivova a koji je temeljen na umjetnoj neuronskoj mreži. Naime, za razvoj takvih modela postoje samo opće metodološke smjernice pa je iz toga razloga četvrti cilj disertacije razvoj metodologije implementacije hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži.

Provedenim prethodnim istraživanjem te definiranjem ciljeva disertacije utvrđuju se dvije hipoteze rada. Prva hipoteza rada temelji se na pretpostavci da je upotrebom umjetne neuronske mreže moguće razviti hidrološki model predviđanja otjecanja za male slivove, a koji će imati dostatne mogućnosti predviđanja kako bi bilo moguće implementirati sustav ranog uzbunjivanja, uz uvjet da postoji uspostavljeno kontinuirano mjerenje meteoroloških i hidroloških podataka. Druga hipoteza rada temelji se na pretpostavci da je hidrološki model temeljen na umjetnoj neuronskoj mreži primjenjiv na male slivove, uz uvjet postojanja kontinuiranog mjerenja meteoroloških i hidroloških parametara, te je moguće razviti metodologiju za implementaciju hidrološkog modela predviđanja otjecanja s malih slivova, a koji je temeljen na umjetnoj neuronskoj mreži.

Ciljevi i hipoteza rada potvrđeni su i objavom rada u ožujku 2016. godine pod nazivom: “*Methodology for Developing Hydrological Models Based on an Artificial Neural Network to Establish an Early Warning System in Small Catchments*“ u inozemnom časopisu *Advances in Meteorology*; IF:1,107 (2015); (<http://www.hindawi.com/journals/amete/2016/9125219/>) u kojem su obuhvaćeni svi gore navedeni ciljevi i rezultati istraživanja kao i znanstveni doprinos predloženog istraživanja.

### **1.3. Struktura rada**

Doktorski rad sastavljen je od šest osnovnih poglavlja i popisa literature u kojem su dani literaturni izvori. Poglavlja disertacije slijede osnovne cijeline postupka istraživanja, a u nastavku će kratko biti opisan sadržaj svakog poglavlja.

#### *Poglavlje 1. Uvod*

U uvodu je dan prikaz problemskoga okvira i predmet istraživanja, cilja i hipoteze rada, opis strukture rada te su navedeni znanstveni projekti u sklopu kojih je izrađena disertacija.

#### *Poglavlje 2. Prethodna istraživanja*

U ovom se poglavlju daje pregled raspoloživih saznanja iz literature o štetnim pojavama, hazardu, riziku i ranjivosti te mjerama za umanjene štetnih pojava, koje su nastale djelovanjem vode, kao što je primjerice sustav ranog uzbunjivanja. Daje se i pregled saznanja o hidrološkim modelima te modelima

umjetne neuronske mreže. Poglavlje sadrži i polazne osnove – saznanja o slivu Slani potok na kojem su provedena istraživanja za potrebe disertacije.

### *Poglavlje 3. Metodologija razvoja modela*

Poglavlje se sastoji od glavnih metodoloških osnova i opisa materijala koji su temelj izrade disertacije. Ovo poglavlje sadrži opis osnovne primijenjene metodologije razvoja hidrološkog modela otjecanja temeljenog na umjetnoj neuronskoj mreži. Potom je detaljno opisana procedura mjerenja hidroloških i meteoroloških podataka koja se provode na istražnom području sliva Slani potok. U nastavku je opisana primijenjena arhitektura modela umjetne neuronske mreže višeslojnog perceptrona i algoritmi treniranja, te opisan postupak programiranja modela i proces validacije i evalvacije modela.

### *Poglavlje 4. Hidrološki model predviđanja otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži*

U ovom poglavlju daje se opis razvijenog hidrološkog modela predviđanja otjecanja. Za potrebe predviđanja razvijen je model koji je ispitan na tri vremenska koraka: (i) M15 s korakom predviđanja od  $\Delta t = 30 \text{ minuta}$ , (ii) M30 s vremenskim korakom predviđanja od  $\Delta t = 60 \text{ minuta}$  i (iii) M60 s vremenskim korakom predviđanja od  $\Delta t = 120 \text{ minuta}$  za istražno područje sliva Slani potok. Opisan je odabir i obrada ulaznih i izlaznih podataka modela te detaljan opis programirane arhitekture modela koja obuhvaća odabir aktivacijskih funkcija, definiranje skrivenog sloja modela, podjelu podataka te broj iteracija računanja. Potom su prikazani rezultati treniranja hidroloških modela otjecanja te nakon toga i rezultati validacije i evalvacije modela koji su popraćeni diskusijom rezultata.

### *Poglavlje 5. Metodologija za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži*

U ovom poglavlju prikazana je razvijena metodologija za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži. Metodologija je razrađena na temelju razvijenog hidrološkog modela otjecanja na istražnom području sliva Slani potok te postojeće metodologije koja daje osnovne smjernice za razvoj hidroloških modela temeljenih na umjetnim neuronskim mrežama općenito.

## *Poglavlje 6. Zaključci*

Uz općenite zaključke temeljene na dobivenim rezultatima i provedenoj raspravi prema utvrđenim ciljevima i hipotezama rada u ovom su poglavlju dane preporuke za daljnja istraživanja.

### **1.4. Potpora znanstvenom istraživanju**

Istraživanja za potrebe izrade disertacije provedena su uz sveobuhvatnu potporu dva znanstveno-istraživačka projekta:

- Bilateralni hrvatsko-japanski znanstveni projekt: *„Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje nepogoda kod odrona zemlje i poplava u Hrvatskoj“* (eng. *Risk Identification and Land Use Planning for Disaster Mitigation of Landslides and Floods in Croatia*), Trajanje projekta: 2009.-2014., Ministarstvo znanosti, obrazovanja i športa Republike Hrvatske i JICA, Voditelj projekta: prof.dr.sc. Nevenka Ožanić
- Sveučilišne potpore za materijalno zahtjevna istraživanja: *„Hidrologija vodnih resursa i identifikacija rizika od poplava i blatnih tokova na krškom području“*. Trajanje projekta: 2014.- , Sveučilište u Rijeci, Voditelj projekta: prof.dr.sc. Nevenka Ožanić

## **2. PRETHODNA ISTRAŽIVANJA**

Prethodna istraživanja za potrebe izrade disertacije obuhvaćaju upoznavanje s osnovnom terminologijom i objašnjenjima iz domene štetnih pojava nastalih pod utjecajem vode, mjerama za umanjeno istih te uvođenja sustava za rano uzbunjivanje u cilju umanjeno posljedica štetnih pojava na mjestima na kojima nije moguće ili nije prihvatljivo iz raznih razloga provesti strukturalne mjere. Jedan od najbitnijih preduvjeta za uvođenje sustava za rano uzbunjivanje je razvoj hidrološkog modela te su iz toga razloga u nastavku definirani elementi hidrološkog sustava, detaljno objašnjeni hidrološki modeli, njihova klasifikacija, povijesni razvoj i postojeće metodologije za razvoj modela. Proučavanje različitih pristupa modeliranju hidroloških sustava daljnje su istraživanje usmjerile prema upotrebi matematičkih parametarskih modela te je stoga prikazan detaljan pregled umjetnih neuronskih mreža, njihova klasifikacija, povijesni razvoj i postojeće metodologije za razvoj modela temeljenih na umjetnim neuronskim mrežama. Temeljem analize postojećih metodologija za razvoj hidroloških modela upotrebom umjetnih neuronskih mreža, vidljiva je potreba za razvojem hidroloških modela otjecanja na malim slivovima u cilju razvoja sustava ranog uzbunjivanja kao i potreba za definiranjem detaljnije metodologije za razvoj modela. Za potrebe razvoja hidrološkog modela otjecanja sa malim slivova je stoga u sklopu istraživanja u disertaciji izabran vodotok Slani potok koji je jedan od pritoka rijeke Dubračine, a nalazi se u Vinodolskoj dolini. Ishodišnu točku u razvoju hidrološkog modela otjecanja na istražnom području sliva Slanog potoka čine prethodna istraživanja koja su usmjerena na prikupljanje i analizu postojećih istražnih, projektnih te znanstvenih radova koji ukazuju na problematiku predmetnog sliva u smislu nastanka štetnih pojava te potrebu za uvođenjem sustava ranog uzbunjivanja.

### **2.1. Hazard**

Hazard se može opisati kao vjerojatnost pojavljivanja potencijalno štetnih prirodnih pojava (prirodni hazard) i/ili pojava uzrokovanih ljudskom aktivnošću (antropogeni hazard) u određenom razdoblju i unutar nekog prostora. Prirodni hazard se definira kao vjerojatnost pojavljivanja štetne prirodne pojave nastale pod utjecajem endogenih (u Zemljinoj kori) i egzogenih (na površini Zemlje) procesa.



Prirodni hazardi se dijele na geološki hazard i atmosferski hazard. Geološki hazardi su prouzročeni geodinamikom Zemlje, a rezultiraju pojavom potresa, erupcije vulkana, ekstremno velikim valovima (tsunami), pokretima masa na kosinama, poplavama i slijeganjima terena. Atmosferski hazardi su prouzročeni procesima u atmosferi (posebice troposferi) kao što su tropske ciklone, tornado, oluja, udar groma, suša i šumski požar (Benac, 2016).

Hazardi prirodnog i antropogenog tipa mogu imati primarne, sekundarne i tercijarne efekte štetne pojave. Primarni efekti uključuju sam proces kao što je primjerice rušenje građevine. Sekundarni efekti su uzrokovani primarnim efektima kao što je poplava ili požar dok se tercijarnim efektima smatraju dugotrajne promjene okoliša (Benac, 2016).

Štetne pojave mogu izazvati cijeli niz posljedica kao što su gubitak ljudskih života, ozljede ili utjecaj na zdravlje, gubitak sredstava za život, narušavanje socijalnih i ekonomskih uvjeta te materijalna oštećenja. Ovakve su pojave, s obzirom da se događaju na naseljenim područjima, predmet istraživanja u cilju umanjavanja ili sprečavanja nastanka nepoželjnih posljedica dok oni koji se događaju na nenaseljenim područjima nisu zanimljivi istraživačima. U naseljenim područjima je posebno teško ustvrditi sve uzroke štetnih procesa jer su oni u mnogo slučajeva izazvani i prirodnim i antropogenim djelovanjem te ih nije moguće uvijek u potpunosti spriječiti ili umanjiti.

### **2.1.1. Hidrotehnički hazard**

U grani hidrotehnike hazard se može opisati kao vjerojatnost pojavljivanja potencijalno štetnih prirodnih pojava i/ili kao posljedica antropogenog djelovanja, koje su prouzročene kombinacijom djelovanja geodinamike Zemlje te procesima u atmosferi, a za posljedicu imaju primjerice pojavu poplava. Poplava se definira kao pojava velike količine vode u vodotoku, odnosno poplavnog vala, koji prouzrokuje izlivanje na poplavno područje. Poplavni val je značajni porast razine vode u vodotoku u fazi akumulacije prispjelih voda s površine sliva ili iz podzemlja a uobičajeno je prirodnim utjecajem izazvan značajnom količinom pale oborine (Benac, 2016). Osim poplava u štetne pojave spadaju još i bujice, muljni tokovi, debratne poplave i slično (Norbiato i sur., 2008).

Unutar disertacije istraživanje je usmjereno na štetne pojave u smislu pojave bujica, muljnog toka i debritnih poplava na malim slivovima. Bujični tok ili bujica se može definirati kao poplava uzrokovana oborinskom epizodom velikog intenziteta, prilikom čega razine vode u vodotoku dosežu maksimalne razine unutar nekoliko minuta do nekoliko sati ostavljajući vrlo malo vremena za upozorenje na opasnost (Georgakakos, 1992). Prema Norbiato i sur. (2008), bujice su lokalizirane pojave koje se javljaju na slivovima površine manje od nekoliko stotina kilometara. Glavna karakteristika takvih slivova je brz odziv na oborine, koji je uobičajeno manji od nekoliko sati. U mnogim slučajevima, takvi slivovi imaju kratko vrijeme odziva na oborinu velikog intenziteta zbog strmog pada sliva te nepropusnih karakteristika tla sliva, saturiranog tla ili zbog negativnog antropogenog utjecaja na drenažnu mrežu sliva. Primjer bujice prikazan je na Slici 1.



*Slika 1. Prikaz primjera bujice (autor: Ivana Sušanjanj)*

Muljni tok se može definirati kao veoma brzi ili ekstremno brzi vodni val ispunjenim saturiranim tlom plastične konzistencije (Indeks plastičnosti > 5%) u strmim kanalima s velikim udjelom vode u odnosu na količinu mulja. U nekim područjima, debritni tok čini krupnozrnati materijal s vrlo malim udjelom mulja i gline, dok je u područjima na kojima postoje sedimenti, vulkanske i metamorfne stijene te stijene s izraženim trošenjem udio sitnih sedimenata visoke plastičnosti značajno veći. Takva vrsta tla ostaje duže u vodi u obliku lebdećeg nanosa te putuje do područja manjeg pada gdje se taloži. Granica između debritnog toka i

muljnog toka određena je udjelom materijala plastične konzistencije u vodi i veličinom zrna sedimenata. Za nastanak muljnog toka potrebne su velike količine vode nastale primjerice pod utjecajem iznenadnih oborina velikog intenziteta, topljenja snijega ili glečera (Hungri i sur., 2014). Primjer muljnoga toka prikazan je na *Slici 2*.



*Slika 2. Prikaz primjera muljnog toka (autor: Ivana Sušan)*

Debritna poplava se definira kao veoma brzi protok vode ispunjen kamenim odlomcima i sitnozrnatim materijalom u strmim kanalima prilikom čega dolazi do pronosa materijala koji se nalazi u samom kanalu (Hungri i sur., 2014). Debritnom poplavom pronos materijala je veći nego kod uobičajenih mehanizma vučenog nanosa pod kojima se definiraju kotrljanje, kliženje i saltacija (Benac, 2016). Prilikom pojave ove štetne pojave voda može transportirati velike količine sedimenata no maksimalni protok vode ostaje isti kao i kod pojave bujice iako je tok osnažen kamenim odlomcima i sitnozrnatim materijalom. Za razliku od debritnog toka, kod debritnih poplava se ne razvijaju toliko velike sile pa je manja mogućnost nastanka infrastrukturnih štetnih pojava. Mogućnost nastanka štete ovisi i o obliku korita vodotoka u kojem nastaje debritna poplava te o podrijetlu toka vode. Dok je debritni tok ograničen na veoma strme kanale te površinu sliva od nekoliko kvadratnih kilometara, debritna poplava se može javiti na mnogo većim slivovima i kao popratna pojava bujice. Također, za razliku od debritnog toka, kod debritnih poplava pronos krupnozrnatog materijala je izraženiji pa se



deponiranje materijala događa na nizvodnim dijelovima vodotoka manjeg nagiba (< 5%). Razlika između bujične i debritle poplave je vidljiva u pronosu krupnozrnatog materijala koji je sastavni dio debritle poplave dok je razlika između debritle poplave i debritle toka u samom mehanizmu nastanka pronosa materijala te u štetnom potencijalu (Hungar i sur., 2014). Primjeri debritle poplave prikazani su na *Slici 3.* i *Slici 4.*



*Slika 3. Prikaz primjera debritle poplave 1 (autor: Ivana Sušanj)*



*Slika 4. Prikaz primjera debritle poplave 2 (autor: Ivana Sušanj)*

### **2.1.2. Rizik i ranjivost**

Rizik se definira kao očekivani stupanj štete kod pojave hazarda u odnosu na gubitak ljudskih života, infrastrukturne štete kao i štetan utjecaj na okoliš. Rizik uključuje kvantifikaciju vjerojatnosti događaja nekog oblika hazarda koji može imati štetne posljedice. U praksi se procjenjuje prihvatljiv stupanj rizika (Benac, 2016).

Ranjivost se definira kao stupanj gubitaka određenih elemenata ili grupe elemenata kod pojave rizika određene magnitude. Ranjivost je izražena na ljestvici od 0 (nema štete) do 1 (potpuna šteta ili gubitak) (Benac, 2016).

## **2.2. Mjere za umanjeње štetnih pojava**

U grani hidrotehnike mjere za umanjeње štetnih pojava mogu se podijeliti u dva razreda: (i) Strukturalne mjere i (ii) Nestrukturalne mjere. Strukturalnim mjerama za umanjeње štetnih pojava u hidrotehnici smatra se izgradnja poprečnih i uzdužnih hidrotehničkih građevina kao što su brane, pregrade, nasipi i druge. Izgradnja pojedinih objekata može iziskivati velika novčana ulaganja no ni tada nema garancije da će takva građevina umanjiti ili spriječiti štetnu pojavu. Nestrukturalne mjere mogu se podijeliti u dvije grupe. Prva grupa nestrukturalnih mjera obuhvaća utjecaj na okoliš primjerice pošumljavanjem, pravovaljanim urbanističkim planiranjem i planom upravljanja poplavama. Ovakve mjere su dugoročne te ne jamče uspjeh u smislu umanjeња ili sprečavanja štetnih pojava te mogu utjecati na promjenu lokacije nastanka štetne pojave. U drugu grupu nestrukturalnih mjera spadaju sustavi ranog uzbunjivanja. Cilj sustava ranog uzbunjivanja je umanjeње posljedica štetnih pojava, a njegova upotreba je preporučljiva u slučaju kada nije moguće umanjiti ili spriječiti štetnu pojavu prvotno strukturalnim, a potom i prvom grupom nestrukturalnih mjera (Corzo Perez, 2009).

U Republici Hrvatskoj aktivnosti i mjere za obranu od štetnih pojava uzrokovanih vodom propisane su Zakonom o vodama (NN 153/09, 63/11, 130/11, 56/13, 14/14). Zakon obuhvaća niz strukturalnih i nestrukturalnih mjera u cilju zaštite od štetnog djelovanja vode kao što su: izrada prethodne procjene rizika od poplava, izrada i provedba planova upravljanja rizicima od poplava i Državni plan obrane od poplava, provedba obrane od leda na vodotocima, zaštita od erozije i bujica, osnovna melioracijska odvodnja i provedba ograničenja prava vlasnika i drugih posjednika zemljišta.

U kontekstu upravljanja hidrotehničkim štetnim pojavama kao što su poplave, bujične poplave, muljni tokovi i debritne poplave, hidrološki modeli predviđanja otjecanja su temelj razvoja sustava ranog uzbunjivanja, pa stoga privlače interes velikog broja znanstvenika.

### 2.3. Sustav ranog uzbunjivanja

Štetne pojave koje su uzrokovane djelovanjem vode, moguće je umanjiti ili spriječiti posljedice istih uz pomoć sustava za rano uzbunjivanje, a njegova primarna zadaća je obznanjivanje informacija o mogućnosti nastanka štetne pojave. U tom slučaju sustav ranog uzbunjivanja ima ključnu ulogu u prevenciji negativnih posljedica (Papa, 2103).

Prema Međunarodnoj strategiji Ujedinjenih nacija za smanjenje rizika od katastrofa (*eng. United Nations International Strategy for Disaster Reduction (UN/ISDR, 2009)*) sustav ranog uzbunjivanja se definira kao: „Skup kapaciteta potrebnih za izradu i dostavljanje pravovremene i smislene informacije upozorenja kako bi se omogućilo pojedincima, zajednicama i organizacijama kojima prijete opasnost da se pripreme i djeluju na odgovarajući način i u odgovarajuće vrijeme u cilju smanjivanja moguće štete ili gubitaka“. Kvalitetni i efikasni sustav ranog uzbunjivanja se sastoji od četiri povezana elementa a koja su: (i) Identifikacija rizika, (ii) Praćenje i služba uzbunjivanja, (iii) Diseminacija i komunikacija i (iv) Mogućnost odziva kao što je prikazano na *Slici 5. (UN/ISDR, 2009)*.



Slika 5. Elementi sustava ranog uzbunjivanja; prikaz izradila: Ivana Sušanjanj prema (UN/ISDR, 2009)

### **2.3.1. Identifikacija rizika**

Rast rizika nastaje kombinacijom hazarda i ranjivosti određenog područja. Procjena rizika iziskuje sustavni pristup sakupljanju i analizi podataka kao i cjelokupnom sagledavanju dinamičke prirode hazarda i ranjivosti, koji proizlaze iz procesa kao što su primjerice urbanizacija, promjena ruralne upotrebe zemljišta, degradacija okoliša i klimatske promjene. Uz pomoć procjene rizika, moguće je definirati potrebu za implementacijom sustava za rano uzbunjivanje kao i izraditi upute za upravljanje rizicima te umanjeње rizika (UN/ISDR, 2009).

### **2.3.2. Praćenje i služba uzbunjivanja**

Služba uzbunjivanja je jezgra sustava ranog uzbunjivanja. Za potrebe uspostave sustava ranog uzbunjivanja mora postojati čvrsto znanstveno uporište za predviđanje i prognoziranje štetnih pojava te pouzdan sustav prognoziranja i uzbunjivanja koji djeluje bez prestanka. Uspostava kontinuiranog mjerenja varijabli koje uzrokuju štetne pojave je od izuzetne važnosti za uspostavu vremenski preciznog sustava uzbunjivanja. Služba uzbunjivanja treba biti, s obzirom na prirodu štetne pojave, dobro povezana s institucionalnom, proceduralnom i komunikacijskom mrežom kako bi njena zadaća bila u potpunosti provedena. Efikasni sustav ranog uzbunjivanja u cilju zaštite od štetnih pojava uzrokovanih djelovanjem vode, temelji se na hidrološkom modelu predviđanja i prognoziranja te omogućuje pravovremeno obznanjivanje potencijalne opasnosti (UN/ISDR, 2009).

### **2.3.3. Diseminacija i komunikacija**

Diseminacija i komunikacija je važan dio sustava ranog uzbunjivanja jer je njen cilj pravovremeno upozorenje svih onih koji su pod utjecajem moguće štetne pojave. Jasne poruke koje se sastoje od jednostavnih i korisnih informacija su od iznimne važnosti za omogućavanje odgovarajućeg djelovanja prilikom kojeg dolazi do spašavanja života i sredstava za život. Regionalna, nacionalna i društvena razina sustava komunikacije mora biti prethodno definirana kao i vjerodostojan izvor informacija. Upotreba više različitih načina informiranja neophodna je u cilju protoka obavijesti o upozorenju do što većeg broja ljudi, te u slučaju otkazivanja pojedinih načina odašiljanja obavijesti, osiguranje protoka informacija (UN/ISDR, 2009).

### **2.3.4. Mogućnost odziva**

Pri mogućnosti odziva, od presudne je važnosti da je zajednica upoznata s rizikom, da poštuje odaslane upozorenja službe uzbunjivanja i da zna kako djelovati u slučaju nadolaska štetne pojave. Ključnu ulogu u tom slučaju čine edukacijski programi. Plan upravljanja katastrofama također mora biti dobro osmišljen, svrsi shodan i testiran kako bi mogućnost odziva stanovništva i njegova djelovanja, pri nailasku štetne pojave, bila što veća. Zajednica mora biti dobro informirana o načinima dobrog djelovanja, mogućim putevima izbjegavanja katastrofom obuhvaćenog prostora te načinima izbjegavanja štete i gubitaka na osobnoj imovini (UN/ISDR, 2009).

## **2.4. Hidrološki modeli**

Hidrološki sustav se općenito kao što je opisao Dooge (1973) može pojednostavljeno definirati kao sklop fizikalnih, kemijskih i/ili bioloških procesa koji djeluju s obzirom na ulaznu varijablu ili varijable i pretvaraju ih u izlaznu varijablu ili varijable.

Varijabla je karakteristika sustava koja se može mjeriti te može imati različite vrijednosti u određenom vremenu mjerenja. Primjeri varijabli u hidrologiji su dnevna količina oborine, otjecanje, evapotranspiracija, temperatura, infiltracija, vlažnost tla i ostale.

Parametar je kvantitativna karakteristika sustava, koja može ali i ne mora biti konstantna u vremenu no u mnogo slučajeva se pri modeliranju sustava smatra konstantnom.


Model je pojednostavljeni prikaz kompleksnog sustava. Stoga, model uvijek opisuje temeljne i najvažnije sastavne dijelove kompleksnog sustava. Prema Dooge (1977) model obuhvaća sličnost bez istovjetnosti te simulira neke no ne sve karakteristike prototipnog sustava.

Svaki razvijeni model treba proći i kroz proces, verifikacije ili validacije te potom kroz proces evaluacije ili testiranja kako bi se utvrdila kvaliteta modela. Verifikacija ili validacija se definira kao proces potvrde modela i njegovih mogućnosti u ispunjenju zahtjeva i/ili uvjeta zadanih određenim ciljem na početku. Evaluacija ili testiranje modela se definira kao proces provjere ili procjenjivanja



modela i njegovih mogućnosti u ispunjenju zahtjeva i/ili uvjeta zadanih određenim realnim sustavom (Dooge, 1977).

U znanstvenoj grani hidrologije sliv se može smatrati hidrološkim sustavom. Granica sustava definirana je iscrtanom topografskom ili hidrogeološkom razvodnicom (vododijelnicom) koja se projicira na horizontalnu ravninu iznad i ispod ravnine sliva čineći sustav kao što je prikazano na *Slici 6*. (Chow i sur., 1973).



*Slika 6. Sliv kao hidrološki sustav; prikaz izradila: Ivana Sušan prema Chow i dr. (1988)*

Cilj analize hidroloških sustava je izučavanje djelovanja sustava i predviđanje njegovih izlaznih varijabli. Model hidrološkog sustava je aproksimacija stvarnog sustava odnosno njegovih ulaznih i izlaznih mjerljivih varijabli, a strukturiran je po konceptu transformacije sustava (Xu, 2002).


Danas je u upotrebi veliki broj raznovrsnih hidroloških modela. Odabir pojedine vrste modela najviše ovisi svrsi samoga modela i količini dostupnih mjerenih varijabli. Veliki broj modela ima svrhu istraživanja hidroloških procesa ili

predviđanja određenih hidroloških varijabli dok drugi služe kao alat pri donošenju odluka pri planiranju i djelovanju (Xu, 2002).

#### **2.4.1. Sliv i čimbenici otjecanja**


Prema Žugaju (2000) sliv se može definirati kao područje na kojem dolazi do odljeva vode nastalog površinskim otjecanjem. Sliv se može promatrati u užem i širem smislu pa se tako slivom u užem smislu naziva površina s koje se voda slijeva prema glavnom sabiraču odnosno vodotoku. U širem smislu sliv označava sve kopnene površine s kojih vodne mase ulaze u oceane, mora ili jezera.

Granice sliva određene su razvodnicom (vododijelnicom) koja čini graničnu liniju između susjednih slivova. Razlikujemo topografsku i hidrološku (hidrogeološku) vododijelnicu. Topografska razvodnica se određuje na topografskoj karti na temelju položaja slojnica terena odnosno u slučaju geološki povoljnih uvjeta dijeli susjedne slivove po najvišim točkama terena. Razvodnica u mnogo slučajeva ne ovisi samo o topografiji već prvenstveno o geološkim i hidrogeološkim uvjetima pa tada govorimo o hidrološkoj odnosno hidrogeološkoj razvodnici. Hidrološka razvodnica ovisi o podzemnoj razini vode te s obzirom na promjene razina nije stalna pa se u takvim slučajevima (određivanje razvodnice na krškom području) razmatra takozvani utjecajni sliv koji obuhvaća podzemno i površinsko otjecanje. Određivanje hidrološke razvodnice je zahtjevan zadatak za čiju su analizu potrebne geološke podloge te rezultati hidrogeoloških istražnih radova. Na *Slici 7.* prikazani su topografski i utjecajni sliv s obzirom na geološke uvjete (Žugaj, 2000).



Slika 7. Shematski prikaz razlike topografskog i utjecajnog sliva tlocrtno i presjekom A--A; prikaz izradila: Ivana Sušanj prema Žugaj (2000)

Otjecanje sa sliva ovisi o nizu čimbenika kao što su (i) Zemljopisni, (ii) Geološki, (iii) Biološki, (iv) Klimatski i (v) Antropološki. Na *Slici 8.* prikazani su čimbenici koji utječu na uvjete otjecanja sa sliva s objašnjenjem (Žugaj, 2000).



*Slika 8. Čimbenici koji utječu na otjecanje sa sliva; prikaz izradila: Ivana Sušan prema Žugaj (2000)*

Prilikom izrade raznovrsnih hidroloških analiza sliva ili hidroloških modela od velike je važnosti, kao što je ranije spomenuto, analizirati sve čimbenike koji utječu na otjecanje sa sliva kao što su geografski položaj, geološku građu, klimatske uvjete te općenito fizičke osobine sliva koje povezuju više vrsta čimbenika otjecanja, a predstavljaju ishodišnu točku za daljnje istraživanje sliva (Žugaj, 2000).

Osnovne fizičke osobine sliva su: (i) Površina i oblik sliva, (ii) Srednja nadmorska visina sliva, (iii) Pad sliva, (iv) Pad vodotoka te (v) Gustoća rječne mreže, a u nastavku će biti opisani (Žugaj, 2000).

### Površina i oblik sliva

Površinu sliva kao što je ranije opisano određujemo topografski ili hidrogeološki, a oblik sliva se opisuje koeficijentom koncentriranosti sliva  $K$ . Ukoliko je oblik sliva bliži krugu i koeficijent koncentriranosti sliva  $K$  je bliži jedinici. O obliku sliva ovisi veličina i trajanje hidrograma vodnih valova. Oblik sliva osim uz

pomoć koeficijenta koncentriranosti sliva određujemo i vizualno pa se oblik može klasificirati kao izduženi, lepezasti ili primjerice okrugli. Koeficijent koncentriranosti sliva moguće je izračunati na više načina prema različitim autorima pa je tako u izrazu (1) prikazan izraz prema D. Srebrenoviću, u izrazu (2) prema R.E. Hortonu i prema H.Graveliusu u izrazu (3) (Žugaj, 2000; Srebrenović, 1986)

$$K = \frac{2 \cdot A}{O \cdot U} \quad (1)$$

$$K = \frac{A}{L^2} \quad (2)$$

$$K = \frac{0,28 \cdot O}{\sqrt{A}} \quad (3)$$

Gdje je:

$K$  – Koeficijent koncentriranosti [–]

$A$  – Površina sliva [ $km^2$ ]

$O$  – Opseg sliva [ $km$ ]

$U$  – Udaljenost od težišta sliva do protjecajnog mjernog profila [ $km$ ]

$L$  – Duljina glavnog vodotoka [ $km$ ]

### Srednja nadmorska visina sliva

Srednja nadmorska visina sliva definira se kao vodoravna linija koja hipsometrijsku krivulju dijeli tako da površine iznad i ispod hipsometrijske krivulje te crte jednake (Žugaj, 2000). Srednja nadmorska visina se osim na ovaj način, uz pomoć hipsometrijske krivulje, može dobiti i analizom digitalnog elevacijskog modela (*eng. Digital Elevation Model, DEM*) u različitim programskim paketima, što je u današnje vrijeme puno uobičajenije.

### Pad sliva

Pad sliva se definira kao odnos površine ispod hipsometrijske krivulje i krivulje površina sliva. Kao i u prihodnom slučaju u današnje vrijeme pad sliva se ponajviše dobiva analizom digitalnog elevacijskog modela (Žugaj, 2000).

### Pad vodotoka

Pad vodotoka je prikaz dionice ili cijelog vodotoka duž osi protjecanja, prikazan u nadmorskim ili relativnim visinama. Najtočnije se određuje na temelju geodetske snimke uzdužnog presjeka, a uobičajeno se definira maksimalni i srednji pad vodotoka. Kao i u ranijim slučajevima i u ovom slučaju moguće je

dobiti pad vodotoka na temelju analize digitalnog elevacijskog modela no njegova točnost će biti manja nego pri geodetskim mjerenjima (Žugaj, 2000).

### Gustoća drenske mreže

Drensku mrežu nekog sliva predstavljaju svi vodotoci (stalni, isprekidani i povremeni). Najčešće se računa specifična gustoća riječne mreže  $D$  a definirana je izrazom (4). Prema specifičnoj gustoći riječne mreže može se razlikovati dobro ( $D > 4 \text{ km/km}^2$ ), srednje ( $D = 1 - 4 \text{ km/km}^2$ ), i slabo dreniran sliv ( $D < 1 \text{ km/km}^2$ ) (Žugaj, 2000).

$$D = \frac{\sum L}{A} \quad (4)$$

Gdje je:

$D$  – Gustoća drenske mreže [ $\text{km/km}^2$ ]

$A$  – Površina sliva [ $\text{km}^2$ ]

$L$  – Duljina vodotoka [ $\text{km}$ ]

### **2.4.2. Mali sliv**

Razvoj hidrološkog modela predviđanja za određeni sliv ili područje smatra se zahtjevnim zadatkom koji postaje još veći izazov ukoliko se model razvija primjerice za mali sliv prilikom čega posebnu pažnju treba posvetiti uspostavi dugotrajnog kontinuiranog mjerenja relevantnih meteoroloških i hidroloških varijabli, prikupljanju povijesnih podataka, pripremi i obradi podataka te validaciji i evalvaciji razvijenog hidrološkog modela (Dooge, 1973).

Prema nekim autorima, mali sliv se definira kao onaj čija je površina manja od  $1000 \text{ km}^2$ , a češće se naziv mali sliv odnosi na slivove čija je površina manja od  $400 \text{ km}^2$  (Žugaj, 2000) no u nekim se slučajevima, kao granična površina, definira ona od  $5 \text{ km}^2$  (Moldan i Černy, 1994).

U hidrološkom smislu teško je odrediti granicu između malog i velikog sliva samo na temelju njegove površine. Pri definiranju maloga sliva potrebno je uzeti u obzir čimbenike koji utječu na uvjete otjecanja sa sliva. Svojstvo koje zasigurno najbolje definira mali sliv kao takav je ujednačena količina oborine koja pada na sliv odnosno uvjet da prilikom nastupanja oborina cjelokupni sliv sudjeluje u otjecanju i nastanku hidrograma otjecanja. S obzirom da je svaki sliv specifičan po svojim, već ranije spomenutim, čimbenicima koji utječu na uvjete otjecanja,

potrebno je pri definiranju veličine sliva, odnosno njegovoj klasifikaciji kao malog ili velikog, proučiti svaki sliv sam za sebe (Žugaj, 2000).

Kada se opisuje male slivove, a koji se odlikuju bujičnim karakteristikama, važno je naglasiti njihovo obilježje kao što je brzi odziv na pale oborine pa shodno tome i mogućnost nastanka štetne pojave koje se pojavljuju u obliku bujice, muljnog toka i debrine poplave. Drugim riječima vrijeme od nastupanja oborina velikog intenziteta do otjecanja u kojemu sudjeluje cjelokupna površina sliva, pritom tvoreći naglo podizanje hidrograma otjecanja, može biti vrlo kratko što otežava mogućnost predviđanja štetne pojave. Upravo zbog toga potrebno je istražiti mogućnosti razvoja hidroloških modela predviđanja otjecanja na malim slivovima.

### **2.4.3. Povijesni razvoj hidroloških modela**

Povijesni razvoj hidroloških modela bit će kronološkim redom opisani u nastavku rada prilikom čega će biti spomenuti najznačajniji znanstvenici te njihova otkrića.

Začetke hidroloških modela otjecanja u širokom smislu moguće je naći sredinom devetnaestog stoljeća kada se javlja potreba za izradom modela kao odgovor na tri vrste inženjerskih problema: (i) projektiranje urbane kanalizacije, (ii) projektiranje melioracijskih sustava i (iii) projektiranje sustava akumulacija. Kod sva je tri spomenuta inženjerska problema protok bio jedna od glavnih varijabli istraživanja (Xu, 2002).

Pri istraživanju melioracija prvi je irski inženjer Mulvany (1850) razvio koncept Racionalne metode koja je služila za utvrđivanje maksimalnih protoka na temelju palih oborina, a koju je dalje američki inženjer Kuichiling (1889) primijenio i pri projektiranju kanalizacije. Racionalna metoda za izračunavanje vršnog protoka temelji se na pretpostavkama da je količina i intenzitet oborine jednoliko raspoređen po površini sliva pa je zbog toga primjena ove metode ograničena na manje slivove te urbane površine.

S obzirom na ograničenja Racionalne metode ubrzo se javila potreba i za razvijanjem metoda koje će biti prihvaćene na slivovima većih površina pa se tako 1920-ih godina razvijaju različite modifikacije Racionalne metode kako bi se mogla nositi s nejednolikom distribucijom oborine i fizičkih karakteristika sliva u prostoru i

vremenu. Modificirana Racionalna metoda temelji se na konceptu izokrona. Izokrone su linije koje povezuju isto vrijeme putovanja vode na slivu pa se ova metoda može smatrati prvim modelom otjecanja koji funkcijom povezuje oblik i parametre sliva dobivene putem topografskih podloga i upotrebu Manningove formule za vrednovanje vremena putovanja vode na slivu (Xu, 2002).

1930-ih godina velikim iskorakom u području hidrološke analize smatra se postavljanje koncepta jediničnog hidrograma temeljenog na superpoziciji kojeg je predstavio američki inženjer Sherman (1932). Upotreba jediničnog hidrograma omogućila je ne samo izračunavanje vršnog protoka već i promatranje cjelokupnog hidrograma otjecanja odnosno volumena otekle oborine iako se metoda temeljila na mnogo pretpostavki kao što je primjerice pretpostavka da se sliv ponaša kao uzročno linearno invarijantni sustav u vremenu u odnosu palih oborina naspram otekle oborine. Krajem 30-ih i tokom 40-ih godina prošlog stoljeća dolazi do daljnjeg razvoja koncepta jediničnog hidrograma s ciljem poboljšanja objektivnosti i rezultata metode te započinje i razvoj statističke analize podataka (Xu, 2002).

Kada su hidrolozi 1950-ih godina postali svjesni da je za sustavni inženjerski pristup potrebna analiza složenog dinamičkog sustava dolazi do veoma značajnog razvoja modela. Uviđanjem ograničenja metode jediničnog hidrograma, priklanjaju se matematičkim metodama kao što su Laplace-ova, Fourier-ova i Z transformacija s kojima se opisuje funkcija odnosa pale oborine i otekle oborine. Na taj su način nastali konceptualni modeli. Konstruiranje jediničnog hidrograma u diskretiziranom obliku iz mjerenih podataka (poznato kao inverzni problem) je u to vrijeme još uvijek predstavljalo težak zadatak zbog relativno nelinearnog ponašanja sustava te općenito velikih pogrešaka u ulaznim i izlaznim podacima. Poboljšanje jediničnog hidrograma dolazi u smislu promjene oblika jediničnog hidrograma manje više jednostavnim diferencijalnim jednadžbama što je omogućilo da se jedinični hidrogram konstruira na temelju više različitih statističkih parametara kao što su moment, regresija, vjerojatnost i ostali. Takav pristup konstruiranju jediničnog hidrograma doveo je do cijelog niza različitih primjena kao što su modeli linearnog i nelinearnog rezervoara, model linearnog kanala i ostali. Bez obzira na veliki razvoj u konstruiranju jediničnog hidrograma, hidrolozima je u to vrijeme, problem predstavljalo konstruiranje jediničnog hidrograma iz mjerenih



podataka, odnosno opaženog hidrograma kao posljedice izolirane ili kompleksne oborine (Xu, 2002). U tom su području postignuta tek pokoja dostignuća među kojima se ističu radovi čiji su autori Tikhonov (1963), a nakon njega Eagleson i sur. (1965) te Natale i Todini (1977). Ovi znanstvenici su dali osnove u promatranju kontinuiteta i regulaciju ograničenja u fazi procjene što je dovelo do realnijih i pouzdanijih konstrukcija jediničnih hidrograma.

Novi pristupi modeliranju otjecanja razvijaju se tokom 60-ih godina prošlog stoljeća. Težnja istraživača usmjerena je ka fizikalnoj interpretaciji procesa koji je u mogućnosti opisati ponašanje određene komponente hidrološkog ciklusa u mjerilu sliva, a koji je povezan raznim konceptualnim elementima, prilikom čega svaki od procesa predstavlja pojedini podsustav (Xu, 2002). Takvim novim pristupom dolazi do razvoja konceptualnih, cjelovitih modela otjecanja koje u svojim radovima ističu Dawdy and O'Donnell (1965), potom Cawford i Linsley (1966) s modelom *Stanford Model IV*, zatim Bergström i Forsman (1973) s *HBV* modelom i Svjetska Meteorološka organizacija (*eng. World Meteorological Organization; WMO*) (1975) s *Tank modelom*. Spomenuti modeli smatraju se najznačajnijima i tokom 70-ih godina prošlog stoljeća.

U 70-im godinama prošlog stoljeća hidrolozi predstavljaju alternativne modele kao što su modeli autoregresivnog pomičnog prosjeka pa tako nastaje ARMA model kojeg su predstavili Box i Jenkins (1970) i drugi oblici stohastičkih modela vremenske serije. U to vrijeme razvijaju se i prvi modeli predviđanja u realnom vremenu u cilju uzbunjivanja na poplavama sklonim prostorima te kao alat za upravljanje akumulacijama i drugim hidrotehničkim objektima. Ovi modeli su općenito bili temeljeni na tehnici stalnog ažuriranja i rekabriranja kao što je primjerice Kalman-ov filter (Kalman, 1960). Kasnih 70-ih godina prošlog stoljeća hidrolozi Beven i Kirkby (1979) razvili su jedan od najznačajnijih modela pod imenom *TOPMODEL*. Temeljna ideja modela je da dominantnu kontrolu puta tečenja vode u brdima imaju topografske karakteristike terena. Osim toga model je u mogućnosti ne samo konstruirati hidrogram otjecanja već i dati podatke koji su korisni pri povezivanju hidroloških s hidrokemijskim izračunima.

Kako se razvijala potreba za predviđanjem posljedica promjene upotrebe zemljišta, prostorne raspodjele ulaznih i izlaznih varijabli modela, kretanja onečišćenja i sedimenata te hidroloških veličina na neizučnim cjelovitim slivovima

na kojima nisu dostupni mjereni podaci za kalibriranje, tako se razvijaju i fizikalni raščlanjeni modeli. Najsofisticiraniji modeli toga doba sagledavaju tečenje vode u tri dimenzije s supraponiranoj vertikalnoj mreži prostora što otvara prostor upotrebi digitalnih elevacijskih modela (*DEM*) ili podataka dobivenim iz rasteriziranih satelitskih snimaka što omogućava implementiranje raznih podataka u modele kao što su vegetacijski pokrov terena, raspodjela vlažnosti tla ili podpovršinsko otjecanje (Xu, 2002). Kao rezultat multinacionalnog programa Europska zajednica (*eng. European Union, EU*) u to vrijeme predstavlja model pod nazivom *The Système Hydologique Européen* ili kraticom *SHE* koji predstavlja dobar primjer opisanog razvoja modela (Abbott i sur., 1986).

Daljnji razvoj modela u 80-im godinama prošlog stoljeća kreće se, s obzirom na potrebe hidrologa, prema modelima velikih kontinentalnih mjerila. Potreba za razvojem makro modela proizašla je iz raznolikosti upravljačkih i planskih svrha, odgovornog upravljanja vodnim resursima na velikim područjima te utjecaja upotrebe zemljišta, klimatskih promjena i pokrova zemljišta na velikim geografskim domenama kao i praćenja utjecaja izvora onečišćenja i njihovog utjecaja na vodotoke u širem smislu (Xu, 2002). Primjeri makro modela koji su temeljeni na Geografsko Informacijskom Sustavu (*eng. geographic information system, GIS*) smatraju se pravim dostignućem, a najznačajniji su doprinos dali Vörösmarty i sur. (1989), potom Wood i sur. (1992) modelom *VIC* i Arnell (1999) s modelom *Macro-PDM*. Kronološki pregled povijesnog razvoja hidroloških modela prikazan je u *Tablici 1*.

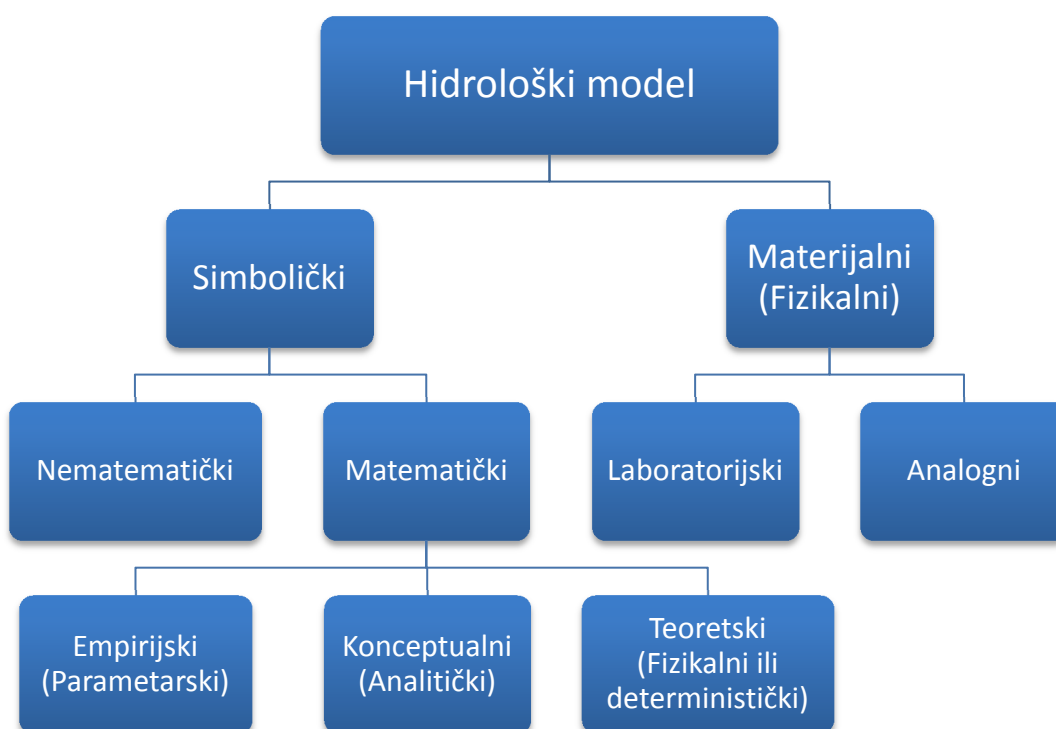
Od tada pa do danas, u korak s razvojem računalne tehnologije, razvoj hidroloških modela bilježi stalan rast te su danas hidrolozi najviše usmjereni ka razvoju matematičkih modela s ciljem rješavanja problema u hidrologiji.

Tablica 1. Kronološki pregled razvoja hidroloških modela kroz povijest

Godina	Model	Autor
1850	Koncept Racionalne metode	Mulvaney, T.J.
1889	Primjena Racionalne metode	Kuichling, E.
1932	Jedinični hidrogram	Sherman, L.K.
1963	Konstruiranje jediničnog hidrograma iz mjerenih podataka	Tikhonov, A.N.
1965	Konceptualni cjeloviti modeli	Dawdy, D.R. i O'Donnell, T.
1965	Konstruiranje jediničnog hidrograma iz mjerenih podataka	Eagleson, P.S., Mejia, R. i March, F.
1966	Konceptualni cjeloviti modeli (Stanford model IV)	Crawford, N.H. i R.K. Linsley R.K.
1970	Modeli autoregresivnog pomičnog prosjeka ARMA (Autoregressive Integrated Moving Average)	Box, G.E.P. i Jenkins, G.M.
1973	Konceptualni cjeloviti modeli (HBV model)	Bergström, S. i Forsman, A.
1975	Konceptualni cjeloviti modeli (Tank model)	Svjetska Meteorološka organizacija (eng. World Meteorological Organization)
1979	Modeli predviđanja u realnom vremenu (TOPMODEL)	Beven, K.J. i Kirkby, M.J
1986	Fizikalni raščlanjeni modeli (The Systéme Hydologique Européen (SHE))	Europska zajednica (eng. European Community)
1989	GIS makro-modeli	Vörösmarty, C.J., Moore, B., Grace, A.L.
1992	GIS makro-modeli VIC	Wood, E.F., Lettenmaier, D.P., Zartarian, V.G.
1999	GIS makro-modeli MacroPDM	Arnell, N. W.

#### 2.4.4. Klasifikacija hidroloških modela

Danas je u uporabi velik broj hidroloških modela. Klasificiramo ih ovisno o rezultatima koje želimo dobiti te ovisno u parametrima s kojima raspolažemo prilikom uporabe modela. Glavna podjela hidroloških modela koju je dao Singh (1988) prikazana je na *Slici 9*.



Slika 9. Klasifikacija hidroloških modela otjecanja; prikaz izradila: Ivana Sušanjanj prema Singh (1988)

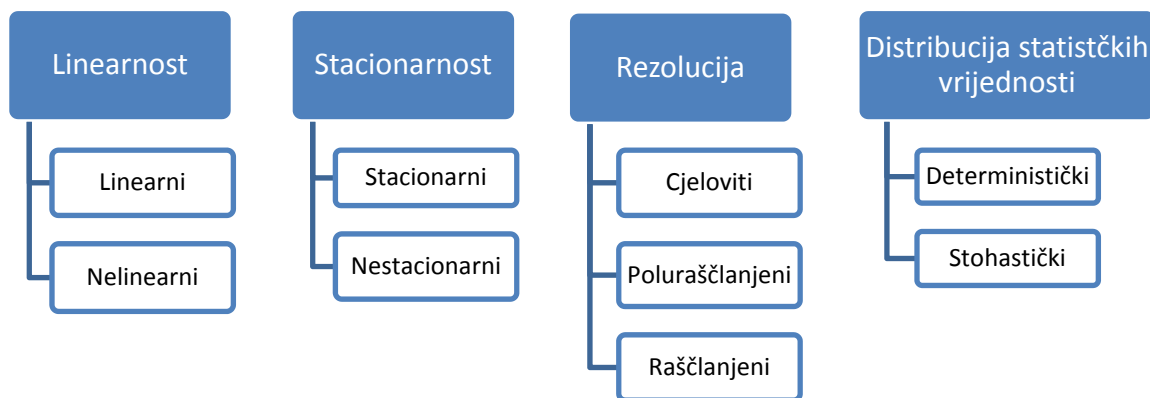
Glavna podjela modela razlikuje simboličke od materijalnih modela. Materijalni modeli zamjenjuju realni sustav s drugim sustavom koji je sličnih karakteristika no jednostavniji za korištenje i analiziranje. Simbolički modeli, koje Chow i sur. (1988) nazivaju još i apstraktnim modelima, karakterizira simboličko logično izražavanje relativno jednostavnim prikazom koji ima glavna tvorbena obilježja originalnog sustava. Najčešći takvi modeli su temeljeni na matematičkim simbolima. Glavna razlika između empirijskih, konceptualnih i teoretskih modela, na koje se dijele matematički modeli, je u promatranju fizikalnih procesa unutar modela. Empirijski modeli koji se još nazivaju i modelima crne kutije ne posjeduju fizikalna objašnjenja procesa te se sastoje od niza parametara koji su dobiveni na temelju povezivanja ulaznih i izlaznih podataka modela koji su dobiveni terenskim mjerenjem. S druge strane teoretski modeli koji se nazivaju i modelima bijele kutije

sadrže opise suštinskih fizikalnih procesa te logičku strukturu sličnu realnom sustavu koji opisuju. Konceptualni modeli koji se još nazivaju i modelima sive kutije se svojim karakteristikama mogu smjestiti između empirijskih i teoretskih modela. Hidrološki modeli se mogu smatrati konceptualnima ukoliko je fizikalni proces, koji povezuje ulazne s izlaznim podacima, opisan funkcijom. Funkcije su uobičajeno temeljene na fizikalnim zakonitostima no u pojednostavljenom obliku (Xu, 2002). U *Tablici 2.* prikazani su primjeri prvih matematičkih modela i njihovih autora.

*Tablica 2. Primjeri prvih matematičkih modela i njihovih autora*

Vrsta modela	Naziv modela	Autori
<b>Simbolički matematički empirijski model</b>	Model autoregresivnog pomičnog prosjeka ; ( <i>eng. Autoregressive moving average model; ARMA</i> )	Box i Jenkins (1970)
<b>Simbolički matematički teoretski model</b>	Model infiltracije temeljen na teoriji tečenja u poroznom okruženju	Morel-Seytoux (1978)
	Model evaporacije temeljen na teorijama turbulencije i difuzije	Brutsaert i Mawdsley (1976)
	Model podzemnog kretanja vode temeljen na osnovnoj jednadžbi gibanja	Freeze (1971)
	The Systéme Hydologique Européen model (SHE)	Abbott i sur. (1986)
<b>Simbolički matematički konceptualni model</b>	HBV model	Bergström i Forsman (1973)

Osim osnovne podjele simboličkih matematičkih modela na empirijske, teoretske i konceptualne, modele se može dijeliti po njihovoj linearnosti, stacionarnosti, rezoluciji te distribuciji statističke vjerojatnosti. Na *Slici 10.* prikazana je podjela simboličkih matematičkih modela prema spomenutim kriterijima.



Slika 10. Podjela simboličkih matematičkih modela; prikaz izradila: Ivana Sušanj prema Singh (1988)

Model se smatra linearnim u smislu teoretskog sustava ukoliko je načelo superpozicije sadržano od linearne funkcije koja povezuje ulazne podatke modela s izlaznim dok je u suprotnom model nelinearan. Stacionarnim modelom smatra se onaj u kojemu izlazni podaci modela ovise isključivo o ulaznim podacima neovisno o vremenu ulaznih podataka dok su oni kod kojih ulazni podaci ovise o vremenskoj komponenti nestacionarni. Modele je moguće podijeliti i prema rezoluciji odnosno raščlanjenosti s kojom se tretira sliv odnosno sustav kojeg obuhvaća model. S obzirom na takvu podjelu sliva razlikujemo: (i) cjelovite, (ii) poluraščlanjene i (iii) raščlanjene modele. Cjeloviti modeli (*eng. Lumped model*) tretiraju sliv kao jednu homogenu cjelinu. Poluraščlanjeni modeli dijele sliv na određene površine primjerice izokronalnom ili podslivnom podjelom dok je kod raščlanjenih modela cjelokupna površina sliva podijeljena u elementarne površinske jedinice metodom konačnih razlika ili metodom konačnih elemenata. Razlika između determinističkih i stohastičkih modela je u varijablama koje se koriste pri modeliranju pa se tako kod determinističkih modela koriste slučajne slobodne varijable koje nije moguće statistički povezati vjerojatnošću pojavljivanja dok je kod stohastičkih modela slobodne varijable moguće povezati analizom vjerojatnosti pojavljivanja (Xu, 2002).

Općenito se danas pri razvoju hidroloških modela u svrhu predviđanja najviše koriste matematički modeli otjecanja (*eng. Rainfall-runoff*) čiji je glavni problem izrazita složenost, koja umanjuje njihovu široku primjenu što je popraćeno nedostatkom objektivnosti i konzistentnosti u ocjeni, validaciji i evalvaciji modela (Legates i McCabe, 1999). Postojeći modeli su uobičajeno pripremljeni za specifične slivove velike površine, pa je upotreba takvih modela na drugim

slivovima ili slivovima male površine nemoguća s obzirom da su mali slivovi izrazito osjetljivi na korak vremena predviđanja.

Unutar ove disertacije cilj je razviti hidrološki model predviđanja otjecanja za male slivove te razviti metodologiju po kojoj će biti moguće primijeniti takav model za druge male slivove. Cilj je također istražiti mogućnosti predviđanja modela, temeljenog na umjetnoj neuronskoj mreži, u cilju razvoja hidrološkog modela otjecanja. Umjetna neuronska mreža se klasificira kao analitička vrsta modela koja procese promatra kao jednu cjelinu (*eng. lumped*) prilikom čega se proces otjecanja tretira po načelu „crne kutije“ (*eng. black box*) (Dawson i Wilby, 2001; Abrahart i sur., 2004; Haykin, 2009).

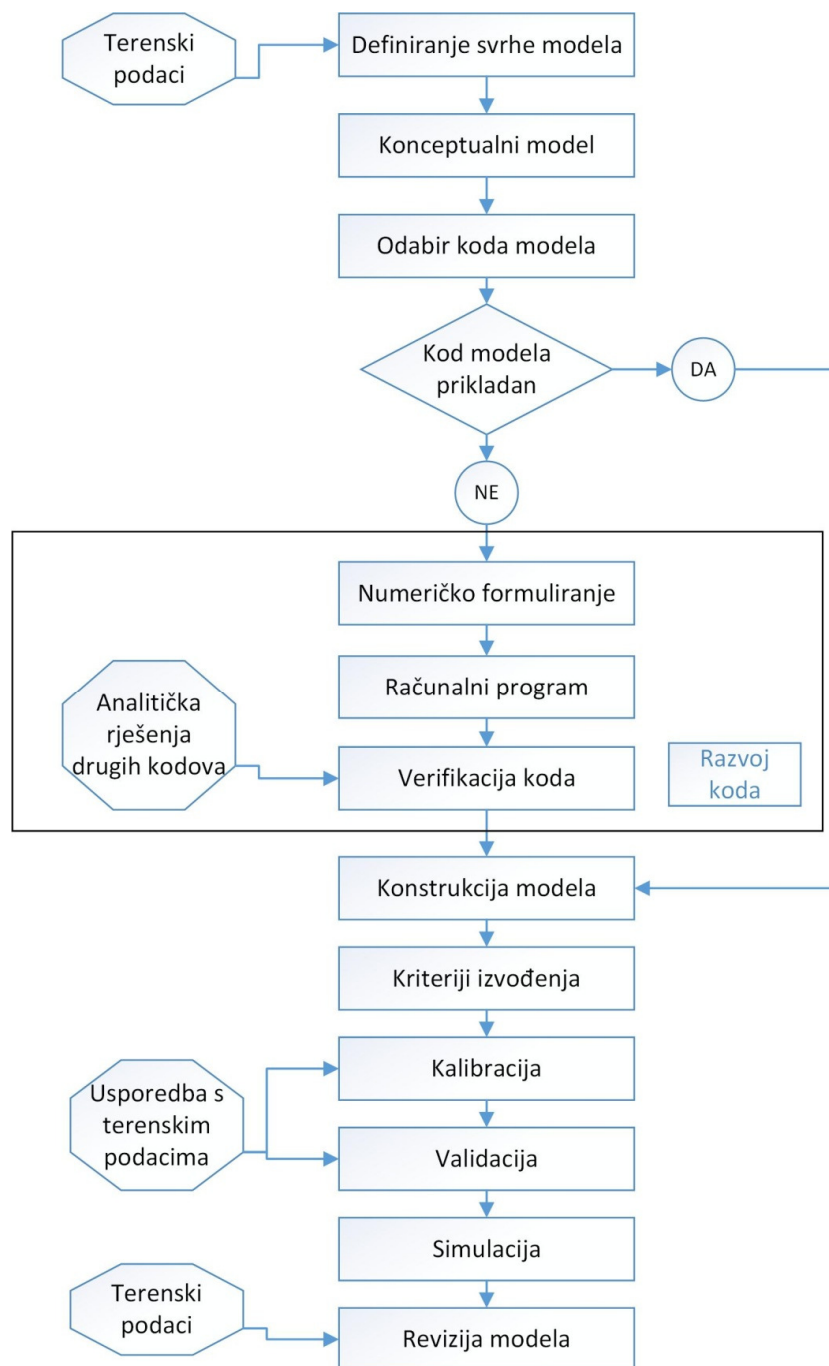
#### **2.4.5. Metodologija za razvoj hidroloških modela**

Općenito, bez obzira na vrstu i svrhu modela te sustava koji model opisuje, ishodišnu točku čini metodologija na osnovu koje će model biti razvijen. Osnovu kvalitetnog razvoja hidrološkog modela čini metodologija razvoja modela koja ima jasno definirane korake. Jednu od prvih metodologija za razvoj hidrološkog modela dao je Dooge (1972) koji u svom radu opisuje metodologiju razvoja modela Racionalne metode, a nakon njega Singh (1988) u svom radu prikazuje modificiranu Dooge-ovu metodu. Glavni koraci metodologije razvoja hidrološkog modela koje je predložio Singh (1988) prikazani su na *Slici 11*.

<b>Metodologija razvoja hidrološkog modela</b>	1. Definiranje problema
	2. Određivanje cilja
	3. Analiza dostupnih podataka
	4. Određivanje računalnih mogućnosti
	5. Određivanje ekonomskih i socijalnih ograničenja
	6. Odabir određene klase hidrološkog modela
	7. Odabir vrste hidrološkog modela iz klase
	8. Optimizacija hidrološkog modela
	9. Evalvacija performansi hidrološkog modela
	10. Upotreba modela u svrhu predviđanja
	11. Generaliziranje modela

*Slika 11. Glavni koraci metodologije razvoja hidrološkog modela; prikaz izradila: Ivana Sušan prema Singh (1988)*

Anderson i Woessner (1992) rade na proširenju postojeće metodologije za razvoj hidroloških modela, koju Refsgaard (1996) dalje razrađuje predlažući njenu modifikaciju. Dijagram toka koji prikazuje metodologiju za razvoj hidrološkog modela prikazan je na *Slici 12*.



*Slika 12. Dijagram toka metodologije za razvoj hidrološkog modela; modificirani prikaz izradila: Ivana Sušan prema Refsgaard (1996)*

Na temelju postojećih metodologija za razvoj hidroloških modela od 1990-ih pa do danas predložen je cijeli niz modificiranih metodologija. Kod svih



predloženih metodologija za razvoj hidroloških modela zajednička su četiri glavna koraka: (i) Kontinuirano mjerenje i praćenje meteoroloških i hidroloških varijabli, (ii) Modeliranje (obrada podataka i razvoj modela predviđanja), (iii) Validacija ili kalibracija hidrološkog modela i (iv) Evaluacija hidrološkog modela.

## **2.5. Umjetne neuronske mreže**

Istraživanje, u cilju razvoja hidrološkog modela, unutar ove disertacije započinje opisivanjem umjetne neuronske mreže (UNM) te njezine osnovne strukture i svojstava, a nastavlja se povijesnim pregledom razvoja umjetnih neuronskih mreža. Na kraju je prikazan pregled upotrebe umjetnih neuronskih mreža u području hidrotehnike kako u svijetu tako i na području Republike Hrvatske.

### ***2.5.1. Biološka osnova i definicija umjetne neuronske mreže***

Rad na umjetnim neuronskim mrežama motiviran je saznanjem da ljudski mozak obrađuje informacije na u potpunosti drugačiji način u odnosu na konvencionalna računala. Ljudski mozak je visoko složeno, nelinearno računalo koje informacije zaprima paralelno. Mozak ima sposobnost da organizira svoje strukturalne jedinice, odnosno neurone u svrhu obavljanja različitih zadataka kao što su primjerice prepoznavanje uzoraka, percepcija, upravljanje, interakcija s okolinom i druge te sve to čini brže od danas najboljeg računala. Razlog tomu je što mozak živih bića (od dana rođenja) posjeduje osnovnu strukturu i veze neurona u mozgu te mogućnost da se razvija i prilagođava iskustveno svom okolišu stvarajući nove neuronske veze (Haykin, 2009).

Mozak živih bića sastoji se od velikog broja strukturalnih jedinica odnosno živčanih stanica (neurona) koje na temelju podražaja stvaraju međuneuronske veze prilikom čega nastaje biološka neuronska mreža. Biološka neuronska mreža je način na koji mozak stvara svoja pravila odnosno sliku (model) okoline, a to čini kroz proces iskustvenog učenja. Cilj rada s umjetnim neuronskim mrežama je oponašanje rada ljudskog mozga odnosno biološke neuronske mreže (Haykin, 2009).

Jedna od preciznijih i jednostavnijih definicija UNM-a je ona iz 1990. godine koju su dali Aleksander i Morton, u kojoj definiraju kako je: „Neuronska mreža masivni paralelni distribuirani sustav za obradu podataka koji se sastoji od


jednostavnih elemenata i ima prirodnu sklonost pohranjivanja iskustvenog znanja koje potom može i koristiti, a sličan je mozgu prema načinu na koji stječe i pohranjuje znanje. Neuronska mreža znanje stiče kroz proces učenja, a pohranjuje ga posredstvom intenziteta međuneuronskih mreža“.

Umjetne neuronske mreže zapravo predstavljaju pojednostavljeni matematički model procesa koje obavljaju mreže živčanih stanica živog bića, a sastoji se od međusobno povezanih umjetnih neurona koje nakon procesa učenja stječu znanje o rješavanju određenog problema. Znanje koje umjetna neuronska mreža posjeduje očitava se kroz jačinu međuneuronskih veza (Haykin, 2009).

### 2.5.2. Struktura umjetne neuronske mreže

Umjetne neuronske mreže sastoje se od dvije glavne tvorbene jedinice koju čine: (i) strukturalna jedinica (struktura neurona) i (ii) težinske veze. Organizacija i povezanost ovih tvorbenih jedinica čine takozvanu arhitekturu modela (Haykin, 2009; Abrahart i sur., 2004).

Osnovna strukturalna jedinica umjetne neuronske mreže je umjetni neuron, a njegov model s težinskim vezama je prikazan na *Slici 13*.



*Slika 13. Model umjetnog neurona ( $x_{1,2,3...m}$ -ulazni podaci u neuron,  $w_{1,2,3...m}$ - vrijednost optimizacijskog parametra,  $v_k$ - suma umnožaka ulaznih podataka i optimizacijskog parametra (težinska veza) u  $k$ -tom koraku računanja,  $\phi(v_k)$  –linearna, ograničena linearna, unipolarna sigmoidalna ili bipolarna sigmoidalna aktivacijska funkcija neurona u  $k$ -tom koraku računanja,  $o_k$  – odaziv neurona u  $k$ -tom koraku računanja); prikaz izradila: Ivana Sušan prema Haykin (2009) i Matić (2014)*

Prilikom ulaska sume umnožaka ulaznih podataka  $x_k$  i vrijednosti optimizacijskog parametra  $w_k$  posredstvom aktivacijske funkcije neuron daje odziv. Umjetni se neuron može prikazati i matematičkim izrazom (5) kojim se definira aktivacijska funkcija umjetnog neurona te izrazom (6) koji definira sumu umnožaka ulaznih podataka i težinskih koeficijenata (Matić, 2014):

$$o_k = \varphi(v_k) \quad (5)$$

$$v_k = \sum_{n=0}^m (w_k)_n \cdot (x_k)_n \quad (6)$$

Gdje je:

$o_k$  – Odziv neurona u  $k$  – tom koraku računanja


$\varphi(v_k)$  – Aktivacijska funkcija neurona

$v_k$  – Suma umnožaka ulaznih podataka  $x_k$  i optimizacijskog parametra  $w_k$  u  $k$  – tom koraku računanja

$(w_k)_n$  – Vrijednost  $n$  – te komponente vektora optimizacijskog parametra u  $k$  – tom koraku računanja


$(x_k)_n$  – Vrijednost  $n$  – te komponente vektora ulaznih podataka u neuron u  $k$  – tom koraku računanja

Svojstva umjetne neuronske mreže ovise o svojstvima neurona odnosno vrsti aktivacijske funkcije pa tako da bi mreža imala sposobnost aproksimacije nelinearne funkcije koja povezuje ulazne i izlazne podatke i aktivacijske funkcije moraju biti nelinearne. Najčešće korištene aktivacijske funkcije su linearna, ograničena linearna, unipolarna sigmoidalna i bipolarna sigmoidalna. Na *Slici 14.* su prikazane najčešće korištene aktivacijske funkcije i njihovi pripadajući matematički izrazi (Matić, 2014).



Slika 14. Aktivacijske funkcije umjetnog neurona; a) linearna, b) ograničena linearna, c) unipolarna sigmoidalna, d) bipolarna sigmoidalna (Matić, 2014)

U svom radu Maren (1991) opisuje kako se arhitektura umjetne neuronske mreže može opisati na tri različite razine rezolucije prema: (i) Mikrostrukturi, (ii) Mezostrukturi i (iii) Makrostrukturi kao što je shematski prikazano na *Slici 15*. Mikrostruktura umjetne neuronske mreže odražava karakteristike svake tvorbene jedinice u mreži pa prema *Slici 9*. razlikujemo tvorbenu jedinicu umjetne neuronske mreže koja se sastoji od mnogobrojnih ulaznih veza, procesne jedinice, aktivacijske funkcije, izlaznih podataka (Abarhart i sur., 2004).



Slika 15. Arhitektura umjetne neuronske mreže; prikaz izradila: Ivana Sušanjan prema Abarhart i sur. (2004)

Mezostruktura umjetne neuronske mreže može se definirati kao način na koji je mreža organizirana. Organizacija mikrostrukturalnih elemenata umjetne neuronske mreže čini njezinu arhitekturu, a odnosi se na broj slojeva, definiranje poveznica između slojeva i sam tok informacija kroz mrežu (Abarhart i sur., 2004).

Makrostruktura umjetne neuronske mreže je rezolucija pri kojoj se opisuje način na koji je spojeno više mreža zajedno tvoreći složenije rješenje za zahtjevnije zadatke (Abarhart i sur., 2004).

### 2.5.3. Svojstva umjetne neuronske mreže

Umjetne neuronske mreže posjeduju cijeli niz svojstava kao što su (i) *Treniranje (učenje)*, (ii) *Adaptivnost*, (iii) *Svojstvo univerzalnog aproksimatora*, (iv) *Nelinearnost*, (v) *Svojstvo generalizacije*, (vi) *Masivna paralelna distributivna strukturiranost* i (vii) *Svojstvo raspodjele pohrane informacija*. Spomenuta svojstva čine umjetne neuronske mreže više nego prihvatljivim rješenjem za cijeli niz

problema u različitim područjima znanosti. U nastavku će svojstva biti detaljnije opisana (Matić, 2014; Haykin, 2009).

### Treniranje (učenje)

Treniranje, kao svojstvo umjetnih neuronskih mreža, predstavlja mogućnost da se na temelju ulaznih i izlaznih varijabli odredi pogreška, odnosno razlika između odziva mreže i željenog odziva mreže te da je pritom moguće učiniti korekciju parametara  $w_k$ . Korekcija parametara  $w_k$  omogućuje da u sljedećoj iteraciji odziv mreže postigne manju pogrešku (Haykin, 2009).

### Adaptivnost

Svojstvo adaptivnosti proizlazi izravno iz svojstva treniranja te označava sposobnost umjetne neuronske mreže da se prilagodi zadanim varijablama koje su mreži predstavljene, odnosno njezinu mogućnost da se oblikuje prema zadanom rješenju problema (Haykin, 2009).

### Svojstvo univerzalnog aproksimatora

Svojstvo univerzalnog aproksimatora omogućava umjetnoj neuronskoj mreži da aproksimira bilo koju zadanu kontinuiranu funkciju s relativnim stupnjem točnosti (Haykin, 2009).

### Nelinearnost

Aktivacijske funkcije koje povezuju neurone određuju svojstvo nelinearnosti mreže. Ukoliko su aktivacijske funkcije nelinearne i umjetna neuronska mreža ima svojstvo nelinearnosti odnosno može aproksimirati kontinuiranu nelinearnu funkciju (Haykin, 2009).

### Svojstvo generalizacije

Svojstvo umjetne neuronske mreže od velike važnosti je generalizacija. Ovo svojstvo daje umjetnoj neuronskoj mreži sposobnost da iz predloženih primjera u procesu treniranja usvoji generalno pravilo, odnosno da upamti funkciju po kojoj se ulazne varijable preslikavaju u izlazne te pritom može riješiti primjere koje nije upoznala u procesu učenja s relativnom točnošću (Haykin, 2009).

### Masivna paralelna distributivna strukturiranost

Prethodno navedena svojstva međusobno su povezana te zajedno čine svojstvo masivne paralelne distributivnosti sustava umjetne neuronske mreže odnosno sposobnosti da mreža paralelno prihvaća informacije i obrađuje raspodijeljeno za razliku od uobičajenog rada računala prilikom kojeg se informacije pohranjuju koncentrirano (Haykin, 2009).

### Svojstvo raspodjele pohrane informacija

Svojstvo prilikom kojeg se informacije pohranjuju raspodijeljeno, odnosno odvojeno, daje umjetnim neuronskim mrežama mogućnost da budu otporne na takozvani „kvar“. Drugim riječima, ukoliko jedan dio umjetne neuronske mreže ne radi, mreža i dalje može raditi zbog redundantnosti (Haykin, 2009).

#### **2.5.4. Treniranje (učenje), validacija i evalvacija umjetnih neuronskih mreža**

Treniranje neuronskih mreža može se opisati kao korekcija optimizacijskog parametra  $w_k$  neuronske mreže kako bi kroz odgovarajući broj iteracija dala željeni odziv. Optimizacijski parametri  $w_k$  predstavljaju pragove odlučivanja svakog neurona te sumu otežanih koeficijenata  $v_k$  koji predstavljaju jačinu neuronskih veza (Matić, 2014; Abrahart i sur., 2004; Dooge, 1972).

Postupak treniranja mreže može se dakle opisati kao iterativni postupak podešenja optimizacijskih parametara  $w_k$  mreže koji se odvijaju prema određenom algoritmu pritom minimizirajući pogrešku prema odzivu.

U procesu treniranja odnosno učenja umjetne neuronske mreže postoje dvije glavne vrste treniranja, a to su nadgledano i nenadgledano učenje. Osnovna razlika između nadgledanog i nenadgledanog učenja je u povezanosti ulaznih i izlaznih podataka pa tako kod nadgledanog učenja set ulaznih podataka mora biti vezan za izlazne podatke iz umjetne neuronske mreže. Kod nenadgledanog učenja ulazni podaci se preslikavaju u izlazne u obliku grupiranih podataka takozvanih klastera. Vrsta treniranja ovisi o odabiru arhitekture umjetne neuronske mreže pa se tako kod višeslojnih perceptrona (*eng. Multilayer perceptron; MLP*) i mreža radijalne baze (*eng. Radial Basis Function; RBF*) koristi nadgledano treniranje, a kod primjerice samo-organizirajućih mapa (*eng. Self-Organising map; SOM*) nenadgledano treniranje. U nastavku rada bit će opisani algoritmi koji se

koriste pri nadgledanom treniranju umjetnih neuronskih mreža (Anderson i Woessner, 1992).

Algoritmi za optimizaciju parametara  $w_k$  mreže su dio iterativnog postupka koji se provode prema izrazu (7), a razlikuju se prema načinu na koji se određuje mjera promjene  $\Delta w$  u svakom koraku (Hagan i sur., 1996; Demuth i sur., 2004).

$$w_{k+1} = w_k + \Delta w \quad (7)$$

Gdje je:

$w_{k+1}$  – Optimizacijski parametar u  $k + 1$  koraku računanja


$w_k$  – Optimizacijski parametar u  $k$  – tom koraku računanja

$\Delta w$  – Mjera promjene

---

Algoritmi za podešenje mjere promjene  $\Delta w$  mreže mogu se općenito podijeliti na lokalne i globalne. Lokalni algoritmi mogu se podijeliti na lokalne algoritme prvoga i drugoga reda (Haykin, 2004).

Među lokalne algoritme prvoga reda spadaju algoritam propagacije greške unatrag (*eng. error backpropagation, BP*) koji se još naziva i delta pravilo te generalizirano delta pravilo. Newton-ov algoritam spada među lokalne algoritme drugoga reda no zbog niza uvjeta koje povlači pri treniranju arhitekture višeslojnog perceptrona umjetne neuronske mreže smatra se neupotrebljivim. Umjesto njega koristi se Quasi-Newton-ov algoritam dok sve veću primjenu pronalazi metoda konjugiranog gradijenta (*eng. conjugate gradient, CG*) čiji je predstavnik Levenberg-Marquardt (LM) algoritam (Demuth, 2004; Haykin, 2004). U nastavku je prikazana podjela algoritama na *Slici 16*.



Slika 16. Podjela algoritama za izračunavanje mjere promjene  $\Delta w$  za izračun optimizacijskog parametara  $w_k$  umjetne neuronske mreže (UNM); prikaz izradila: Ivana Sušan prema Demuth, (2004) i Haykin (2004)

Algoritmi za podešavanje mjera promjene  $\Delta w$  težinskih koeficijenata  $v_k$  umjetne neuronske mreže bit će detaljnije objašnjeni u nastavku rada prilikom opisa podloga i metoda za razvoj modela umjetne neuronske mreže u poglavlju 3.3.2.

Nakon procesa treniranja modela temeljenog na umjetnoj neuronskoj mreži model mora proći kroz proces validacije i evaluacije. Proces validacije umjetnih neuronskih mreža se definira kao procjena kvalitete odziva modela za vrijeme treniranja modela, odnosno procjenom njegove osnovne funkcionalnosti. Proces evaluacije modela temeljenog na umjetnoj neuronskoj mreži se definira kao ocjena kvalitete odziva modela na temelju podataka koji nisu korišteni u procesu treniranja, a nastupa nakon što je model zadovoljio kriterije kvalitete modela pri validaciji (Moradkhani i Sorooshian, 2008, Abrahart, 2004.)

### **2.5.5. Razvoj i upotreba umjetnih neuronskih mreža**

Krajem devetnaestoga te početkom dvadesetog stoljeća javlja se osnovna ideja o umjetnim neuronskim mrežama kada se znanstvenici Hermann von Helmholtz, Ernst Mach i Ivan Pavlov bave općenitim teorijama učenja, razmišljanja te problemom uvjetnog donošenja odluke (Matić, 2014). Sredinom dvadesetog



stoljeća Warren McCulloch i Walter Pitts (1943) opisuju mogućnosti rješavanja logičke i aritmetičke funkcije te opisuju koncept umjetne neuronske mreže pa njihov rad možemo smatrati ishodišnim u području razvoja umjetnih neuronskih mreža. Značajniji razvoj i primjena UNM-a zabilježena je izumom Franka Rosenblatta (1957) koji je uz računalnu podršku razvio prvi jednostavni model UNM-a te ga nazvao Perceptron (jednosmjerna neuronska mreža za raspoznavanje uzoraka) te time privukao širu znanstvenu zajednicu ka proučavanju UNM-a. Interes za razvoj UNM-a trajao je do trenutka kada su Marvin Minsky i Seymour Papert (1969) objavili knjigu pod nazivom „*Perceptrons: an introduction to computational geometry*“ gdje su ukazali na čitav niz nedostataka i ograničenja UNM-a i samog Perceptrona te zbog toga 70-ih godina dvadesetog stoljeća nastupa razdoblje stagnacije u istraživanju UNM-a (Abrahart i sur., 2004; Govindaraju i Ramachandra Rao, 2000; Matić, 2014; Haykin, 2004).

Stagnacija istraživanja UNM-a traje do 80-ih godina dvadesetog stoljeća kada započinje razvoj računalne tehnologije te se ponovno javlja interes znanstvenika za razvoj UNM-a (Matić, 2014).

Ključnim razvojnim trenutkom UNM-a može se smatrati razvoj algoritma propagacije greške unatrag, koji se definira kao algoritam za treniranje UNM-a, na čijem je razvoju kroz godine radio čitav niz znanstvenika. Uvidom u nedostatke Perceptrona, Frank Rosenblatt (1962) prvi spominje pojam rasprostiranja pogreške unatrag dok prvu primjenu algoritma predstavlja Paul Werbos (1974) u svojoj disertaciji „*Beyond Regression*“. Osim spomenutih znanstvenika u tom su razdoblju na razvijanju spomenutog algoritma sudjelovali i David Parker, David E. Rumelhart te James McClelland. Konačnu formu i primjere primjene algoritma propagacije greške unatrag dali su David E. Rumelhart, Geoffrey Hinton i Ronald William (1986) u svome radu iz kojeg je razvijen višeslojni perceptron. Osim razvoja najpoznatije i najkorištenije mreže višeslojnog perceptrona UNM-a u isto vrijeme se razvijaju i samo-organizirajuće mape (*eng. Self-Organising Map; SOM*), opće regresijske neuronske mreže (*eng. Generalized Regression Neural Networks; GRNN*), vektorsko upravljanje strojevima (*eng. Support Vector Machines; SVM*), vremenske neuronske mreže (*eng. Temporal Neural Networks; TNN*), Neuro-fuzzy i druge (Abrahart, 2004).

Tijekom 1990-ih nastaju neki od najiscrpnijih izvora o ideji, razvoju i primjeni UNM-a, a za to su najviše zaslužni radovi autora Simona Haykina, Jamesa Andersona, Christophera Bishopa, Laurene Fausett i Raula Rojas. Martin T. Hagan, Howard B. Demuth i Mark H. Beale od 1992-e godine sustavno rade na razvoju alata i pripadajuće literature za razvoj UNM-a, te su 1996-e godine objavili knjigu pod nazivom „Neural Networks Design“ (Haykin i sur., 1996). Osim toga objavili su i priručnike za formiranje neuronskih mreža u programskom paketu MATLAB-u (MathWorks) (Demuth i Beale, 2004).

Osim spomenutih znanstvenika u razdoblju od 90-ih godina dvadesetog stoljeća pa do danas javlja se cijeli niz primjena UNM-a u svim granama znanosti, a shodno tome danas je dostupan cijeli niz literature vezan za korištenje i rad s UNM-a. Paralelno s razvojem UNM-a razvijaju se algoritmi treniranja pa se među lokalnim algoritmima prvoga reda uz spomenuti algoritam propagacije pogreške unatrag, razvija i generalizirano delta pravilo. Također se razvijaju i lokalni algoritmi drugoga reda kao što su Quasi-Newton algoritmi (Broyden, Flecher, Goldfarb, Shano metode) te Levenberg-Marquardt algoritam (Matić, 2014).

Upotreba UNM-a u području hidrologije može se smatrati relativno novom s obzirom da je prva primjena zabilježena u radovima koje su objavili znanstvenici Daniell (1991), French i sur. (1992) te potom Hall i Minns (1993). Od tada pa do danas UNM-e su pronašle veliku primjenu u području hidrologije, a naročito u izradi modela koji opisuju odnos oborina i otjecanja u čijem su razvoju pridonijeli Half i sur. (1993) s upotrebom UNM-a u predviđanju hidrograma dok Rayman i Sunil Kumar (1995) predstavljaju model procjene mjesečnih oborina. Od tada pa do danas upotreba UNM-a u području hidrologije je sve učestalija. Među značajnijim upotrebama UNM-a u hidrologiji valja spomenuti prvo korištenje UNM-u za potrebe predviđanja poplava koje su objavili u svom radu autori Openshaw i sur. (1998) dok se po svom doprinosu na području razvoja modela otjecanja još ističu: Hall i Minns (1993), Abrahart i Kneale (1997), Dawson i Wilby (1998), See i Openshaw (1998), Maier i Dandy (1999) koji su uspješno predstavili modele otjecanja za razne slivove, većinom veće površine dok su Jayawardena i Fernando (1998) prvi primjenili UNM-u na malom slivu (Abrahart i sur., 2004; Govindaraju i Ramachandra Rao, 2000).

Paralelno razvoju upotrebe UNM-a objavljuju se i razni priručnici te knjiške edicije posvećene radu s UNM-a od kojih su najznačajnije: knjiga čiji je autor Haykin (2009) naziva „Neural Networks and Learning Machines“ koja je prvi puta bila objavljena 1999. godine, a 2009. izlazi u trećem izdanju te objašnjava teoretsku i praktičnu primjenu upotrebe UNM-a do detalja, priručnik koji su izradili Demuth, Beale i Hagan (2004) pod nazivom „*Neural Network Toolbox™ 6 User's Guide*“ koji je od 1992. godine imao već cijeli niz upotpunjenih izdanja i velika je pomoć pri razvoju UNM-a u programskom paketu MATLAB (MathWorks). U području hidrologije treba istaknuti dvije knjiške edicije, a to su knjiga „Artificial neural networks in hydrology“ čiji su urednici Govindaraju i Ramachandra Rao (2000) te Knjiga „Neural Networks for Hydrological Modelling“ čiji su urednici Abraham, Kneale i See (2004). Obje knjige su koncipirane kao zbornik radova grupe znanstvenika i njihove primjene UNM-a u području hidrologije.

Na području Republike Hrvatske uporaba neuronskih mreža nije značajno zastupljena, odnosno nije implementirana u smislu široke uporabe, no postoji velika potreba za razvojem metodologije i implementacijom u području hidrologije. Na području vodnog gospodarstva mogu se istaknuti radovi poput onog čiji je autor Deduš (1994) pod nazivom „Neuralni modeli upravljanja kanalskim sustavima“ u kojima postavlja osnove važnosti primjene neuronskih mreža pri upravljanju sustavima odvodnje. Zatim Barbalić i Rajčić (2003) u svom radu opisuju mogućnost utvrđivanja obuhvata vodenih površina sa satelitske snimke primjenom UNM-a. Šperac (2004) u svojoj disertaciji opisuje mogućnosti upravljanja sustavima javne odvodnje pomoću analiza optimizacije u realnom vremenu uz primjenu UNM-a. Grupa autora Carević, Bekić i Vouk (2008) u svome radu koriste neuronske mreže za predviđanje vodostaja. Vouk (2009) u svojoj disertaciji analizira mogućnost primjene neuronskih mreža u ekonomskim analizama sustava odvodnje te kreira NEMATSO – neuronsku mrežu za aproksimativnu procjenu troškova sustava odvodnje. Grupa autora Vouk, Malus i Carević (2010) objavljuju rad u kojem naglašavaju mogućnosti upotrebe UNM-a u vodnom gospodarstvu. Također Matić (2014) u svojoj disertaciji koristi UNM-e za kratkoročno predviđanje dotjecanja rijeke Cetine u akumulaciju Peruća. Autori Rabi i sur. (2015) u svom radu „Modelling river temperature from air temperature

in the River Drava (Croatia)“ predstavljaju korištenje UNM-e u predviđanju temperature vode na temelju temperatura zraka.

U znanstvenim radovima je, u području hidrologije, češće zastupljeno korištenje UNM-a u obliku već pripremljenih alata za rad prilikom čega je moguće koristiti UNM-e bez potrebe za detaljnijim promatranjem arhitekture i procesa treniranja. U primjeni pripremljenih alata za rad s UNM-a značajni su doktorski rad kojeg je izradio Volf (2012) pod nazivom „Određivanje odgovarajućeg stupnja pročišćavanja otpadnih voda s obzirom na stanje morskog ekosustava“ u kojem je primjenjen programski paket WEKA i CUBIST dok Rubinić (2014) u svojoj disertaciji „Vodni režim Vranskog jezera u Dalmaciji i klimatski utjecaji“ koristi programski paket WEKA.

Kada se sagleda korištenje UNM-a u području hidrologije autori Maier i Dandy (2001) daju sustavni prikaz upotrebe UNM-a te kritički osvrt prilikom čega pozitivno ocjenjuju potencijal korištenja UNM-a dok kao nedostatak navode izostanak kritičke analize ulaznih podataka modela i unutarnjeg funkcioniranja UNM-a.

S obzirom na vrlo nagli razvoj UNM-a u svim granama znanosti kao i u području hidrologije, prilikom čega je značajan znanstveni doprinos usmjeren ka matematičkom opisu unutarnjeg djelovanja UNM-a s pravom se može zaključiti da se UNM-e više ne mogu sagledavati jednoznačno kao modele „crne kutije“ s obzirom da se danas pri modeliranju UNM-a definiraju unutarnja svojstva kao što je arhitektura, aktivacijske funkcije i algoritmi treniranja UNM-a.

Veliku pažnju znanstvenici su posvetili i mjerama kvalitete za ocjenu hidroloških modela prilikom čega Dawson i Wilby (2001) provode detaljnu diskusiju o mjerama kvalitete modela koji se koriste u hidrologiji. Najviše problema stvaraju nekonzistentnost korištenja mjera kvalitete, odnosno korištenje cijelog niza različitih mjera u različitim modelima. Također raznolikost slivova i njihovih obilježja, načina tečenja vode te koraka vremena koji se koristi u modelima onemogućuju njihovu usporedbu i korištenje jednakih mjera kvalitete modela.

Također znanstvenici Minns i Hall (Abrahart i sur., 2004) daju pregledni tablični prikaz modela otjecanja temeljenih na umjetnim neuronskim mrežama za razdoblje od 1995. do 1999. godine iz kojeg je vidljivo da su u najvećoj mjeri

zastupljeni modeli izrađeni za slivove većih površina. Jedini primjer primjene UNM-e na malom slivu je onaj koji su opisali autori Fernando i Jayawardena (1988) s vremenskim korakom od 10 minuta dok su drugi primjeri primjena na malim slivovima i vremenskim korakom mjerenim u sekundama obuhvaćali laboratorijske slivove (Carriere i sur., 1996).

Maier i drugi (2010) u svom radu daju pregled svih hidroloških modela po vrsti varijable koju se modelira, vremenskom koraku, arhitekturi modela, algoritmu treniranja te istražnom području na kojem je umjetna neuronska mreža primijenjena za razdoblje od 1999. do 2007. godine. Analizirani radovi ukazuju na raširenu upotrebu umjetnih neuronskih mreža za predviđanje protoka u vodotocima s vremenskim korakom od jednog dana uz najučestaliju upotrebu višeslojnog perceptrona. U procesu treniranja ponajviše se koriste algoritmi prvoga reda, a za validaciju i evalvaciju modela koristi se cijeli niz različitih mjera kvalitete modela.

Pregled postojećih istraživanja i primjena UNM-a u području hidrologije ukazuje na povećani interes znanstvenika za izradom modela na površinski većim slivovima. Nadalje, pri izradi hidrološkog modela za predviđanje štetne pojave veći interes znanstvenika privlače slivovi velike površine u odnosu na one male površine. Razlogi manjeg interesa se mogu pronaći u nedostatku terenskih mjerenja, sklonosti umanjenu značaja štetnih pojava na malim u odnosu na velike slivove, te pretpostavki da se modeliranjem na malim slivovima ne može postići dostatno predviđanje. Dodatni razlog nedovoljne primjene UNM-a može se obrazložiti i slabim poznavanjem UNM-a te njihovih mogućnosti kao što navodi Vouk i sur. (2010). Isto tako primjena umjetnih neuronskih mreža u sklopu hidroloških modela je u mnogo većem omjeru zastupljena na svjetskoj znanstvenoj razini nego na području Republike Hrvatske. Iz svega gore navedenog vidljiva je potreba za daljnjim razvojem i upotrebom umjetnih neuronskih mreža u hidrologiji, a pogotovo pri izradi hidroloških modela predviđanja otjecanja za male slivove, implementaciju razvijenijih algoritama treniranja (algoritmi drugog reda) te definiranju procesa treniranja, validacije i evalvacije modela što je i motivacija izrade ove disertacije.

### **2.5.6. Klasifikacija umjetnih neuronskih mreža**

Pri modeliranju hidroloških procesa temeljenih na umjetnim neuronskim mrežama, potrebno je odabrati arhitekturu modela koji se razlikuje prema: (i) karakteristikama neurona, (ii) obrascu neuronskih veza i (iii) algoritmima za izračunavanje mjere promjene  $\Delta w$  pri izračunu optimizacijskog parametra  $w_k$ . Broj mogućih kombinacija koje se mogu koristiti u tu svrhu je velik no za potrebe modeliranja u hidrologiji najčešće korištene arhitekture modela su: (i) Višeslojni perceptron, (ii) Mreže radijalne baze i (iii) Samo-organizirajuće mape (Matić, 2014).

Višeslojni perceptron je najčešće korištena arhitektura modela u hidrologiji koja nudi učinkovitu računalnu proceduru za vrednovanje pogrešaka proizašlih iz funkcije za izvođenje mreže na temelju optimizacijskih parametara mreže te daje odgovor na propagaciju pogreške unatrag kroz mrežu. Višeslojni perceptron se koristi za izvođenje nelinearnih regresijskih operacija, prilikom čega se razvija funkcija koja na temelju seta ulaznih podataka daje odgovor u obliku seta izlaznih podataka, a čiji su podaci dobiveni terenskim mjerenjima. Primjena arhitekture višeslojnog perceptrona pri razvoju raznih hidroloških modela vidljiva je u raznim primjerima od kojih se mogu izdvojiti model otjecanja kojeg su razvili autori Minns i Hall (1996), model predviđanja rasta algi kojeg su razvili autori Whitehead i sur. (1997), konstrukcija konsupcijske krivulje koju su u svojim radovima prikazali Tawfil i sur., (1997) te Jain (2001). Arhitektura višeslojnog perceptrona primjenjena je i pri određivanju promjene pogrešaka modela kao što su to prikazali u svom radu Shamseldin i O'Connor (2001) te pri višemodelnom spajanju kao što su to učinili Abrahart i See (2002) te mnogi drugi.

Umjetne neuronske mreže temeljene na arhitekturi radijalne baze sastoje se od tri glavna sloja, a to su ulazni, skriveni i izlazni sloj kao i višeslojni perceptron no glavna razlika između ove dvije arhitekture je u težinskim koeficijentima te aktivacijskoj funkciji. Kod modela temeljenih na radijalnoj bazi ulazni i skriveni sloj se ne množe težinskim koeficijentima te u skrivenom sloju aktivacijska funkcija posjeduje radijalno simetrična svojstva. Skriveni sloj koristi uobičajeno nepromjenjivu nelinearnu funkciju transformacije, a izlazni sloj je vezan sa skrivenim slojem linearnom sumarnom funkcijom. Ovakva se arhitektura modela koristi za opis različitih nelinearnih regresijskih operacija u hidrologiji, a

prve primjere primjene u predviđanju otjecanja sa sliva dali su Mason i sur. (1996) i Dawson i Wilby (1999).


Samo-organizirajuće mape predstavljaju arhitekturu umjetne neuronske mreže koja nenadgledanim treniranjem uz pomoć mrežnog algoritma otkriva značajne veze koje postoje u ulaznim podacima mreže prilikom čega se podaci suprotstavljaju jedan drugome. Arhitektura ovakve umjetne neuronske mreže se uobičajeno sastoji od dva sloja prilikom čega je prvi jedno-dimenzionalni ulaz, a drugi dvodimenzionalni izlaz koji prikazuje ulazne podatke u odnosu na suprotstavljene podatke značajnih veza (Abrahart i sur., 2004).

Uz spomenute arhitekture koriste se još Opće regresijske neuronske mreže (*eng. Generalized Regression Neural Networks; GRNN*), Vektorsko upravljanje strojevima (*eng. Support Vector Machines; SVM*), Vremenske neuronske mreže (*eng. Temporal Neural Networks; TNN*), Neuro-fuzzy i druge.

#### ***2.5.7. Metodologija za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži***

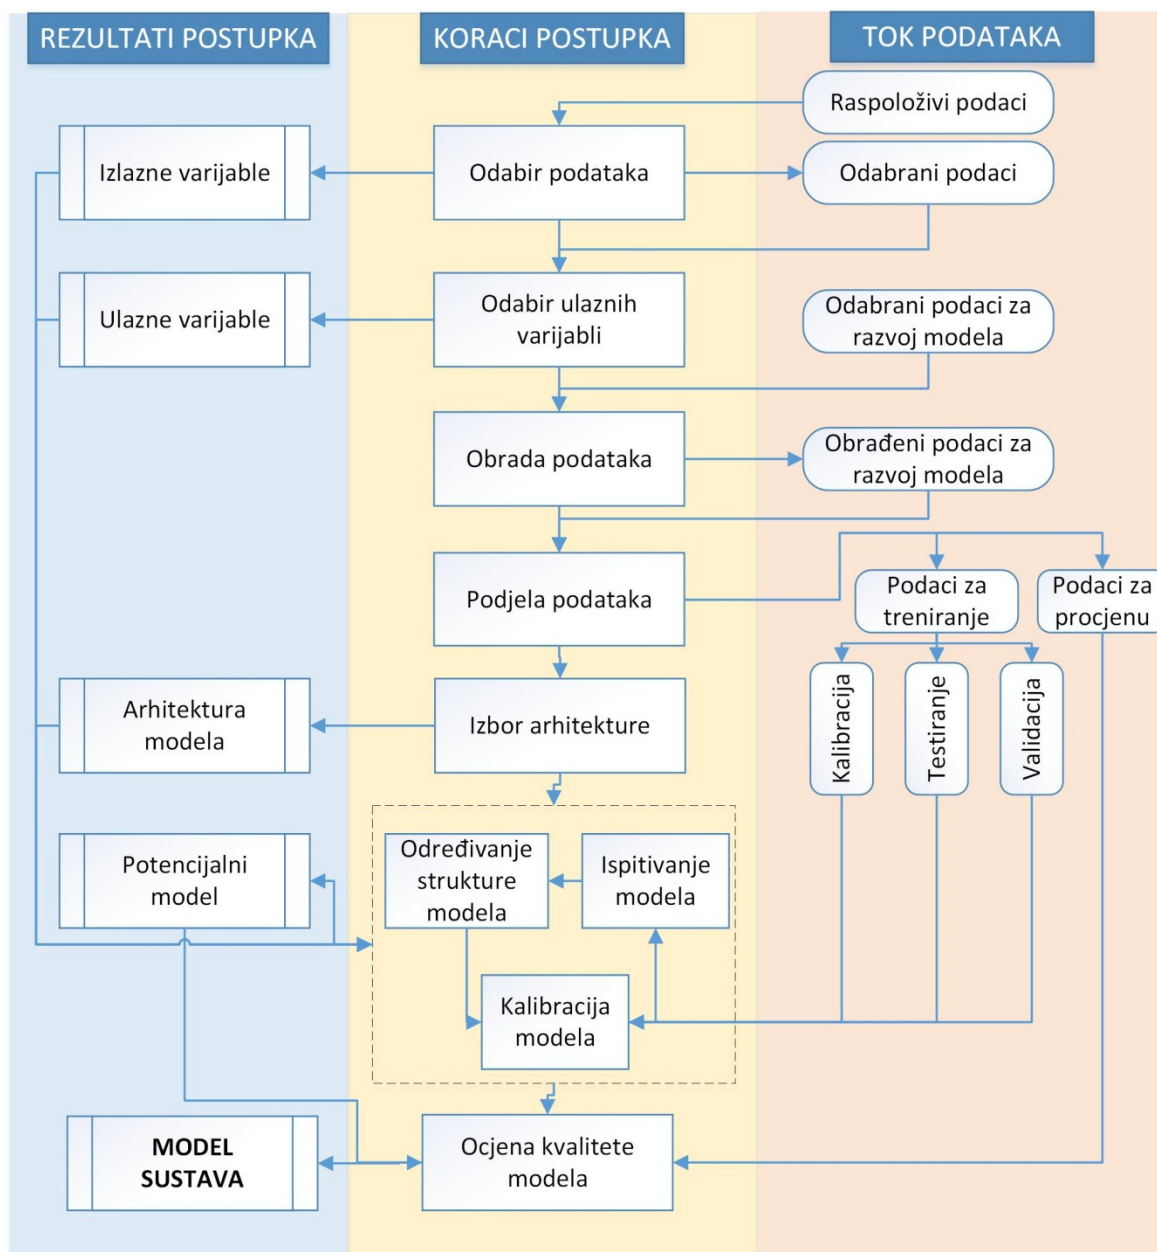
Općenito, osnovni koraci metodologije za razvoj hidroloških modela čine temelj za izradu metodologije razvoja modela temeljenih na umjetnim neuronskim mrežama. Iako znanstvenici Maier i Dandy (2000) te Maier i sur. (2010) u svojim radovima ističu dobra svojstva predviđanja modela umjetnih neuronskih mreža u isto vrijeme naglašavaju nedostatak u sustavnom pristupu razvoja modela umjetnih neuronskih mreža u hidrologiji. Glavni problem pri razvoju hidroloških modela temeljenih na umjetnim neuronskim mrežama, koji je prisutan već desetak godina, predstavlja nedostatak definiranih koraka odnosno metodologije za razvoj modela. Zbog nedostatka definirane metodologije za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži, u mnogo se slučajeva u potpunosti proizvoljno odabire primjerice broj ulaza u mrežu, podjela podataka, izbor arhitekture, aktivacijskih funkcija i broj skrivenih neurona (Matić, 2014). Uz nedostatak definirane metodologije uočljiva je i nedosljednost u postupku ocijene kvalitete modela, pri čemu se redovno koriste i one koje nisu takvoj vrsti modela primjerene. Osnovne smjernice za razvoj hidrološkog modela temeljenog na umjetnoj neuronskoj mreži daju Dawson i Wilby (2001), a potom Maier i sur. (2010) te u svom radu također opisuju metodologiju razvoja modela umjetne neuronske mreže. Obje metodologije razvoja modela umjetne neuronske mreže su

slične te opisuju jednake temeljne korake. Metodologija koju su predložili Dawson i Wilby (2001) prikazana je dijagramom toka na *Slici 17*. dok je ona koju su izradili Maier i sur. (2010) prikazana dijagramom toka na *Slici 18*.



*Slika 17. Metodologija za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži; modificirani prikaz izradila: Ivana Sušanjan prema Dawson i Wilby (2001)*





Slika 18. Metodologija za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži; modificirani prikaz izradila: Ivana Sušan prema Maier i sur. (2010)

Prikazane metodologije za razvoj hidroloških modela temeljenih na umjetnim neuronskim mrežama kao i zapažanja znanstvenika upućena prema nedostatku detaljnije razrađenih metodologija i procedura ukazuju na nužan razvoj u tom području. Preciznije definiranje koraka metodologije razvoja hidroloških modela temeljenih na umjetnim neuronskim mrežama preduvjet su povećanju kvalitete modela općenito te put ka ujednačavanju procedura pri korištenju umjetnih neuronskih mreža koje su prijeko potrebne.

## 2.6. Istražno područje


Unutar disertacije istraživanje je usmjereno ka upotrebi umjetnih neuronskih mreža na malim slivovima, pa je za istražno područje izabran sliv Slanog potoka koji se nalazi u Vinodolskoj dolini, a koji svojom površinom od svega oko  $A = 2,2 \text{ km}^2$  i jednolikom raspodjelom oborine na cijelom slivu spada u mali sliv. U nastavku rada biti će opisana glavna geografska, geološka, klimatološka obilježja područja istraživanja koja su prethodila istraživanjima za potrebe disertacije te čine ishodišnu točku istraživanju i razvoju hidrološkog modela otjecanja kao i analizi čimbenika otjecanja sa sliva.

### 2.6.1. Geografski položaj analiziranog područja

Sliv Slanog potoka, dio je sliva Dubračine koji se nalazi u središnjem dijelu Vinodolske doline, a izdvojena je geografska cjelina istočnog kvarnerskog prostora (Rubinić, 2009). U geografskom smislu Vinodol je jedinstvena prostorna cjelina između Križišća na sjeverozapadu i Novog Vinodolskog na jugoistoku te primorja uz Vinodolski kanal (*Slika 19.*).

Vinodolska dolina je krajnji jugoistočni dio veće morfološke cjeline koju osim te doline, tvore dolina Rječine, dolina Sušačke drage i depresija Bakarskog zaljeva. Sama Vinodolska dolina ima nepravilan eliptičan oblik najveće duljine do  $23 \text{ km}$  i širine do  $4 \text{ km}$ , te izlomljeno pružanje osnovnim smjerom Sjeverozapad-Jugoistok. Sa sjeveroistočne strane Vinodolska dolina oštro je odvojena strmim padinama, čiji vrhovi mjestimice premašuju nadmorsku visinu od  $700 \text{ m n. m.}$  Počevši od naselja Antovo prema jugoistoku, te padine poprimaju oblik gotovo vertikalnih litica visine preko  $100 \text{ m n. m.}$  S jugozapadne strane dolina je odvojena od obala Vinodolskog kanala nižim primorskom bilom čiji vrhovi mjestimice imaju nadmorske visine od  $250$  do  $350 \text{ m.}$  Cjelovitost primorskog bila je razbijena nizvodnim dijelom dolina Dubračine i Suhe Ričine Novljanske. Prijevojem kod naselja Križišće na sjeverozapadu, dolina je odvojena od depresije Bakarskog zaljeva. Prijevoj između naselja Saftići i Kričina dijeli samu Vinodolsku dolinu na veći sjeverozapadni i manji i jugoistočni dio, koji se postupno sužava i završava u zaleđu Novog Vinodolskog (Županijski zavod za razvoj, prostorno uređenje i zaštitu okoliša, 2004).

Vinodolska dolina ima u svom većem dijelu izrazito asimetričan poprečni profil, s izrazito dužom sjeveroistočnom i znatno kraćom jugozapadnom padinom. Zato su najniže kote Vinodolske doline, a to su korita Dubračine i Suhe Ričine Novljanske, smještene uz primorsko bilo. Veća zaravnjenja su sada potopljeni prostor oko Tribaljskog jezera kao i Velo polje kod Pavlomira (Županijski zavod za razvoj, prostorno uređenje i zaštitu okoliša, 2004).



Slika 19. Situacijski položaj sliva Dubračine; prikaz izradila: Ivana Sušanjan na topografskoj podlozi


Na području Vinodolske doline nalaze se dva glavna vodotoka koja se ulijevaju u Jadransko more i to Dubračina u Crikvenici i Suha Ričina Novljanska u Novom Vinodolskom. Na krajnjem sjevernom dijelu Vinodolske doline nalazi se i bujica Bakarački rov koja, za razliku od prethodno spomenutih vodotoka, ima naglašeniji bujični karakter s vrlo rijetkim pojavama tečenja u svom koritu. Sliv Dubračine je svojom neposrednom površinom i vodnom bilancom najveći i najznačajniji vodotok Vinodolske doline (Ružić i sur., 2010; Ružić i sur., 2011).



Područje sliva Slanog potoka, je dio većeg slivnog područja rijeke Dubračine, a čini jedan od mnogobrojnih lijevih pritoka rijeke Dubračine. Sliv Slanog potoka smješten je u središnjem dijelu Vinodolske doline te se proteže pravcem sjeverozapad-jugoistok kao što je prikazano na *Slici 20.* i *Slici 21.*



*Slika 20. Situacijski prikaz sliva Slanog potoka; prikaz izradila: Ivana Sušanjanj na topografskoj podlozi*



Slika 21. Prikaz sliva Slanog potoka; prikaz izradila: Ivana Sušan na ortofotografskoj podlozi

### **2.6.2. Geološka građa istražnog područja Slanog potoka**


Geološka građa Vinodolske doline kao i analiziranog područja vrlo je složena, te će u nastavku biti opisane glavne geološke karakteristike Vinodolske doline, a potom i sliva Slanog potoka.

U području Vinodolske doline nalaze se vrlo različite karbonatne i klastične sedimentne stijene krednog i paleogenskog perioda te pliokvartarne tvorevine koje tvore djelomični ili potpuni pokrivač na stjenjnoj masi (Benac i sur., 2005).


Gornjokrednske i paleogenske karbonatne stijene oblikovale su sjeveroistočne padine i primorsko bilo Vinodolske doline. Flišni stijenski kompleks eocenske starosti tvori niže dijelove Sjeveroistočne padine i dno doline. Stariji dio fliša tvori tipična izmjena silita i pješčenjaka, a u podređenom udjelu lapora, brečokonglomerata i vapnenaca. Mlađi dio, kojeg čine konglomerati,



konglomeratični biokalkarenit i litični arenit diskordantno leže na starijem djelu (Blašković i Tišljar, 1983). Pokrivač fliša čine deluvijalno-koluvijalne tvorevine, čija je debljina veća na sjeveroistočnoj padini Vindolske doline. Na sjeveroistočnoj padini Vinodolske doline gdje se nalaze u dvije hipsometrijske razine pojavljuju se Kvartarne siparne breče te tvore ispučene ploče na flišnoj padini (Blašković, 1997). Tektonski odnosi i morfogeneza mogu se promatrati kroz proces kontinentalne subdukcije uz formiranje tangencijalnih boranih i rasjednih struktura prilikom čega je Vinodolska dolina nejednoliko sužena. Sjeveroistočni kontakt između fliša i karbonatnih stijena čine reversni rasjed po kojemu je karbonatna stijenska masa nagurana na fliš, dok je na jugozapadnom dijelu Vinodolske doline također izražen tektonski kontakt u obliku reversnog rasjeda. Mlađi, poprečni i dijagonalni rasjedi ocrtavaju se u karbonatnim padinama doline. Središnji dio Vinodolske doline pripada slivu rijeke Dubračine (Benac i sur., 2005). S obzirom na asimetričan poprečni profil Vinodolske doline s izrazito dužom sjeveroistočnom i kraćom jugozapadnom padinom, korito rijeke Dubračine je smješteno većim dijelom uz primorsko bilo. Tijekom kišnih razdoblja stvara se mreža vodotoka zbog male vodopropusnosti kako matične flišne stijene, tako i zone fizikalno-kemijske razgradnje različitih litogenetskih tipova deluvijalno-koluvijalnih tvorevina. Zato je mjestimice erozija spiranjem značajno izražena. Obilježje flišnih padina u Vinodolskoj dolini je izmjenjena površina, prilikom čega pokrivač ima zaštitnu funkciju od erozije i ogoljelih dijelova, a prilikom nedostatka pokrivača su matične stijene napadnute pluvijalnom erozijom. Obradive površine imaju oblik terasa s mrežom odvodnih kanala radi smanjena štetnog djelovanja erozije i povećanja stabilnosti padina. Napuštanjem obrade zemljišta nastupa gospodarska degradacija terena - urušavanje zidova terasa i zatrpavanje kanala (Benac i sur., 2005). Tada se pojačava erozija, a ispiranje poprima mjestimice drastične razmjere stvarajući ogoline (*eng. badland*). Prema definiciji koju je dao Benac (2016), ogolinom se smatra rezvedeni brežuljkasti reljef bez vegetacije ili vrlo oskudne vegetacije strmih nagiba pada te velike gustoće hidrografske mreže s čestim jarugama. Na *Slici 22.* prikazana je osnovna geološka karta sliva rijeke Dubračine, a na *Slici 23.* je prikazan sliv Slanog potoka na podlozi geološke karte.




Slika 22. Pregledna geološka karta sliva rijeke Dubračine; Hrvatski geološki institut (2007)



Slika 23. Prikaz sliva Slanog potoka na geološkoj karti Hrvatski geološki institut (2007); prikaz izradila: Ivana Sušanj



Sliv bujičnog vodotoka Slanog potoka je primjer kombiniranog djelovanja erozije s pratećim pojavama klizanja, a istim procesom su djelomice zahvaćeni i susjedni slivovi vodotoka Male Dubračine i Kučine. Žarište te pojave nalazi se u slivu Slanog potoka, a prikazano je na digitalnom elevacijskom modelu na *Slici 24.* te fotografijom na *Slici 25.*



*Slika 24. Prikaz granica sliva Slanog potoka i granica žarišta erozije na digitalnom elevacijskom modelu; prikaz izradila: Ivana Sušanj*



*Slika 25. Fotografija žarišta erozije na slivu Slanog potoka; autor fotografije: Ivana Sušanj*



Teren koji je zahvaćen pretjeranom (ekscesivnom) erozijom ima dimenzije od otprilike 600 m po osi i 250 m po širini te površinu od 3 km<sup>2</sup>. Popratne pojave oko žarišta erozije, kao i u njemu samom, brojna su klizišta kao posljedica trošenja matičnih stijena flišnoga kompleksa i pretvaranja stijene u inženjersko tlo (Ružić i sur., 2011), a kao posljedica tih procesa dolazi do pojave bujica, muljnog toka te debratne poplave. Zahvaćena površina obuhvaća i okolna naselja Belgrad, Baretići, Grižane i Kamenjak uz koje su ugrožene prometna i ostala komunalna infrastruktura. Postojeće bujične pregrade na vodotoku Slani potok su gotovo u potpunosti ispunjene nanosom, uglavnom muljem, a incidentno čišćenje nekoliko najnižvodnih pregrada 2015. godine nije pridonjelo značajnijem zaustavljanju pronosa materijala s obzirom da su u vrlo kratkom vremenu iznova ispunjene nanosom. Flišni kompleks u slivu Slanog potoka sastavljen je od siltita i siltnih lapora s rijetkim proslojcima pješčenjaka. Obilježje materijala u žarištu je disperznost zbog prisutnosti čestica nanometarskih dimenzija i minerala sklonih bubrenju. To je razlog prekomjernoj erodibilnosti, kojoj pridonosi i tektonska deformiranost fliša. Tlo sadrži povećanu količinu otopljenog natrijevog iona u pornoj vodi, a indikator je mineral tenardit. Proces erodiranja zbiva se zbog prelaska koloidnih čestica gline u suspenziju u praktički stajaćoj vodi. Fenomen eflorescencije ili “ cvjetanja” je posebno uočljiv tijekom sušnog razdoblja, kada su na površini vidljive nakupine bijeloga praha koji je po sastavu mineral tenardit kao što je prikazano na *Slici 26*. (Mileusnić i sur., 2004).



*Slika 26. Fenomen eflorescencije na području žarišta erozije na slivu Slanog potoka; autor fotografije: Ivana Sušan*

Pokrivač na matičnoj stijeni djeluje zaštitno no jednom ogoljena flišna matična stijena ostaje dugotrajno izložena djelovanju atmosferilija, odnosno opetovanom vlaženju i sušenju, što vjerojatno uzrokuje promjenu obujma pojedinih litoloških članova fliša. Taj proces integrirano dovodi do premrežavanja stijene pukotinama sušenja kroz koje prodire padalinska voda. Konačna posljedica je razrahljivanje i razgradnja stijena, kao i njihovo postupno pretvaranje u inženjersko tlo. Tako nastao deluvijalni materijal ima svojstvo deformabilnosti plastičnim tečenjem, posebice kada je saturiran vodom. U određenim okolnostima te naslage su nestabilne pa nastaju klizišta slična onima na drugim lokacijama u Vinodolskoj dolini (Holjević, 1996).

### **2.6.3. Klimatološke značajke istražnog područja**

Za sliv Slanog potoka ne postoje kontinuirana meteorološka mjerenja a najbliža klimatološka postaja Državnog hidro-meteorološkog zavoda se nalazi u gradu Crikvenici dok su u Bribiru i Hreljinu postavljene oborinske postaje. S obzirom na veliku udaljenost oborinskih postaja te prostornu raspodjelu oborina, na temelju dostupnih podataka nije moguće u potpunosti utvrditi referentne količine oborina za istražno područje Slanog potoka. U nastavku će stoga biti prikazane glavne klimatološke značajke šireg područja sliva Dubračine (Rubinić, 2010).


U *Tablici 3.* su prikazane osnovne značajke opažanja klimatološkim i oborinskim postajama na slivu rijeke Dubračine te godina početka mjerenja.

*Tablica 3. Osnovne značajke opažanja na klimatološkim i oborinskim postajama u slivu Dubračine i okolici*


Postaja	Karakter	Početak mjerenja	Nadmorska visina	Sr.god oborina (1961.-90)	Sr.god. temp. (1961.-90)
Crikvenica	Klimatološka	1891	2	1243	14.1
Brbibir	Oborinska	1952	150	1363	
Hreljin	Oborinska	1953	307	1603	

Za referentno 30-godišnje razdoblje od 1961.-90., Državni hidrometeorološki zavod (2002) je proveo na razini Republike Hrvatske i analizu prostornog rasporeda srednjih godišnjih temperatura. Na osnovi te obrade u dokumentu Hrvatskih voda VGO Rijeka (2004a) napravljen je i detaljniji prikaz

spomenutih prostornih značajki oborina i temperatura širega analiziranog prostora, što je prikazano na *Slici 27.* i *Slici 28.*



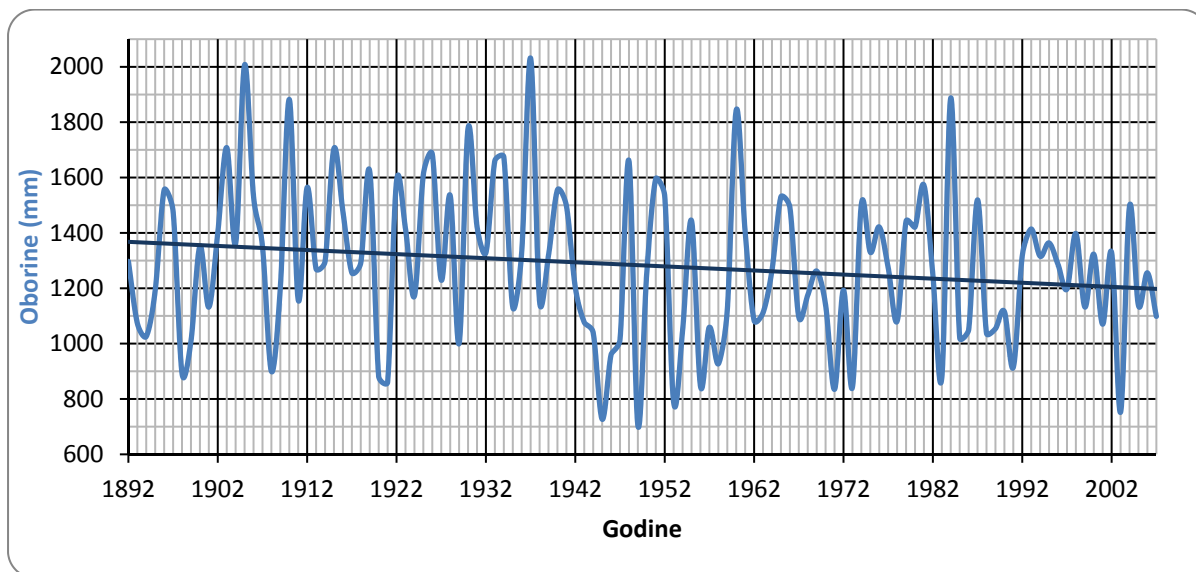
Slika 27. Prikaz srednjih godišnjih oborina (1961.-1990.); prema Hrvatskim vodama VGO Rijeka (2004a)



Slika 28. Prikaz srednjih godišnjih temperatura zraka (1961.-1990.); prema Hrvatskim vodama VGO Rijeka (2004a)


Godišnji hod srednjih godišnjih oborina prikazan je na *Slici 29.* iz koje je vidljivo da oborine imaju trend smanjenja od 1.48 mm/god. Spomenuti su trendovi

posebno naglašeni tijekom posljednjih 20-tak godina (Hrvatske vode VGO Rijeka, 2004).



Slika 29. Hod srednjih godišnjih količina oborina za postaju Crikvenica (1892. – 2007.); prema Hrvatskim vodama VGO Rijeka (2004a)

Godišnja raspodjela srednjih mjesečnih temperatura i oborina prikazana je na *Slici 30.* iz koje je vidljivo da se u prosjeku najniže godišnje temperature zraka javljaju u siječnju, a najviše u srpnju. Hod oborina pokazuje postojanje dvaju oborinskih maksimuma – u listopadu i svibnju, od kojih je naglašeniji onaj u listopadu. Oborinski minimum javlja se u prosjeku tokom srpnja (Hrvatske vode VGO Rijeka, 2004a).



Slika 30. Godišnji hod srednjih mjesečnih temperatura zraka i oborina za postaju Crikvenica (1892. – 2007.); prema Hrvatskim vodama VGO Rijeka (2004a)

Prikazane osnovne klimatološke značajke poslužiti će kao referentne granice pri analizi sliva Slanog potoka. Prema analizi na slivu Slanog potoka trebala bi biti prisutna nejednolika raspodjela temperature i količina oborina što će istraživanjem u sklopu disertacije mjerenjima meteoroloških podataka biti ispitano. Nedostatak prikazane obrade podataka je osim velike udaljenosti mjernih postaja i postignuta razlučivost raspodjele oborina i temperature koje u mjerilu istražnog područja nisu upotrebljive.

#### **2.6.4. Biološka obilježja istražnog područja**


Prema podacima i analizama koje je provela Horvat izrađen je elaborat: *Analiza slivnog područja Vinodolske doline: klimatske i hidrološke prilike – radna verzija* (Hrvatske vode, 2004a) unutar kojeg je prikazan pokrov i korištenje zemljišta na području Vinodolske doline kao što je prikazano na *Slici 31*. Rezultat je dobiven analizom i interpretacijom satelitskog snimka (Landsat ETM) koje je također provela Horvat. Detaljniji je opis definiranih klasa, postupak klasifikacije snimka te konačne karte pokrova/korištenja zemljišta dan u zasebnom elaboratu rađenom za potrebe ove Studije pod nazivom *Pokrov/korištenje zemljišta na području Vinodolske doline* (Hrvatske vode, 2004b). U nastavku se ovdje navode tek osnovne karakteristike pokrova/korištenja zemljišta analiziranog područja.

Duž cijele Vinodolske doline, u njenim nižim dijelovima gdje su i nagibi terena ravni i blagi do umjereni, prevladavajuća vegetacija su livade uz gustu i nisku bjelogoričnu šumu. Porastom nagiba terena postupno se mijenja i vegetacija pa se tako mjestimično pojavljuje i crnogorična šuma, uglavnom na lokacijama čija je orijentacija uglavnom prema sjeveru, sjeveroistoku te istoku. Na južnim, jugoistočnim te jugozapadnim padinama koje su ujedno klasificirane kao strme i vrlo strme, vegetacija je daleko oskudnija pa se tako umjesto grmlja i drugog niskog raslinja javljaju površine s rijetkom vegetacijom dok je na rubovima doline omeđene vrhovima litica, kao i na strmim padinama orijentiranim prema jugu vegetacija vrlo oskudna ili je uopće nema (Rubinić, 2010).

U samoj su dolini locirana i brojna manja naselja te osamljena domaćinstva uz minimalnu poljoprivrednu proizvodnju, uglavnom za vlastite potrebe. Zbog velike prostorne rezolucije analiziranog snimka ( $15 \times 15 m$ ), tako mala poljoprivredna zemljišta uglavnom nisu mogla biti registrirana postupkom



klasifikacije. Izgrađenost same doline vidljiva je i u izgrađenosti prometne mreže Vinodolske doline koja dobro povezuje analizirano područje s obalnim pojasom.



Slika 31. Pokrov/korištenje zemljišta Vinodolske doline (Hrvatske vode, 2004b)

Iz provedene analize maksimalne rezolucije na slivu Slanog potoka moguće je identificirati površine prekrivene crnogoričnom i bjelogoričnom šumom, područja obrasla grmljem, žbunjem i makijom, golet te urbano područje. Podaci analize su za potrebe izrade disertacije poslužili pri opisivanju čimbenika koji utječu na otjecanje sa sliva no zbog rezolucije nisu primjenjivi za detaljnije određivanje granica pojedinog pokrova zemljišta (Rubinić, 2010).

### 2.6.5. Fizičke osobine sliva

Kao ishodište za osnovno upoznavanje čimbenika koje uvjetuju otjecanje sa sliva prije razvoja hidrološkog modela otjecanja potrebno je opisati osnovne fizičke osobine sliva kao što su: (i) Površina i oblik sliva, (ii) Srednja nadmorska visina sliva, (iii) Pad sliva, (iv) Pad vodotoka te (v) Gustoća drenske mreže. Dio fizičkih osobina sliva opisan je od strane drugih autora te će rezultati tih analiza biti prikazani. Dio fizičkih osobina je izračunat za potrebe disertacije.

Topografski sliv Slanog potoka površine određen je na topografskoj karti mjerila  $M 1:25000$  te iznosi  $A = 2,2 \text{ km}^2$  a pruža se od 50 do 700 m n.m. (Slika 4.). Donji

dio sliva površine  $0,9 \text{ km}^2$  prekriven je flišom, te čini glavninu površinskog otjecanja. Gornji dio sliva je većinom krška zaravan sa koje su otjecanja puno manja. U zoni kontakta fliša i krša nalazi se više preljevnih izvora koji čine glavninu vodne bilance u sušnom razdoblju (Ružić i sur., 2011). Pokrov sliva čini većinom bjelogorična šuma i u manjem opsegu crnogorična šuma dok na području erozijske baze prevladava golet s malim udjelom grmlja, žbunja i makije. Opseg sliva je prema određenom topografskom slivu  $O = 7,481 \text{ km}$  dok je udaljenost od težišta sliva do protjecajnog profila jednaka  $U = 1,906 \text{ km}$ . Duljina glavnog vodotoka je određena na temelju topografske karte te iznosi  $L = 2,15 \text{ km}$ .

Oblik sliva određuje se koeficijentom koncentriranosti sliva  $K$  prema izrazima (1), (2) i (3) te vizualnom analizom sliva, a za potrebe disertacije je izračunat u nastavku.

$$K = \frac{2 \cdot A}{O \cdot U} = \frac{2 \cdot 2,2 \text{ km}^2}{7,481 \text{ km} \cdot 1,906 \text{ km}} = 0,3$$

$$K = \frac{A}{L^2} = \frac{2,2 \text{ km}^2}{2,15 \text{ km}^2} = 0,47$$

$$K = \frac{0,28 \cdot O}{\sqrt{A}} = \frac{0,28 \cdot 7,481 \text{ km}}{\sqrt{2,2 \text{ km}^2}} = 1,41$$

Gdje je:

$K$  – Koeficijent koncentriranosti [–]

$A$  – Površina sliva [ $\text{km}^2$ ]


$O$  – Opseg sliva [km]

$U$  – Udaljenost od težišta sliva do protjecajnog mjernog profila [km]

$L$  – Duljina glavnog vodotoka [km]


Prema izračunatim koeficijentima koncentriranosti sliva te vizualnom analizom može se zaključiti da sliv Slanog potoka ima „izduženi“ oblik. Izduženi oblik sliva upućuje na pojavu izduženih hidrograma s neizraženim maksimumom, no s obzirom da je geološka građa sliva Slanog potoka podijeljena na dvije zone koje čine flišni i krški dio, koji se značajno razlikuju po koeficijentu otjecanja, hidrogrami imaju istaknute maksimume, a vodotok pokazuje brz odziv na palu oborinu pa se ovaj sliv može bolje klasificirati kao sliv „okruglog“ oblika ukoliko se uzme u obzir oblik flišne površine sliva na kojoj je otjecanje mnogo izraženije.

Srednja nadmorska visina nije analizirana za potrebe disertacije no na temelju digitalnog elevacijskog modela razlučivosti  $25 \times 25$  metara određen je srednji pad sliva uz pomoć programskog paketa MATLAB R2012b (MathWorks). Srednji pad sliva je 22%, a nagibi se kreću u rasponu od 5% do 100% što sliv karakterizira kao veoma strm. Nagibi sliva utječu na uvjete otjecanja i procese erozije koji su na području Slanog potoka veoma izraženi. Ako se razmotri samo dio sliva na flišnoj podlozi srednji nagib sliva iznosi 19% (Ružić i sur., 2011). Na *Slici 32.* prikazana je prostorna raspodjela padova sliva po površini sliva temeljem analize provedene pomoću programskog paketa MATLAB (Mathwoks), a na *Slici 33.* prostorna raspodjela nadmorske visine.



*Slika 32. Rezultati analize digitalnog elevacijskog modela prostorne raspodjele pada sliva (Ružić i sur., 2011)*





Slika 33. Rezultati analize digitalnog elevacijskog modela raspodjele nadmorske visine sliva (Ružić i sur., 2011)

Pad vodotoka nije analiziran s obzirom da na slivu Slanog potoka ne postoji geodetska snimka uzdužnog pada vodotoka.

Specifičnu gustoću drenске mreže u slivu Slanog potoka moguće je izračunati prema izrazu (4). Na slivu Slanog potoka izražen je glavni vodotok te četiri manje pritoke čija je dužina dobivena na temelju topografske karte redom:  $L_1 = 2,15\text{km}$ ,  $L_2 = 0,636\text{km}$ ,  $L_3 = 0,151\text{km}$ ,  $L_4 = 0,102\text{km}$  i  $L_5 = 0,142\text{km}$ .

$$D = \frac{\sum L}{A} = \frac{2,15\text{km} + 0,636\text{km} + 0,151\text{km} + 0,102\text{km} + 0,142\text{km}}{2,2\text{km}^2} = 1,45 \frac{1}{\text{km}}$$

Gdje je:

$D$  – Gustoća drenске mreže [ $\text{km}/\text{km}^2$ ]

$A$  – Površina sliva [ $\text{km}^2$ ]

$L$  – Duljina vodotoka [ $\text{km}$ ]

Prema određenoj specifičnoj gustoći drenске mreže može se zaključiti da je sliv „srednje“ dreniran.

### 2.6.6. Stanje, istraživanja i zahvati na slivu Slanog potoka

Sliv Slanog potoka je zbog svoje kompleksne geološke strukture, strmog pada sliva (22%) te površine zahvaćene erozijskim procesima i lokalnim klizištima već dugi niz godina predmet istraživanja (Ružić i sur., 2011). Njegov bujični karakter koji se očituje u pojavi bujica, muljnog toka i debrinih poplava predstavlja


štetnu pojavu kojom su ugrožena naselja (Belgrad, Baretići, Grižanje i Kamenjak) i komunalna te prometna infrastruktura. S obzirom na spomenute razloge za područje sliva Slanog potoka postoje hidrogeološka istraživanja, pokušaji i prijedlozi za sanaciju koji na žalost nisu doveli do rješenja cjelokupnog i vrlo kompleksnog problema. Problemi na području sliva Slanog potoka prepoznati su već 90-ih godina devetnaestog stoljeća kada se pokušava zaustaviti procese erozije na slivu Slanog potoka pošumljivanjem s 12 000 sadnica vrbe 1899. godine (Jurković i sur., 2010). Od tada se konstantno radilo na održavanju vodotoka, kako izradom bujičnih pregrada, drenažnih kanala i kineta tako i pokušajem umanjenja erozijskih procesa sadnjom borova. 60-ih godina dvadesetog stoljeća planirala se i izgradnja velike pregrade koja bi zaustavila erozivne procese no izgradnja nije realizirana jer su 1964. godine zabilježene katastrofalne bujice koje su izazvale velike štete na postojećim objektima te pokrenule otvaranje novih kliznih ploha i pojačanih erozijskih procesa. Nakon katastrofalnih bujica 1970-ih godina izrađuje se projekt sa strane Vodoprivrede Rijeka pod nazivom „Uređenje bujice Mala Dubračina“ u sklopu kojeg je tehničar Andrija Lušičić ručno ucrtao u topografski kartu M 1:2000 stanje vodoprivrednih objekata u slivu bujice Slani potok i Mala Dubračina. Posebnost toga projekta je u prikazu stanja nakon katastrofalnih bujica. Digitalizirana karta prikazana je na *Slici 34*. S obzirom da je većina dokumentacije iz toga vremena izgubljena, vrijednost ove karte može se prepoznati i u ucrtavanju postojećih bujičnih pregrada kojih na glavnom toku Slanog potoka ima 45 dok je na desnoj pritoci evidentirano 24 stepenica te izgrađena jedna kineta (kamen u betonu). Na uzvodnoj lijevoj pritoci evidentirane su 3 bujične pregrade dok su na nizvodnoj lijevoj pritoci evidentirane 4 bujične pregrade. Od 1970-ih godina do danas nije izgrađen niti jedan novi objekt na vodotoku, a štete objekata koje su nastale tokom katastrofičnih bujica 1964. godine nisu u potpunosti sanirane. Održavanje zaplavnih prostora bujičnih pregrada se ne izvršava redovito. Većina je zaplavnih prostora prepunjena nanosom pa se novonastali materijal s erozijske površine, prilikom nastanka bujica, kreće prema nizvodnim dijelovima vodotoka što uzrokuje pojavu muljnog toka. Neodržavanje i izostanak obnavljanja pojedinih pregrada dovelo je do degradacije postojećeg prirodnog korita Slanog potoka pa pri nadolasku bujica dolazi do pronosa krupnozrnatog materijala koji se nalazi u koritu vodotoka, odnosno bujice poprimaju karakteristike debitne poplave što u konačnosti dovodi

do povećanja štetnih pojava kako na samom vodotoku tako i u smislu oštećenja okolnog područja prometne i komunalne infrastrukture.

Uz pokušaje sanacije erozivnih problema te pojave bujica od kraja 50-ih godina dvadesetog stoljeća pa do danas proveden je niz geoloških, inženjerskogeoloških, hidrogeoloških i geomehaničkih istraživanja koja na žalost također nisu dovela do kvalitetnih zaključaka ili prijedloga sanacije. Jedan od zadnjih prijedloga za sanaciju je izradio Institut za elektroprivredu i energetiku d.d. (Jurković i sur., 2010) no niti ono nije detaljnije razrađeno i izvedeno.

U *Tablici 4.* su prikazana geološka, inženjerskogeološka, hidrogeološka i geomehanička istraživanja koja su izvedena na slivu Slanog potoka.





Slika 34. Stanje vodoprivrednih objekata u slivu bujice Slani potok i Mala Dubračina (Andrija Lušičić)

Tablica 4. Kronološki pregled geoloških, inženjerskogeoloških, hidrogeoloških i geomehaničkih istraživanja na slivu Slanog potoka; izrađeno prema Jurković i sur. (2010)

GOD.	VRSTA ISTRAŽIVANJA	IZVOĐAČ	OPIS ISTRAŽIVANJA
1957	Hidrogeološki i geološki istražni radovi	Geološki institut SR Hrvatske i IGH SRH	Utvrđivanje osnovnih parametara klizne plohe i hidrogeoloških parametara
1965	Sondiranje terena kod Grižana	Rijeka projekt - geotehničko istraživanje	Na dijelu terena kod između groblja kod naselja Belgrad i županijske ceste (Tribalj-Grižane-Bribir) izbušeno je 15 bušotina (dubina-3,70-8,00m)
1968	Klizište Grižane - Inženjerskogeološki radovi	Institut za geološka istraživanja SRH	Izrađena geološka karta (M1:5000) koja prikazuje različite nestabilnosti tla i fizičko-geološke procese, deformacije terena, hidrogeološke pojave i položaja 44 bušotine (10 strukturnih i 34 prospektorske) a 14 ih je izvedeno kao piezometri
1974	Klizište Slani potok-Mala Dubračina, Elaborat o geomehaničkim istraživanjima	IGH Zagreb	Izvedene su 34 bušotine od čega 23 piezometarske te je izvršena laboratorijska obrada uzoraka, dani geološko-geotehnički profili, orijentacijski položaj drenažnih rovova
1976	Odron na cesti Grižane-Kamenjak - geomehanički izvještaj	Geoexpert Zagreb	Izbušene su tri istražne bušotine i obavljeno laboratorijsko ispitivanje fizičko-mehaničkih svojstava na 10 uzoraka
1977	Izvještaj o klizištu Slani potok i Mala Dubračina kod Grižana	Općina Crikvenica, OVP Rijeka	Opis postupaka istraživanja i planirani i izvedeni građevinski radovi te prijedlog nastavka radova na sanaciji.
1980	Strukturno-geomorfološka i neotektonska istraživanja	RGN	Na uzorcima litotipova fliša provedena su sedimentološka i mineraloška istraživanja
2000	Križišće -Tribalj-Grižane-Bribir-Novi Vinodolski, Dionica Blaškovići-Grižane dužine oko 1 km	IGH PC Rijeka	Za potrebe sanacije oštećenja ceste izbušeno 6 istražnih bušotina u tri profila te su obavljena laboratorijska ispitivanja.
2001	Program istraživačkih radova za područje sliva Slani potok i Male Dubračine u Vinodolskoj dolini	RGN	Prijedlog programa istraživanja te definiran geološki okvir problema ekscesivne erozije
2007	Geološko-tektonska osnova za studij pojačane erozije u slivu Dubračine	Institut za geološka istraživanja	Prikaz svih litostratigrafskih jedinica izdvojenih na širem području sliva Dubrašine, te tektonskih odnosa u Vinodolskoj dolini, izrađena geološka karta M 1:2500 šireg područja sliva Dubračine

Provedena istraživanja na slivu Slanog potoka su većinom geološka, a proizlaze iz potrebe pronalaska načina sanacije ili cjelokupnog rješenja erozivnih procesa na slivu koji su sada već dosegli ekcesivne razmjere. Iako je neupitno utvrđen utjecaj vode, kao pokretačke komponente u erozivnim procesima, na ovom području nisu zabilježena značajnija hidrološka i meteorološka istraživanja. Iz svega navedenog, za daljnje i detaljnije je analiziranje cjelokupne problematike na istražnom području Slanog potoka neophodno istraživanje koje se prvenstveno treba temeljiti na praćenju hidroloških i meteoroloških podataka.

Temeljem analize prikupljenih prethodnih istraživanja na području sliva Slanog potoka može se zaključiti da ovaj povijesno prepoznati prostor, pod utjecajem štetnih pojava uzrokovanih djelovanjem vode, predstavlja dugogodišnji i kompleksni problem kojemu se za rješenje treba pristupiti multidisciplinarno. Upravo zbog toga ovo područje, već cijeli niz godina, privlači mnoge istraživače koji svojim raznolikim pristupima pridonose boljem shvaćanju procesa koji se odvijaju na ovom području, a prilikom čega je objavljen čitav niz znanstvenih radova. Za ovo su istraživanje značajni radovi Benca i sur. (2005) u kojem se objašnjava proces ekcesivne erozije, Aljinovića i sur. (2010) u kojem je opisana geološka struktura te procesi nastanka erozije na slivu Slanog potoka, Ružića i sur. (2011) u čijem su radu analizirana otjecanja sa sliva Slanog potoka i izvora rijeke Dubračine te rad Sušanj i sur. (2013) koji izrađuju bazu podataka stanja vodotoka na području Vinodolske doline.

Prethodna istraživanja sliva Slanog potoka ukazuju na nedostatak meteoroloških i hidroloških mjerenja dok cjelokupna problematika područja daje motivaciju za daljnjim istraživanjem područja.



### **3. METODOLOGIJA RAZVOJA MODELA**

Razvoj hidrološkog modela otjecanja na malim slivovima zahtijeva sustavni pristup u smislu određivanja metodologije razvoja modela, prikupljanja hidroloških i meteoroloških mjerenja za potrebe modela, odabira arhitekture umjetne neuronske mreže te načina na koji će model biti evalviran, a koji su svaki zasebno u nastavku rada detaljno opisani. Unutar ovoga poglavlja bit će prikazan način na koji su provedena mjerenja za potrebe izrade modela te numerička osnova modela umjetne neuronske mreže i algoritama treniranja na temelju kojeg će biti razvijen model, kao i odabir mjera kvalitete modela koji će se primjeniti za proces evaluacije modela.

#### **3.1. Metodologija razvoja modela umjetne neuronske mreže**

Kao što je već ranije opisano u poglavlju 2.5.7., koraci metodologije izrade modela temeljenog na umjetnoj neuronskoj mreži čine osnovu za razvoj hidrološkog modela otjecanja.

Prethodnim je istraživanjem utvrđen nedostatak detaljnije razrađenih metodologija i ujednačenih procedura koji su preduvjet povećanja kvalitete modela umjetnih neuronskih mreža.

S obzirom na ukazanu potrebu za razvojem detaljnije metodologije i ujednačavanja procedura koje će se primjenjivati pri implementaciji hidroloških modela predviđanja otjecanja temeljenih na umjetnoj neuronskoj mreži, unutar ove disertacije cilj je, na temelju razvijenog hidrološkog modela predviđanja otjecanja s malih slivova, definirati precizne proceduralne korake metodologije za implementaciju takve vrste modela.

Postojeća metodologija kao što je ona koju su predložili Maier i sur. (2010) prikazana na *Slici 18.* čini ishodišnu metodologiju na temelju koje će unutar disertacije biti razvijen model, a potom i upotpunjena detaljnim koracima procedure koji će omogućiti implementaciju hidroloških modela na malim slivovima upotrebom umjetne neuronske mreže.

Metodologija razvoja hidrološkog modela koju su predložili Maier i sur. (2010) daje opću proceduru koja se općenito može podijeliti u nekoliko glavnih koraka: (i) Prikupljanje podataka, (ii) Odabir arhitekture modela umjetne neuronske

mreže, (iii) Programiranje modela (treniranje i validacija modela) i (iv) Ocijena kvalitete modela. Prikupljanje podataka za potrebe razvoja hidrološkog modela otjecanja obuhvaća prikupljanje meteoroloških i hidroloških podataka. Odabir arhitekture modela umjetne neuronske mreže odnosi se na odabir odgovarajuće arhitekture koju je moguće primjeniti na konkretnom hidrološkom sustavu kojega se modelira nakon čega je potrebno u odgovarajućem programskom paketu programirati odabranu arhitekturu modela te provesti treniranje i validaciju modela. Na samom kraju potrebno je provesti ocijenu kvalitete modela, odnosno evaluaciju modela, s odgovarajućim mjerama kvalitete kako bi se takav model mogao usvojiti kao model određenog hidrološkog sustava.

Shodno osnovnim smjernicama metodologije za razvoj modela u nastavku rada je opisan postupak prikupljanja podataka mjerenjem hidroloških i meteoroloških podataka na istražnom području sliva Slani potok. Nadalje, za potrebe izrade hidrološkog modela predviđanja otjecanja izabrana je arhitektura višeslojnog perceptrona čija će svojstva i ustroj biti detaljno opisani. Algoritmi treniranja modela umjetne neuronske mreže su od velike važnosti za efikasan rad modela pa će svi oni u nastavku biti detaljno opisani. Za potrebe treniranja umjetne neuronske mreže u ovoj će se disertaciji koristiti koristit Levenberg – Marquardt algoritam. Za ocijenu kvalitete modela u procesu validacije i evaluacije koristi se cijeli niz različitih mjera kvaliteta, a u sklopu ove disertacije biti će prikazan pregled najčešće korištenih mjera kvalitete te odabir onih koje će se koristiti za ocijenu kvalitete predmetnog modela.

### **3.2. Hidrološka i meteorološka mjerenja na istražnom području Slanog potoka**


U sklopu međunarodnog hrvatsko-japanskog znanstvenog projekta: „*Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje nepogoda kod odrona zemlje i poplava u Hrvatskoj*“ (eng. *Risk Identification and Land Use Planning for Disaster Mitigation of Landslides and Floods in Croatia*), 2009. godine započinjju sveobuhvatna geološka, hidrogeološka i hidrološka istraživanja, kako na području Vinodolske doline, tako i na području Slanog potoka. Rezultati istraživanja tokom trajanja projekta rezultirali su nizom radova koji su prezentirani na organiziranim radionicama projekta, na mnogobrojnim tuzemnim i inozemnim radionicama i znanstvenim radovima, a čine temelj za izradu ove disertacije.



Uvidom u postojeću dokumentaciju istraživanja, evidentan je nedostatak kontinuiranih mjerenja meteoroloških i hidroloških podataka zbog čega je od 2012. godine uspostavljeno mjerenje.

Cilj istraživanja, za potrebe izrade modela temeljenog na umjetnoj neuronskoj mreži, je uspostava kontinuiranog mjerenja s obzirom da je to jedan od glavnih uvjeta koji omogućuje razvoj takve vrste modela.


Na *Slici 35.* su prikazani postavljeni instrumenti na području sliva Slanog potoka, a u nastavku će detaljnije biti opisan način i uspostava meteoroloških i hidroloških mjerenja s obzirom da su ti podaci korišteni u sklopu disertacije.



*Slika 35. Situacijski prikaz postavljenih instrumenata na području sliva Slani potok; prikaz izradila: Ivana Sušan na ortofotografskoj podlozi*

### 3.2.1. Hidrološka mjerenja


U sklopu već ranije spomenutog znanstvenog projekta 2009. godine započinje se s hidrološkim mjerenjima koja su na početku obuhvaćala mjerenja brzine vode u vodotoku na unaprijed predviđenom profilu (Ružić i sur., 2011) te nakon toga od 2012. godine započinje se s kontinuiranim mjerenjem razina vode tlačnom sondom. Za potrebe kontinuiranog mjerenja razina vode koristila se tlačna sonda miniDiver (DI502 – 20m) proizvođača Schlumberger Water Services (*Slika 36.*) koja uz razine vode bilježi i temperaturu vode. Raspon mjerenja instrumenta je 20 metara vodnog stupca, točnost  $\pm 1,0$  cm, a rezolucija 4 mm. Instrument ima ugrađenu bateriju i prostor za pohranu podataka na koji stane oko 24000 podataka, te je moguće definirati vremenski korak pohrane podataka. Na samom početku trebalo je odrediti vremenski korak mjerenja prilikom čega su se testirali jednominutni, dvominutni, petominutni i desetominutni vremenski koraci mjerenja. Iako se jednominutnim mjerenjima dobivaju veoma detaljna mjerenja razina vode, dvominutni vremenski koraci mjerenja ne ukazuju na razlike u smislu točnosti mjerenja dok kod petominutnih i desetominutnih koraka mjerenja postoji mogućnost da se ne uspiju zabilježiti maksimalne razine vode. S obzirom na bujične karakteristike vodotoka, odnosno brz odziv sliva na pale oborine, određen je dvominutni korak pohrane kako bi bilo moguće zabilježiti naglo podizanje razina vode odnosno kako bi se mjerenjima dobio što točniji nivogram te ujedno izbjeglo nepotrebnu količinu podataka dobivenu jednominutnim korakom vremena mjerenja. Nakon završetka spomenutog projekta istraživanje je nastavljeno uz financiranje Sveučilišne potpore za materijalno zahtjeva istraživanja: „Hidrologija vodnih resursa i identifikacija rizika od poplava i blatnih tokova na krškom području“.



Slika 36. Tlačna sonda tipa miniDiver (DI502 – 20m) proizvođača Schlumberger Water Services ([www.swstechnology.com](http://www.swstechnology.com))



Tlačna sonda je postavljena na unaprijed određenom profilu vodotoka koji se nalazi na najnižvodnijem mjestu vodotoka na koji rijeka Dubračina, u koju vodotok Slani potok utječe, nema utjecaj uspora. Položaj postavljenog instrumenta prikazan je na geološkoj podlozi na *Slici 35*. dok je na *Slici 37*. prikazana fotografija položaja na kojem se provode kontinuirana mjerenja razine vode.



*Slika 37. Mjerni profil postavljene tlačne sonde tipa miniDiver (DI502 – 20m); autor fotografije: Ivana Sušanj*

Za potrebe istraživanja unutar ove disertacije koristit će se podaci prikupljeni u razdoblju od 2012. -2015. godine. Unutar ovoga razdoblja prikupljen je dovoljno dug niz podataka koji je okarakteriziran s više oborinskih epizoda visokog intenziteta koje su izazvale naglo podizanje nivograma. Valja napomenuti da su prve dvije godine (2012 i 2013) bile sušne godine te je u tom razdoblju mnogo puta vodotok presušio stoga nisu zabilježena značajnija podizanja razine vode koja bi mogla poslužiti za analizu u disertaciji. Otegotnu okolnost pri mjerenju stvarao je muljni nanos na mjestu mjerenja zbog kojeg očitavanje instrumenta ponekad nije bilo mjerodavno te se zbog toga moralo odbaciti.

### **3.2.2. Meteorološka mjerenja**


Na slivu Slanog potoka tokom 2012. godine su postavljene dvije automatske meteorološke postaje Vantage Pro 2 proizvođača Davis Instruments Corporation (*Slika 38.*) putem kojih se kontinuirano prikupljaju sljedeći

meteorološki podaci: (i) Količina oborine, (ii) Intenzitet oborine, (iii) Temperatura zraka, (iv) Tlak zraka, (v) Vlažnost zraka, (vi) Solarna radijacija (Insolacija), (vii) Smjer vjetra i (viii) Brzina vjetra. Automatska meteorološka postaja se sastoji od dva osnovna dijela, a to su vanjski dio koji ima funkciju mjerenja te unutarnji dio instrumenta koji se postavlja u zaklon te prikuplja i sprema podatke. Vanjski odnosno mjerni dio meteorološke postaje se napaja solarnim panelom dok su za unutarnju jedinicu potrebne ili baterije ili pristup struji. Unutarnji i vanjski dio meteorološke postaje komuniciraju bežičnom vezom.



*Slika 38. Meteorološka postaja Vantage Pro 2 proizvođača Davis Instruments Corporation: unutarnji i vanjski dio instrumenta; (www.cactusnav.com)*

Meteorološke postaje su postavljene u mjestu Kamenjak i na mjesnom groblju Belgrad, a točni položaj prikazan je na *Slici 35*. dok su na *Slici 39*. prikazane fotografije postavljenih instrumenata. Razlog postavljanja dvije meteorološke postaje je utvrđivanje razlike meteoroloških podataka s obzirom na površinu sliva.



Slika 39. Položaj postavljenih automatskih meteoroloških postaja: a) Kamenjak i b) Mjesno groblje Belgrad; autor fotografija: Ivana Sušanjanj

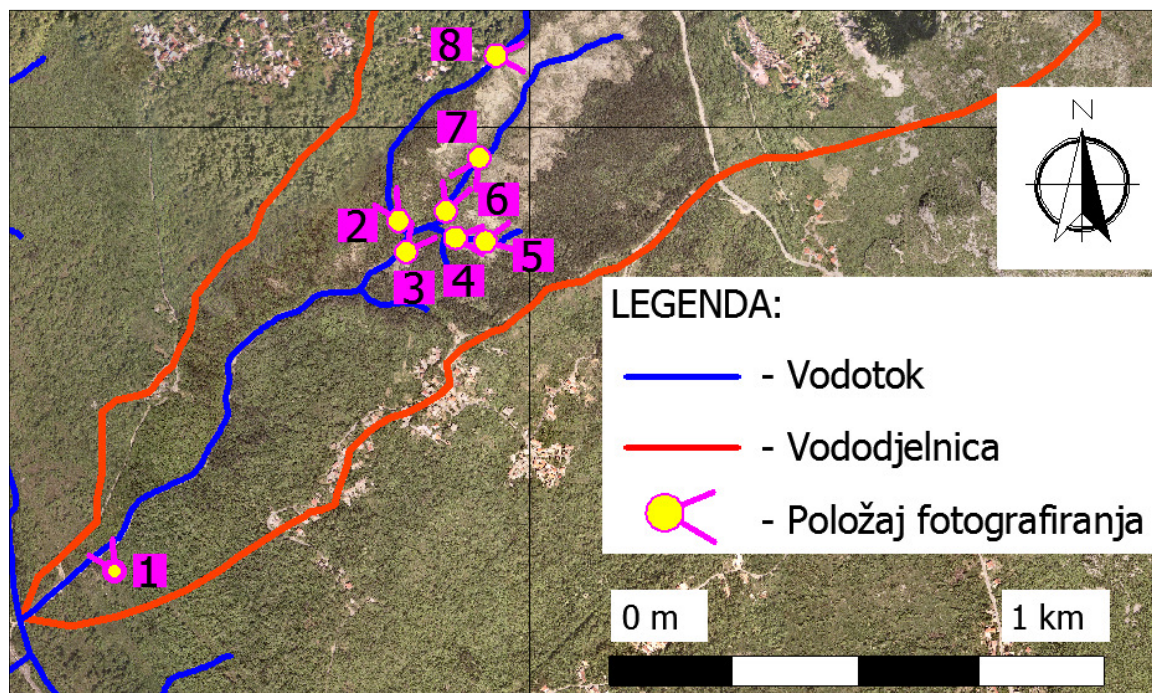
Prilikom uspostave mjerenja u 2012. godini i dalje tokom 2013. godine meteorološke postaje bile su programirane na prikupljanje meteoroloških podataka s uobičajenim vremenskim korakom od 10 minuta. U 2014. godini vremenski korak mjerenja je smanjen na dvominutni korak mjerenja kako bi mjerenja bila usklađena s mjerenjima razine vode tlačnim sondama te time pojednostavljena analiza podataka. Otegotne okolnosti pri kontinuiranom mjerenju stvarao je olujni vjetar koji je u nekoliko navrata nanio štetu na instrumentima te time ugrozio slijed kontinuiranog mjerenja kao i počinjen vandalizam na instrumentima prilikom kojeg je meteorološka postaja na mjesnom groblju Belgrad početkom 2015. godine u potpunosti devastirana.

### **3.2.3. Praćenje štetnih pojava na slivu Slanog potoka**

U samom početku istraživanja početkom 2012. godine za potrebe disertacije bilo je potrebno utvrditi trenutačno stanje hidrotehničkih objekata na vodotoku Slani potok, utvrditi stanje erozijskog područja i njegov utjecaj na okolna mjesta kao i utjecaj erozije na postojeću prometnu i komunalnu infrastrukturu. Utvrđivanje stanja provedeno je detaljnim obilaskom područja te fotodokumentiranjem stanja. Na *Slici 40.* prikazane su brojevima položaji na








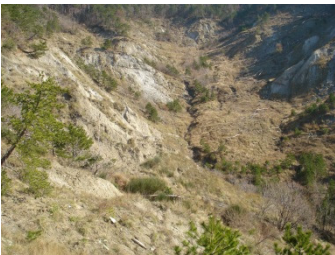


kojima su slikane fotografije stanja sliva i vodotoka. Dok su u *Tablici 5.* prikazane fotografije stanja sliva s opisom.



Slika 40. Situacijski prikaz položaja fotografiranja stanja sliva Slanog potoka; prikaz izradila: Ivana Sušan na ortofotografskoj podlozi

Tablica 5. Foto dnevnik stanja sliva i vodotoka Slanog potoka 2012. Godine; autor fotografija: Ivana Sušan


FOTOGRAFIJA	STANJE SLIVA ili VODOTOKA	FOTOGRAFIJA	STANJE SLIVA ili VODOTOKA
	1 Zapravni prostor bujične pregrade prepun mulja i krupnozrnatog materijala		5 Bujične pregrade čiji su zaplavni prostori u potpunosti zapunjeni nanosom te kao takvi nisu u funkciji
	2 Kineta (kamen u betonu) neoštećena no obrasla te s nakupinama nanosa		6 Cijevni hidrotehnički objekt u funkciji sifonskog propusta vode s naniže točke erozijske baze ukazuje na tragove nanosa
	3 Bučnica stepenice u potpunosti ispunjena nanosom te stoga nefunkcionalna		7 Ulaz u sifonski propust vode u najnižoj točki erozijske baze djelomično neprohodan te ispunjen nanosom
	4 Kineta (kamen u betonu) neoštećena no obrasla raslinjem		8 Žarište erozije ukazuje na aktivne procese, vidljiva svježa lokalna klizišta te izražene jaruge nastale pod utjecajem tečenja vode

Početno stanje sliva i vodotoka Slani potok može se opisati kao zabrinjavajuće. Godine neodržavanja hidrotehničkih objekata koji se ispunjeni nanosom obrasli raslinjem čine uvjete za nastanak štetnih pojava kao što su bujice, muljni tok te debratne poplave. Većinu bujičnih pregrada u srednjem dijelu glavnog toka nije bilo moguće niti pronaći jer su ili u potpunosti zatrpane ili uništene pod utjecajem djelovanja vode. Žarište erozije pokazuje tendencije



širenja te izrazitog trošenja flišnog kompleksa dok je veličina površine zahvaćene erozivnim procesima impresivne veličine te na neki način daje objašnjenje dugoročnog neriješenog inženjerskog problema sanacije tog područja. Prometna infrastruktura je prohodna no pokazuje naznake deformacija asfaltnih površina na cijelokupnom području oko žarišta erozije što je uzrokovalo i oštećenja komunalne infrastrukture kao što je primjerice pucanje vodovodnih cijevi.


Od 2012. godine, uz uspostavu mjerenja hidroloških i meteoroloških podataka, kontinuirano se provode redoviti obilasci istražnog područja, a posebice za vrijeme i nakon oborina velikog intenziteta. Redovitim obilascima evidentirana je pojava muljnog toka, bujica i debrinnih poplava primjeri kojih su prikazani na *Slici 41*.



*Slika 41. Zabilježene pojave: a) Muljni tok (29.07.2014.); b) Bujični tok (21.08.2014.) i c) Debrinna poplava (21.08.2014.) na nizvodnom dijelu vodotoka Slani potok (Pelićev most); autor fotografija: Ivana Sušanj*



Tokom redovitih obilaska evidentirana je i stalna degradacija područja sliva u smislu oštećenja prometne i komunalne infrastrukture i pojave lokalnih klizišta kao što je prikazano na *Slici 42*.



*Slika 42. Zabilježena oštećenja: a) Oštećenje kolničke trase na Pelićevom mostu (21.08.2014); b) Oštećenje kolnika na lokalnoj cesti Belgrad-Rupe (3.3.2015) i c) Lokalno klizište na rubu žarišta erozije ispod lokalne ceste Belgrad-Kamenjak (3.3.2015); autor fotografija: Ivana Sušan*

Većina oštećenja zabilježena je tokom 2014. godine pod utjecajem oborina velikog intenziteta, a posljedice istih nastavile su se i tokom početka 2015. godine.

Na temelju obilaska terena može se utvrditi da nastupanje štetnih pojava može ugroziti okolna naselja Belgrad, Baretići, Grižane i Kamenjak, a pogotovo postojeću prometnu i komunalnu infrastrukturu. Također u nizvodnim dijelovima vodotoka štetne pojave ugrožavaju Pelićev most te postoji i mogućnost propagacije mulja i krupnozrnatog materijala u rijeku Dubračinu prilikom čega je moguć pronos materijala i do grada Crikvenice. S obzirom na niz neuspjelih ranije opisanih prijedloga sanacije te uz sve češće nastupanje štetnih pojava, do pronalaska inženjerskog rješenja problema, predlaže se implementacija sustava za rano uzbuđivanje. Implementacija sustava za rano uzbuđivanje moguća je uz razvoj hidrološkog modela otjecanja za sliv Slanog potoka što je i jedan od ciljeva ove disertacije.

Hidrološki model predviđanja otjecanja, unutar disertacije, bit će temeljen na umjetnoj neuronskoj mreži, arhitekture višeslojnog perceptrona. Ulaznu varijablu modela činiti će meteorološki podaci dok će izlaznu varijablu predviđanja činiti razine vode u vodotoku. U nastavku rada bit će detaljno opisan razvoj modela.


### **3.3. Višeslojni perceptron i treniranje umjetne neuronske mreže**

Za potrebe razvoja hidrološkog modela predviđanja otjecanja temeljenog na umjetnoj neuronskoj mreži koristit će se arhitektura modela višeslojnog perceptrona čije je treniranje nadgledano. U nastavku rada opisana je arhitektura višeslojnog perceptrona te proces treniranja. Zbog razumijevanja algoritma treniranja objašnjene su sve vrste algoritama koji dovode do razvoja Levenberg-Marquardt-ovog algoritma putem kojeg će biti provedeno treniranje umjetne neuronske mreže u sklopu disertacije.

#### **3.3.1. Višeslojni perceptron**

Razvoj neuronskih mreža je kroz povijest bio vezan za razvoj računalstva i algoritama za treniranje neuronskih mreža pa je njihov najveći razvoj zabilježen od 1970-ih godina. Ključan trenutak u razvoju neuronskih mreža pokazao se razvoj algoritma propagacije pogreške unatrag kojeg je prvi puta koristio, u sklopu neuronskih mreža, Frank Rosenblat (1962). Daljnji značajan napredak bio je vidljiv u pokušajima da se pojedini perceptroni odnosno umjetni neuroni formiraju u slojeve tvoreći višeslojni perceptron, čiju je osnovnu ideju primijenio Paul Werbos,

1974-e u svojoj disertaciji. Višeslojni perceptron je statička (unaprijedna) neuronska mreža koja se sastoji od najmanje tri sloja: ulaznog, skrivenog i izlaznog sloja kao što je prikazano na *Slici 43*.



*Slika 43. Model višeslojnog perceptrona; prikaz izradila: Ivana Sušanaj prema Abraham i sur. (2004)*

### **3.3.2. Treniranje umjetnih neuronskih mreža i algoritmi za izračun mjere promjene $\Delta w$ u sklopu optimizacijskog parametara $w_k$**

Za potrebe treniranja višeslojnog perceptrona koristiti će se Levenberg-Marquardt algoritam. Ovaj algoritam spada u algoritme drugoga reda te je razvijen specijalno za treniranje mreža višeslojnog perceptrona u cilju bržeg treniranja, odnosno učenja umjetnih neuronskih mreža. Ovim algoritmom se ostvaruje brže i preciznije konvergencije ka minimumu kvadratne funkcije pogreške. Levenberg-Marquardt algoritam se temelji na Gauss-Newton-ovom (GN) algoritmu i algoritmu propagacije pogreške unatrag. Zbog boljeg razumijevanja korištenog algoritma u nastavku će rada biti prvo objašnjeni lokalni algoritmi prvoga reda, a potom drugoga te na kraju Levenberg-Marquardt algoritam (Matić, 2014).

Kao što je prethodno objašnjeno treniranje umjetnih neuronskih mreža može se opisati kao korekcija optimizacijskog parametara  $w_k$  neuronske mreže kako bi kroz odgovarajući broj iteracija dala željeni odziv pa se putem algoritma treniranja definira mjera promjene  $\Delta w$  kao što je prikazano u izrazu (7) (Matić, 2014).

### 3.3.3. Lokalni algoritmi prvoga reda

Općenito, postupke optimizacije koji se temelje na linearnoj aproksimaciji funkcije pogreške nazivamo algoritmima prvoga reda ili gradijentnim postupkom. Kao što je već ranije spomenuto među lokalne algoritme prvoga reda spadaju algoritam propagacije pogreške unatrag (BP) koji se još naziva i Delta pravilo te Generalizirano delta pravilo koje možemo smatrati unaprijeđenim delta pravilom (Haykin, 2009; Govindaraju i Ramachandra Rao, 2000).

Algoritam propagacije pogreške unatrag služi se gradijentom funkcije pogreške, odnosno njenom parcijalnom derivacijom po podesivim parametrima mreže pa mjeru promjene  $\Delta w$  možemo zapisati kao što je prikazano u izrazu (8) (Haykin, 2009; Govindaraju i Ramachandra Rao, 2000).

$$\Delta w_k = -\eta \frac{\partial E_k}{\partial w_k} \quad (8)$$

Gdje je:

$\Delta w_k$  – Mjera promjene u  $k$  – tom koraku računanja

$\eta$  – Bezdimenzionalna veličina koja definira intenzitet promjene parametra (brzina učenja)

$\frac{\partial E_k}{\partial w_k}$  – Parcijalna derivacija pogreške po podesivim parametrima u  $k$  – tom koraku računanja

Algoritam propagacije pogreške unatrag je jedan od najčešće korištenih metoda za računanje mjere promjene, a očituje se jednostavnošću izračuna parcijalne funkcije pogreške te prolaskom signala u dva smjera: (i) Unaprijed - od ulaza prema izlazu iz mreže, (ii) Unatrag - od izlaza prema ulazu mreže.

Za vrijeme rasprostranjenja signala unaprijed kroz mrežu višeslojnog perceptrona svaki neuron računa preko aktivacijske funkcije neurona  $\phi(v_k)$  vrijednost odziva neurona  $o_k$  na temelju trenutnih ulaznih podataka  $x_{1,2,3,\dots,m}$  i optimizacijskih parametara mreže  $w_{1,2,3,\dots,m}$ .

Rasprostiranje signala unatrag započinje u izlaznom sloju mreže višeslojnog perceptrona kada je moguće izračunati pogrešku  $e_k^j$  u  $k$ -tom koraku za  $j$  – ti neuron na temelju vrijednosti odziva neurona mreže  $o_k^j$  i željenog odziva mreže  $d_k^j$  kao što je prikazano u izrazu (9).

$$e_k^j = d_k^j - o_k^j \quad (9)$$

Gdje je:

- $e_k^j$  – Pogreška  $j$  – tog neurona mreže višeslojnog perceptrona u  $k$  – tom koraku računanja  
 $d_k^j$  – Željeni odziv  $j$  – tog neurona mreže višeslojnog perceptrona u  $k$  – tom koraku računanja  
 $o_k^j$  – Odziv  $j$  – tog neurona mreže višeslojnog perceptrona u  $k$  – tom koraku računanja

U svrhu izračunavanja mjere promjene mreže potrebno je nadalje izračunati parcijalnu derivaciju pogreške mreže prema izrazu (10) koju možemo izračunati i preko lokalnog gradijenta  $\delta_k$  za  $j$  – ti neuron u  $k$  – tom koraku računanja kao što je prikazano u izrazu (4).

$$\frac{\partial E_k^j}{\partial w_k^j} = \delta_k^j \cdot o_k^j \quad (10)$$

Gdje je:

- $\frac{\partial E_k^j}{\partial w_k^j}$  – Parcijalna derivacija pogreške neurona po podesivim parametrima u  $k$  – tom koraku računanja  
 $\delta_k^j$  – Lokalni gradijent za  $j$  – ti neuron u  $k$  – tom koraku računanja  
 $o_k^j$  – Odziv  $j$  – tog neurona mreže višeslojnog perceptrona u  $k$  – tom koraku računanja

Lokalni gradijent  $\delta_k$  za  $j$  – ti korak računanja u  $k$  – tom koraku računa se kao umnožak pogreške  $e_k^j$  u  $k$ -tom koraku za  $j$  – ti korak računanja te vrijednosti derivacije aktivacijske funkcije neurona za vrijednost sume umnožaka ulaznih podataka i težinskih koeficijenata u  $k$ -tom koraku računanja  $v_k$  kao što je prikazano u izrazu (11).

$$\delta_k^j = e_k^j \cdot (\varphi^j(v_k^j))' \quad (11)$$

Gdje je:

- $\delta_k^j$  – Lokalni gradijent za  $j$  – ti neuron u  $k$  – tom koraku računanja  
 $e_k^j$  – Pogreška  $j$  – tog neurona mreže višeslojnog perceptrona u  $k$  – tom koraku računanja  
 $(\varphi^j(v_k^j))'$  – Vrijednost derivacije aktivacijske funkcije  $j$  – tog neurona za vrijednost  $v_k^j$   
 $v_k^j$  – Suma umnožaka ulaznih podataka  $x_k$  i težinskih koeficijenata  $w_k$  u  $k$  – tom koraku računanja u  $j$ -ti neuron

Algoritam propagacije pogreške unatrag (BP) može se napisati i izrazom (12) uvrštavanjem izraza (10) u izraz (8) prilikom čega ga u tom obliku nazivamo Delta pravilo.

$$\Delta w_k^j = -\eta \cdot \delta_k^j \cdot o_k^j \quad (12)$$

Gdje je:

- $\Delta w_k^j$  – Mjera promjene  $j$  – tog neurona u  $k$  – tom koraku računanja  
 $\eta$  – Bezdimezionalna veličina koja definira intenzitet promjene parametra (brzina učenja)  
 $\delta_k^j$  – Lokalni gradijent za  $j$  – ti neuron mreže višeslojnog perceptrona u  $k$  – tom koraku računanja  
 $o_k^j$  – Odziv neurona mreže za  $j$  – ti neuron mreže višeslojnog perceptrona u  $k$  – tom koraku računanja

Kako je ovakav algoritam s obzirom na  $\eta$  koji definira intenzitet mjere promjene  $\Delta w$  odnosno brzinu učenja pridonosi njenoj sporosti te statičnosti, razvijen je jednostavan način da se kontrolira povećanje brzine učenja koje se zove Generalizirano delta pravilo. Unutar ovoga algoritma kojega se može smatrati poboljšanim Delta pravilom, uveden je moment  $\alpha$  kako bi se smanjio ili povećao iznos mjere promjene  $\Delta w_k$  u  $k$  – tom koraku računanja s obzirom na prethodni korak kao što je prikazano u izrazu (13).

$$\Delta w_k^j = \alpha \cdot \Delta w_{k-1} - \eta \cdot \delta_k^j \cdot o_k^j \quad (13)$$

Gdje je:

- $\Delta w_k^j$  – Mjera promjene  $j$  – tog neurona u  $k$  – tom koraku računanja  
 $\alpha$  – Moment za smanjenje ili povećanje mjere promjene  $\Delta w$  [-1,1]  
 $\Delta w_{k-1}$  – Mjera promjene u  $k-1$  – tom koraku računanja  
 $\eta$  – Bezdimezionalna veličina koja definira intenzitet promjene parametra (brzina učenja)  
 $\delta_k^j$  – Lokalni gradijent za  $j$  – ti neuron mreže višeslojnog perceptrona u  $k$  – tom koraku računanja  
 $o_k^j$  – Odziv neurona mreže za  $j$  – ti neuron mreže višeslojnog perceptrona u  $k$  – tom koraku računanja

Glavni problem korištenja algoritama prvoga reda je što izračunati gradijent ne upućuje direktno na minimum funkcije pogreške, što može dovesti do zaobilaženja minimuma odnosno spore konvergencije prema potencijalnom minimumu. Izravniju potragu za minimumom funkcije pogreške omogućavaju algoritmi drugoga reda koji će biti detaljnije opisani u nastavku.

### 3.3.4. Algoritmi drugoga reda

Lokalni algoritmi drugoga reda imaju za cilj povećati brzinu učenja mreže višeslojnog perceptrona kroz kvadratnu aproksimaciju funkcije pogreške te omogućiti brži i izravniji put ka minimumu funkcije pogreške. Kao i kod algoritama prvoga reda tako se i ovdje optimizacijski parametar  $w_k$  računa preko iterativnog postupka kao što je prikazano u izrazu (7). Kako bi se to omogućilo u mjeri promjene  $\Delta w_k$  umjesto bezdimezionalne veličine za definiranje inteziteta

promjene parametara  $\eta$  koristi se inverzni Hessian  $\mathbf{H}^{-1}$  kao što je prikazano u izrazu (14).

$$\Delta w_k = -\mathbf{H}^{-1} \cdot \frac{\partial E}{\partial w} \quad (14)$$

Gdje je:

$\Delta w_k$  – Mjera promjene u  $k$  – tom koraku računanja

$\mathbf{H}$  – Hessian matrica zakrivljenosti površine prostora pogreške

$\frac{\partial E}{\partial w}$  – Parcijalna derivacija pogreške po podesivim parametrima mreže

Hessian matrica daje podatak o zakrivljenosti površine prostora pogreške parcijalnom derivacijom drugoga reda prema izrazu (15) dok inverz Hessian matrice aproksimira matricu varijanci/kovarijanci parametara procjene pa se korištenjem ove matrice postiže preciznija procjena pogreške (Matić, 2014).

$$\mathbf{H} = \frac{\partial^2 E}{\partial w^2} = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1^2} & \frac{\partial^2 E}{\partial w_1 \partial w_2} \cdots & \frac{\partial^2 E}{\partial w_1 \partial w_n} \\ \frac{\partial^2 E}{\partial w_2 \partial w_1} & \frac{\partial^2 E}{\partial w_2^2} \cdots & \frac{\partial^2 E}{\partial w_2 \partial w_n} \\ \vdots & \vdots & \vdots \\ \frac{\partial^2 E}{\partial w_n \partial w_1} & \frac{\partial^2 E}{\partial w_n \partial w_2} \cdots & \frac{\partial^2 E}{\partial w_n^2} \end{bmatrix} \quad (15)$$

Gdje je:

$\mathbf{H}$  – Hessian matrica zakrivljenosti površine prostora pogreške

$\frac{\partial^2 E}{\partial w_n^2}$  – Parcijalna derivacija drugog reda pogreške po podesivim parametrima mreže

Kada se u izraz (7) za izračun optimizacijskog parametra  $w_k$  uvrste izrazi (14) i (15) dobiva se Newton-ov algoritam (16) koji na žalost za treniranje neuronskih mreža višeslojnog perceptrona nije upotrebljiv s obzirom da Hessian matrica nije singularna matrica ili nije dovoljnog ranga.

$$w_{k+1} = w_k - (\nabla^2 E(w))^{-1} \cdot \nabla E(w) \quad (16)$$

Gdje je:

$w_{k+1}$  – Optimizacijski parametar u  $k + 1$  koraku računanja

$w_k$  – Optimizacijski parametar u  $k$  – tom koraku računanja

$(\nabla^2 E(w))^{-1}$  – Parcijalna derivacija drugog reda pogreške po podesivim parametrima mreže

$\nabla E(w)$  – Parcijalna derivacija pogreške po podesivim parametrima mreže

Kako bi bilo moguće računati optimizacijski parametar  $w_k$  pri treniranju mreža višeslojnog perceptrona savjetuje se korištenje quasi-Newton ili Secant



metode koji računaju aproksimaciju Hessian matrice a najčešće se koriste Broyden, Fletcher, Shanno (BFGS) metode (Demuth i sur., 2004).

Kako je cilj računanja izbjegavanje računski vrlo zahtjevne Hessian matrice, pored korištenja quasi-Newton metode preporuča se korištenje metoda konjugiranog gradijenta (*eng. Conjugate gradient, CG*) ili Levenberg-Marquardt algoritma (LM) koji mjeru promjene  $\Delta w_k$  temelji na jednostavnijoj Jacobijevoj matrici. U nastavku rada će biti opisan LM algoritam koji je razvijen posebno za treniranje mreža višeslojnog perceptrona (Matić, 2014).

### **3.3.5. Levenberg-Marquardt algoritam za treniranje umjetne neuronske mreže višeslojnog perceptrona**

Kao što je već spomenuto ranije u radu, LM algoritam je razvijen specijalno za treniranje mreža višeslojnog perceptrona u cilju bržeg treniranja odnosno učenja umjetnih neuronskih mreža odnosno brže i preciznije konvergencije ka minimumu kvadratne funkcije pogreške, a osnove za razvoj ovoga algoritma dao je Marquardt (1963).

LM algoritam se temelji na Gauss-Newton-ovoj (GN) metodi, odnosno njezin je poseban slučaj. Gauss-Newton-ovu metodu dobivamo zamjenom Hessian matrice u izrazu (16) s Jakobijevom matricom koja se sastoji od prvih derivacija vektora pogreške po podesivim parametrima mreže. U izrazu (17) prikazan je optimizacijski parametar  $w_{k+1}$  preko Gauss-Newton-ove metode (Matić, 2014; Gavin, 2013; Balada, 2014).

$$w_{k+1} = w_k - (\mathbf{J}^T \cdot \mathbf{J})^{-1} \cdot \mathbf{J}^T \cdot \mathbf{e} \quad (17)$$

Gdje je:

$w_{k+1}$	– Optimizacijski parametar u $k + 1$ koraku iterativnog postupka
$w_k$	– Optimizacijski parametar u $k$ – tom koraku iterativnog postupka
$\mathbf{J}^T$	– Transponirana Jakobijeva matrica
$\mathbf{J}$	– Jacobija matrica derivacije vektora pogreške po podesivim parametrima mreže
$\mathbf{e}$	– Vektor pogreške

Jakobijeva matrica  $\mathbf{J}$  je kao prva derivacija vektora pogreške  $\mathbf{e}$  definirana izrazom (18).

$$\mathbf{J} = \frac{\partial \mathbf{e}}{\partial \mathbf{w}} = \begin{bmatrix} \frac{\partial \mathbf{e}_1}{\partial w_1} & \frac{\partial \mathbf{e}_1}{\partial w_2} & \dots & \frac{\partial \mathbf{e}_1}{\partial w_n} \\ \frac{\partial \mathbf{e}_2}{\partial w_1} & \frac{\partial \mathbf{e}_2}{\partial w_2} & \dots & \frac{\partial \mathbf{e}_2}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial \mathbf{e}_n}{\partial w_1} & \frac{\partial \mathbf{e}_n}{\partial w_2} & \dots & \frac{\partial \mathbf{e}_n}{\partial w_n} \end{bmatrix} \quad (18)$$

Gdje je:

- $\mathbf{J}$  – Jacobijeva matrica derivacija vektora pogreške po podesivim parametrima mreže  
 $\frac{\partial \mathbf{e}_1}{\partial w_1}$  – Derivacija vektora pogreške po podesivim parametrima mreže

LM algoritam koji definira mjeru promjene u optimizacijskom parametru i definiran je izrazom (19) kao poseban slučaj GN metode nastaje dodavanjem kombinacijskog koeficijenta  $\mu$  koji upravlja povećanjem ili smanjenjem sume kvadrata funkcije pogreške  $E(e)$ .

$$\mathbf{w}_{k+1} = \mathbf{w}_k - (\mathbf{J}^T \cdot \mathbf{J} + \mu \cdot \mathbf{I})^{-1} \cdot \mathbf{J}^T \cdot \mathbf{e} \quad (19)$$

Gdje je:

- $w_{k+1}$  – Optimizacijski parametar u  $k + 1$  koraku iterativnog postupka  
 $w_k$  – Optimizacijski parametar u  $k$  – tom koraku iterativnog postupka  
 $\mathbf{J}^T$  – Transponirana Jakobijeva matrica  
 $\mathbf{J}$  – Jacobijeva matrica derivacije vektora pogreške po podesivim parametrima mreže  
 $\mu$  – Kombinacijski koeficijent Levenberg – Marquardt algoritma  
 $\mathbf{I}$  – Jedinična matrica  
 $\mathbf{e}$  – Vektor pogreške


Kako bi se upravljalo povećanjem ili smanjenjem sume kvadrata funkcije pogreške  $E(e)$  prema izrazu (20), kombinacijski koeficijent  $\mu$  se množi odnosno dijeli s faktorom konstantnog iznosa (na primjer  $\beta$  u granicama  $[0, 1]$ ) dok samo povećanje ili smanjenje kombinacijskog koeficijenta  $\mu$  definira i promjenu LM algoritma prema BP algoritmu ili prema GN algoritmu (Matić, 2014). Tako za smanjenje kombinacijskog koeficijenta  $\mu$  LM algoritam postaje sve sličniji Gauss-Newton-ovom algoritmu, dok pri rastu parametra postaje sve sličniji algoritmu propagacije unatrag. Promjena LM algoritma ovisno o kombinacijskom koeficijentu  $\mu$  prikazana je na *Slici 44*.

$$E(e) = \sum_{k=1}^n (e_k)^2 \quad (20)$$

Gdje je:

$E(e)$  – Suma kvadrata funkcije pogreške

$e_k$  – Pogreška mreže višeslojnog perceptrona u  $k$  – tom koraku



Slika 44. Promjena LM algoritma s obzirom na promjenu kombinacijskog koeficijenta  $\mu$ ; prikaz izradila: Ivana Sušanjan prema Matić (2014)

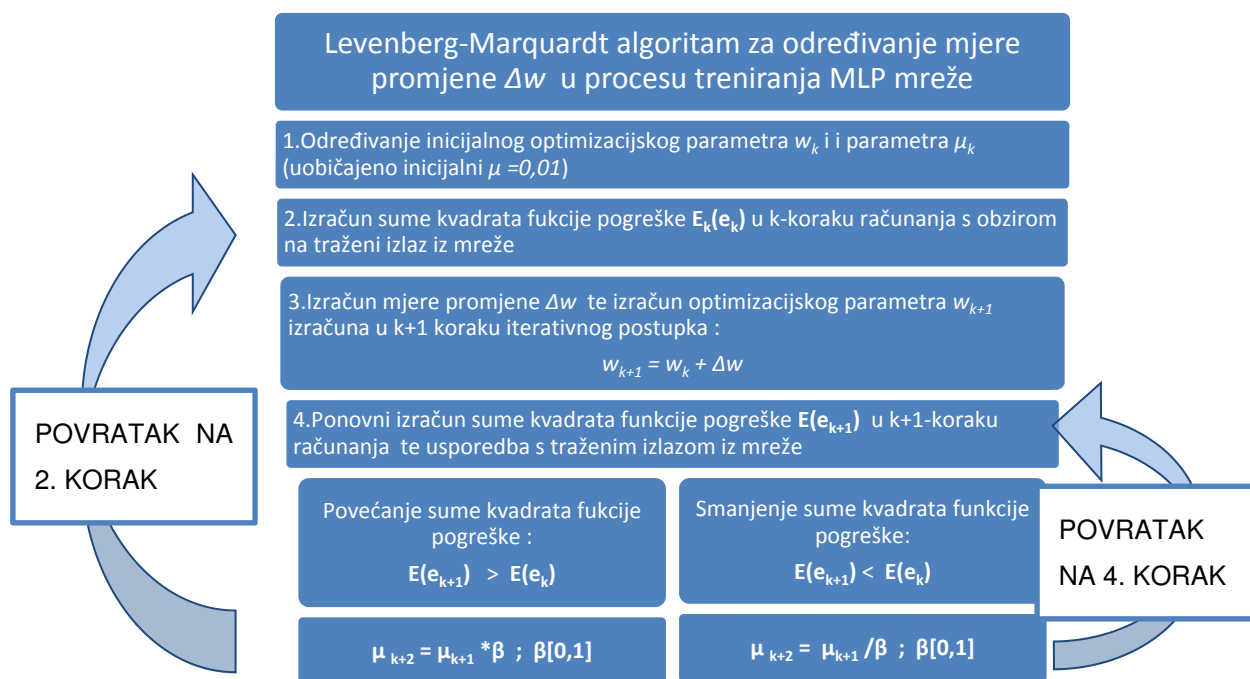
### 3.4. Programiranje višeslojnog perceptrona i Levenberg-Marquardt algoritma

Za razvoj modela potrebno je odabrati programski paket u kojem će se model izraditi. Danas je na raspolaganju veliki broj već pripremljenih programskih paketa koji imaju već unaprijed pripremljene arhitekture umjetne neuronske mreže i pridružene algoritme treniranja u kojima nije moguće imati uvid u cijeli proces modela te pojedine elemente nije moguće mijenjati. Ukoliko se želi imati uvid i kontrolu nad cijelim procesom rada umjetne neuronske mreže, moguće je koristiti programske pakete u sklopu kojih se programira cijeli model. Jedan od

programskih paketa koji imaju takvu mogućnost je MATLAB (MathWork) koji ima implementirane zasebne elemente umjetnih neuronskih mreža kao što su vrste i elementi arhitekture, algoritme treniranja, načine treniranja, validacije i evalvacije modela (Demuth i Beale, 2004). U procesu programiranja modela može se stoga definirati svaki element arhitekture zasebno te u potpunosti upravljati svim elementima modela.

Nakon što je pripremljen programski kod modela umjetne neuronske mreže u model se implementira skup podataka pripremljen za proces treniranja. U procesu treniranja dolazi do promjena optimizacijskog parametra pod utjecajem algoritma treniranja u više iteracija izračuna. Cilj procesa je optimalno treniranje modela u cilju izbjegavanja stanja pretreniranosti koji dovodi do gubitka generalizirajućih svojstava modela. Iako ne postoji jasno definiran način za izračun broja iteracija kroz koje model treba proći da bi bio optimalno treniran jedan od sigurnih načina je da zaustavljanje procesa treniranja nastupa u trenutku kada Suma kvadratne pogreške (SSE) odziva modela naspram mjerenih podataka računata prema izrazu (21) dosegne iznos prilikom kojeg ne dolazi do povećanja sume kvadratne pogreške odziva modela u procesu validacije. Po završetku procesa treniranja hidrološkog modela predviđanja otjecanja prelazi se na procese validacije i evalvacije modela (Demuth i Beale, 2004).

Za potrebe ovoga rada korišten je LM algoritam koji je uz pomoć programskog paketa MATLAB R2012b (MathWorks) implementiran u model. Proces treniranja samog LM algoritma može se ilustrativno prikazati kroz korake postupka prikazane na *Slici 45*.




Slika 45. Koraci postupka primjene LM algoritma u treniranju mreže višeslojnog perceptrona

### 3.5. Mjere kvalitete umjetne neuronske mreže

Za ispitivanje valjanosti modela u procesu validacije i evalvacije općenito se koriste grafičke i numeričke metode. Prema diskusiji koju su proveli Dawson i Wilby (2001) o mjerama kvalitete modela koji se koriste u hidrologiji, ocjena kvalitete modela vrlo je zahtjevna kao i usporedba modela. Najviše problema stvaraju nekonzistentnost korištenja mjera kvalitete, odnosno korištenje cijelog niza različitih mjera u različitim modelima. Također raznolikost slivova i njihovih obilježja, načina tečenja vode te koraka vremena koji se koristi u modelima onemogućuju njihovu usporedbu i korištenje jednakih mjera kvalitete modela.

Umjetna neuronska mreža ima svojstvo univerzalnog aproksimatora što znači da umjetna neuronska mreža ima sposobnost aproksimirati bilo kakvo preslikavanje ulaznih podataka u izlaznu vrijednost s relativnom točnošću. Iako imaju tu sposobnost to ne znači da su u stanju dati točne odzive za vrijednost koja im nije predstavljena u procesu treniranja. Upravo zbog toga potrebno je, prije nego se jedna ovakva mreža prihvati kao model jednog sustava, ispitati njena generalizacijska svojstva. Model umjetne neuronske mreže mora proći kroz proces validacije i evalvacije, a u tu svrhu koriste se grafičke metode koje se svode na vizualnu usporedbu odziva modela te mjerenih podataka te niz različitih

numeričkih mjera kvalitete. Numeričke mjere kvalitete modela se općenito mogu podijeliti na apsolutne i relativne mjere (Slika 46.) čije će značenje te način izračuna biti objašnjen u nastavku rada. Valja napomenuti da će, s obzirom da postoji veliki broj mjera kvalitete modela, u sklopu ove disertacije bit objašnjene najčešće korištene mjere za ocjenu modela u području hidrotehnike.



Slika 46. Podjela numeričkih mjera kvalitete modela; prikaz izradila: Ivana Sušanjanj prema Abrahart i sur. (2004); Matić, (2014); Govindaraju i Ramachandra Rao (2000)

### 3.5.1. Apsolutne mjere kvalitete modela

Apsolutne mjere kvalitete modela smatraju se one koje u jedinici analiziranih podataka daju mjeru kvalitete modela (Abrahart i sur., 2004; Matić, 2014; Govindaraju i Ramachandra Rao 2000). U njih spadaju: Suma kvadratne pogreške (SSE), Srednja kvadratna pogreška (MSE), Srednja pogreška četvrtog reda (MS4E), Korijen srednje kvadratne pogreške (RMSE) i Srednja apsolutna pogreška (MAE) kao što je prikazano na *Slici 46.*, a koje će biti u nastavku opisane.

#### Suma kvadratne pogreške (eng. Sum Squared Error, SSE)

Najčešće općenito korištena mjera kvalitete je Suma kvadratne pogreške koja je definirana sljedećim izrazom (21).

$$SSE = \sum_{k=1}^n (d_k - o_k)^2 \quad (21)$$

Gdje je:

$SSE$  – Suma kvadratne pogreške

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

Suma kvadratne pogreške mjeri ukupno odstupanje odziva modela u odnosu na mjerene podatke sumirajući pogreške za cijeli skup podataka. Nedostatak ovakve mjere je što ne ukazuje na područje rasprostranjenosti pogreške, odnosno da li je točnost modela veća pri minimalnim vrijednostima odziva modela ili pri maksimalnim vrijednostima. Cilj je pri modeliranju sustava umjetnom neuronskom mrežom naravno da ova mjera bude čim manja (Matić, 2014; Abrahart i sur., 2004).

Zbog nedostataka ove mjere potrebno je uz nju koristiti i druge mjere koje će nam dati detaljniji uvid u točnost modela.

#### Srednja kvadratna pogreška (eng. Mean Squared Error, MSE)

Jedna od često korištenih mjera kvalitete, koja daje uvid u prosječno odstupanje od željenog odziva mreže je Srednja kvadratna pogreška koja je definirana izrazom (22). Ova mjera ima jednake nedostatke kao i Suma kvadratne pogreške (Abrahart i sur., 2004).



$$MSE = \frac{1}{n} \sum_{k=1}^n (d_k - o_k)^2 \quad (22)$$

Gdje je:

$MSE$  – Srednja kvadratna pogreška

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

Kako i ova mjera daje prikaz odstupanja od željenog odziva mreže, cilj je također da i ona bude što manja, što ukazuje na točnost modela.

S aspekta ocjenjivanja hidroloških modela ova mjera kvalitete prema Karunanithi i sur. (1994) daje dobru ocjenu prilagodbe modela pri velikim protocima, no autori također napominju da ova mjera ovisi i o režimu tečenja zbog čega se ova mjera ne smije smatrati definitivnom mjerom kvalitete.

#### Srednja pogreška četvrtog reda (eng. Mean Higher-order Error, MS4E)

Po uzoru na često korištenu mjeru kvalitete srednju kvadratnu pogrešku, Abarhart i See (2000) su razvili Srednju pogrešku četvrtog reda koja za razliku od Srednje kvadratne pogreške daje veći naglasak na pogreške maksimuma odnosno u hidrologiji na maksimalne protoke. Srednja pogreška četvrtog reda je definirana izrazom (23). Kao i kod prethodno navedenih mjera kvalitete i kod ove je poželjan što manji izračunati iznos.

$$MS4E = \frac{1}{n} \sum_{k=1}^n (d_k - o_k)^4 \quad (23)$$

Gdje je:

$MS4E$  – Srednja pogreška četvrtog reda

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

#### Korijen Srednje kvadratne pogreške (eng. Root Mean Squared Error, RMSE)

Korijen srednje kvadratne pogreške je također mjera koja daje općenitu točnost modela no razlika u odnosu na Sumu kvadratne pogreške (SSE) i srednju kvadratnu pogrešku (MSE) je u tome što je pogreška prikazana u istoj mjernoj jedinici koja je korištena u modelu. Korijen srednje kvadratne pogreške definiran je izrazom (24) (Abrahart i sur., 2004).

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (d_k - o_k)^2} \quad (24)$$

Gdje je:

$RMSE$  – Korijen srednje kvadratne pogreške

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

### Srednja apsolutna pogreška (eng. Mean Absolute Error, MAE)

Srednja apsolutna pogreška definirana je izrazom (25) koja daje mjeru devijacije naspram ulaznih podataka no također ne daje ocjenu modela primjerice u hidrologiji pri velikim protokama (Abrahart i sur., 2004).

$$MAE = \frac{1}{n} \sum_{k=1}^n |d_k - o_k| \quad (25)$$

Gdje je:

$MAE$  – Srednja apsolutna pogreška

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

### **3.5.2. Relativne mjere kvalitete**

S ciljem postavke općih uvjeta za ocjenu kvalitete modela koriste se relativne mjere kvalitete, pri čemu su izrazito zastupljene one mjere koje se temelje na korelaciji (Abrahart i sur., 2004; Matić, 2014; Govindaraju i Ramachandra Rao 2000). S obzirom da su temeljene na korelaciji kao rezultat upotrebe takvih mjera dobivaju se koeficijenti koji nemaju definiranu jedinicu mjere. U ove mjere spadaju: Srednja kvadratna relativna pogreška (MSRE), Koeficijent određenosti ( $r^2$ ), Koeficijent učinkovitosti (CE), Indeks podudarnosti (d), Indeks dosljednosti (PI), PBIAS te Omjer srednje kvadratne pogreške i Standardne devijacije (RSR) kao što je prikazano na *Slici 46.*, a u nastavku će nabrojene mjere biti detaljnije opisane.

### Srednja kvadratna relativna pogreška (eng. Mean Squared Relative Error, MSRE)

Srednja kvadratna relativna pogreška je mjera kvalitete koja je definirana izrazom (26), a služi ocjenjivanju relativne točnosti modela. Prema mišljenju

Karunanithi i sur. (1994) ova mjera kvalitete daje uvid u kvalitetu prilagodbe modela, u hidrologiji primjerice pri srednjim protocima (Abrahart i sur., 2004).

$$MSRE = \frac{1}{n} \sum_{k=1}^n \left( \frac{d_k - o_k}{d_k} \right)^2 \quad (26)$$

Gdje je:

$MSRE$  – Srednja kvadratna relativna pogreška

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

### Koeficijent određenosti (eng. Coefficient of determination, $r^2$ )

U hidrološkim modelima, odnosno pri ocjenjivanju modela temeljenih na umjetnoj neuronskoj mreži, najčešće se predlaže korištenje Koeficijenta određenosti koji predstavlja mjeru kvalitete prilagodbe modela mjerenim podacima, a definiran je izrazom (27) (Abrahart i sur., 2004).

$$r^2 = \frac{[\sum_{k=1}^n (d_k - \bar{d}) \cdot (o_k - \bar{o})]^2}{[\sum_{k=1}^n (d_k - \bar{d})^2] \cdot [\sum_{k=1}^n (o_k - \bar{o})^2]} \quad (27)$$

Gdje je:

$r^2$  – Koeficijent određenosti

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$\bar{d}$  – Srednja vrijednost željenog odziva mreže

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

$\bar{o}$  – Srednja vrijednost odziva neurona mreže

Vrijednosti koeficijenta određenosti predstavlja mjeru linearne korelacije između mjerenih vrijednosti te odziva modela, a kreće se od 0 do 1. Minimalna vrijednost koeficijenta 0 ukazuje na nepostojanje linearne povezanosti podataka dok iznos 1 upućuje na potpuno definiranu linearnu vezu među podacima (Žugaj, 2000).

### Koeficijent učinkovitosti (eng. Coefficient of Efficiency, CE)

Osim Koeficijenta određenosti u hidrologiji se predlaže korištenje Koeficijenta učinkovitosti koji je još poznat i pod nazivom Nash-Sutcliffe koeficijent, koji se također temelji na korelaciji. Ova mjera kvalitete pokazala se kao prikladnija metoda za procjenu kvalitete prilagodbe od Koeficijenta određenosti zbog procjene mogućnosti modela da prikaže predviđanje primjerice protoka vode koji je različit od srednjeg protoka. Ova mjera ima mogućnost izbjeći proporcionalne pogreške

koje koeficijent određenosti ne prepoznaje (Legates i McCabe, 1999). Koeficijent učinkovitosti definiran je izrazom (28).

$$CE = 1 - \frac{\sum_{k=1}^n (d_k - o_k)^2}{\sum_{k=1}^n (d_k - \bar{d})^2} \quad (28)$$

Gdje je:

$CE$  – Koeficijent učinkovitosti

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

$\bar{d}$  – Srednja vrijednost željenog odziva mreže

Vrijednost ovoga koeficijenta se kreće u vrijednostima od  $-\infty$  u najgorem do 1 u najboljem slučaju, te je bitno napomenuti da su ova mjera i koeficijent određenosti vrlo osjetljivi na maksimume modela odnosno u hidrološkim modelima; visoke protoke (Matić, 2014).

#### Indeks podudarnosti (eng. Index of Agreement, $d$ )

Indeks podudarnosti je jedna od mjera kvalitete s kojom su Legates i McCabe (1999) pokušali zaobići osjetljivost mjera kvalitete na maksimume, odnosno u hidrologiji na primjerice velike protoke. Indeks podudarnosti je definiran izrazom (29).

$$d = 1 - \frac{\sum_{k=1}^n (d_k - o_k)^2}{\sum_{k=1}^n (d_k - \bar{d})^2 \cdot (o_k - \bar{d})^2} \quad (29)$$

Gdje je:

$d$  – Indeks podudarnosti

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$\bar{d}$  – Srednja vrijednost željenog odziva mreže

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

#### Indeks dosljednosti (eng. Persistence indeks, $PI$ )

Indeks dosljednosti spada u bezdimenzionalne, relativne mjere kvalitete, a njegove granice vrijednosti idu od  $-\infty$  do 1, pri čemu se u radu Gupta i sur. (1999) vrijednost od 0 do 1 smatra zadovoljavajućom, a definiran je izrazom (30).

$$PI = 1 - \frac{\sum_{k=1}^n (d_k - o_k)^2}{\sum_{k=1}^n (d_k - d_{k-1})^2} \quad (30)$$

Gdje je:

$PI$  – Indeks dosljednosti

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$d_{k-1}$  – Željeni odziv mreže u  $k - 1$  – koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

Uz gore spomenute relativne mjere kvalitete modela valja napomenuti da se još koriste modifikirani Koeficijent učinkovitosti ( $CE_b$ ) i Indeks kompatibilnosti ( $db$ ). Među bezdimenzionalnim mjerama kvalitete moguće je kao mjeru kvalitete koristiti PBIAS (*engl. Percent bias*) te RSR (*engl. RMSE to standard deviation ratio*) (Matić, 2014).

#### Postotno odstupanje (PBIAS)

PBIAS mjeri prosječnu sklonost modela ka predviđanju vrijednosti koje su veće ili manje od mjerenih podataka, a definiran je izrazom (31). U idealnom slučaju vrijednost ovog kriterija je jednaka 0% dok se odstupanje  $\pm 10\%$  smatra vrlo dobrom kvalitetom predviđanja (Matić, 2014). Negativna vrijednost ovog kriterija upućuje na podbačaj modela dok pozitivne vrijednosti upućuju na prebačaj predviđanja modela s obzirom na mjerene podatke.

$$PBIAS = \frac{\sum_{k=1}^n (d_k - o_k)}{\sum_{k=1}^n (d_k)} \cdot 100\% \quad (31)$$

Gdje je:

$PBIAS$  – Postotno odstupanje

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

#### Omjer Srednje kvadratne pogreške i standardne devijacije (eng. RMSE to standard deviation, RSR)

Kriterij RSR daje omjer između Korijena srednje kvadratne pogreške (RMSE) i Standardne devijacije ( $\sigma$ ) čija je optimalna vrijednost bliska nuli što bi značilo da je poželjno da Srednja kvadratna pogreška bude daleko manja od iznosa Standardne devijacije, a definiran je izrazom (32) (Matić, 2014).

$$RSR = \frac{RMSE}{\sigma} = \sqrt{\frac{\sum_{k=1}^n (d_k - o_k)^2}{\sum_{k=1}^n (d_k - \bar{d})^2}} \quad (32)$$

Gdje je:

$RSR$  – Omjer Srednje kvadratne pogreške i standardne devijacije

$\sigma$  – Standardna devijacija željenog odziva mreže

$d_k$  – Željeni odziv mreže u  $k$  – tom koraku računanja

$o_k$  – Odziv neurona mreže u  $k$  – tom koraku računanja

$\bar{d}$  – Srednja vrijednost željenog odziva mreže

### 3.5.3. Odabir mjera kvalitete te granice mjera kvalitete za ocjenu modela umjetne neuronske mreže

Prilikom odabira skupa mjera za ocjenjivanje kvalitete modela vlada suglasje u smislu preporuke korištenja više mjera za ocjenu modela, no dodatni problem u odabiru mjera kvalitete stvaraju nedefinirane granice ocijene modela. Kod većine mjera za kvalitetu modela nisu definirane egzaktno granice iznosa izračunate mjere prema kojem je moguće ocjeniti razinu kvalitete modela, pa se ona često temelji na procjeni autora modela. U radu Morisai i sur. (2007) prikazuju najpreciznije granice za mjere: CE, RSR i PBIAS za primjenu u hidrološkim modelima kao što je prikazano u *Tablici 6.* kao i granice kriterija kojima model treba težiti. Ove gore spomenute mjere kao i njihove granice su uz mjere MSE, RMSE, MAE, MSRE,  $d$  i RSR korištene i u disertaciji koju je izradio Matić (2014) prilikom ocjenjivanja kvalitete predviđanja modela.

*Tablica 6. Mjere kvalitete modela te njihove granice za ocjenu kvalitete; Izradila: Ivana Sušanjan prema Morisai i sur. (2007), Matić (2014) i Žugaj (2000)*

KVALITETA PREDVIĐANJA	MSE, RMSE, MAE, MSRE, $d$ , RSR	CE	$r^2$	PBIAS
<b>Granice</b>	Nije moguće postaviti granice za ocjenu razine kvalitete modela. POŽELJNI SU REZULTATI ŠTO MANJIH VRIJEDNOSTI	<b>&lt; -∞, +1]</b>	<b>[-1,+1]</b>	<b>[0%, ±100%]</b>
<b>Vrlo dobro</b>		<0.75, 1.00]	<0.75, 1.00]	<±10%
<b>Dobro</b>		<0.65, 0.75]	<0.50, 0.75]	[±10%, ±15%>
<b>Dovoljno</b>		<0.5, 0.65]		[±15%, ±25%>
<b>Nedovoljno</b>		≤0.5	<  0.5	≥ ±25%

S obzirom na postojanje velikog broja mjera kvalitete za potrebe disertacije će se u procesu validacije i evalvacije primijeniti vizualna usporedba odziva modela i mjerenih podataka te numeričke mjere kvalitete koje su prikazane u *Tablici 7.*

Tablica 7. Odabrane numeričke mjere kvalitete modela za proces validacije i evalvacije modela

VALIDACIJA MODELA	EVALVACIJA MODELA
<ul style="list-style-type: none"> <li>• Srednja kvadratna pogreška (MSE)</li> <li>• Koeficijent određenosti (<math>r^2</math>)</li> </ul>	<ul style="list-style-type: none"> <li>• Srednja kvadratna pogreška (MSE)</li> <li>• Korijen srednje kvadratne pogreške (RMSE)</li> <li>• Srednja apsolutna pogreška (MAE)</li> <li>• Srednja kvadratna relativna pogreška (MSRE)</li> <li>• Koeficijent određenosti (<math>r^2</math>)</li> <li>• Koeficijent učinkovitosti (CE)</li> <li>• Indeks podudarnosti (d)</li> <li>• Postotno odstupanje (PBIAS)</li> <li>• Omjer srednje kvadratne pogreške i standardne devijacije (RSR)</li> </ul>



## **4. HIDROLOŠKI MODEL PREDVIĐANJA OTJECANJA S MALIH SLIVOVA TEMELJEN NA UMJETNOJ NEURONSKOJ MREŽI**

### **4.1. Razvoj hidrološkog modela predviđanja otjecanja sa sliva Slanog potoka temeljen na umjetnoj neuronskoj mreži**

Hidrološki model predviđanja otjecanja, temeljen na umjetnoj neuronskoj mreži, razvijen je za potrebe predviđanja otjecanja na slivu Slanog potoka koji svojim obilježjima spada u mali sliv bujičnog karaktera te na kojem je zbog štetnih pojava potrebno implementirati sustav ranog uzbunjivanja. Cilj modela je da na temelju ulaznih meteoroloških mjerenih varijabli daje predviđanje kretanja razine vode u vodotoku za zadani vremenski korak predviđanja. Kako je model razvijen za mali sliv na kojemu se ne mogu očekivati dugoročna predviđanja, cilj je razviti model koji će imati dovoljne mogućnosti predviđanja kako bi bilo moguće implementirati sustav ranog uzbunjivanja za istražno područje. Vremenska razlučivost modela je  $\Delta t = 2 \text{ minute}$ , a definirana je vremenskim korakom mjerenja hidroloških i meteoroloških podataka. Za potrebe predviđanja razvijen je model koji je ispitan na tri vremenska koraka: (i) M15 s korakom predviđanja od  $\Delta t = 30 \text{ minuta}$ , (ii) M30 s vremenskim korakom predviđanja od  $\Delta t = 60 \text{ minuta}$  i (iii) M60 s vremenskim korakom predviđanja od  $\Delta t = 120 \text{ minuta}$ , prilikom čega broj koraka predviđanja prema vremenskoj razlučivosti modela daje dvostruko vremensko predviđanje. U nastavku rada bit će opisan način odabira i obrade ulaznih i izlaznih varijabli hidrološkog modela otjecanja te arhitektura modela.

#### ***4.1.1. Odabir i obrada ulaznih varijabli hidrološkog modela predviđanja otjecanja***

Mjerenja meteoroloških varijabli na istražnom području sliva Slanog potoka započinju, kao što je već opisano, 2012. godine te se od tada provode kontinuirano. Meteorološki podaci se prate na obje postavljene postaje, a usporedbom mjerenja utvrđena je jednolika prostorna raspodjela meteoroloških podataka. Zbog toga se u analizi za potrebe disertacije koriste podaci s meteorološke postaje postavljene kod mjesnog groblja u Belgradu. Mjerenja su pokazala da su 2012. i 2013. bile sušne godine u kojima nisu zabilježene količinski značajnije oborine dok je 2014. godina okarakterizirana kao vodna godina. Zbog hidrološki značajnije 2014. godine za razvoj modela koristi se upravo ta godina u

kojoj je zabilježeno više značajnih oborinskih epizoda i intenziteta oborina. Meteorološki podaci koji su određeni kao ulazne varijable modela su: (i) Količina oborine, (ii) Intenzitet oborine, (iii) Temperatura zraka, (iv) Vlaga zraka, (v) Tlak zraka i (vi) Insolacija, a odabrani su zbog njihovog direktnog utjecaja na uvjete otjecanja sa sliva.


Mjereni podaci su prethodno obrađeni te analizirani kako bi se pronašle moguće sustavne ili slučajne pogreške pa je zbog toga za razvoj modela odabran kontinuirani period od 2. travnja do 3. prosinca 2014 godine. Korak mjerenja meteoroloških podataka je  $\Delta t = 2 \text{ minute}$  te uslijed tako malog koraka mjerenja podaci sadržavaju takozvani „šum“ (*eng. Noise*) odnosno smetnje u mjerenju. Šum u mjerenim podacima može dodatno opteretiti izračune u modelu pa su smetnje otklonjene lokalnom nelinearnom regresijom (*eng. Loess method*) za zadane intervale od 10 podataka.

Na pripremljenim podacima koji čine ulazne podatke, odnosno ulazni sloj u modelu umjetne neuronske mreže, provedena je osnovna statistička obrada podataka koje čini 132781 mjerena meteorološka varijabla. Osnovne statističke parametre čine: (i) Maksimum, (ii) Minimum, (iii) Srednja vrijednost te (iv) Standardna devijacija čiji su rezultati prikazani u *Tablici 8*. Osnovna statistička obrada ulaznih varijabli meteoroloških mjerenja ukazuje na dostatnu raznolikost i raspon podataka, što je od velike važnosti za kvalitetu modela.


*Tablica 8. Statistička obrada meteoroloških varijabli koje čine ulazne varijable modela*

Ulazni sloj podataka						
Statistički parametri*	Količina oborina	Intenzitet oborina	Temperatura zraka	Vlaga zraka	Tlak zraka	Insolacija
	$P$	$i$	$T$	$u$	$p$	$I$
	[mm]	[mm/h]	[°C]	[%]	[mmHg]	[W/m <sup>2</sup> ]
<b><math>n</math></b>	132781	132781	132781	132781	132781	132781
<b><math>Max.</math></b>	10,11	303,20	33,30	96,00	773,00	1092
<b><math>Min.</math></b>	0,00	0,00	5,80	32,00	750,20	0
<b><math>\bar{x}</math></b>	0,01	0,24	16,83	69,95	762,16	111,06
<b><math>\sigma</math></b>	0,12	3,54	5,02	14,27	3,81	208,43
* $n$ = Broj mjerenih podataka; <b><math>Max.</math></b> = maksimum; <b><math>Min.</math></b> = minimum; $\bar{x}$ = Srednja vrijednost; $\sigma$ = standardna devijacija.						

Ulazna varijabla količine oborine mjerena je u milimetrima (mm). Ukupna količina oborine u promatranom periodu (2. travanj - 3. prosinc 2014) iznosi  $P = 1047,5 \text{ mm}$  oborine, a maksimalna količina oborine zabilježena u periodu ulaznih podataka je  $P = 10,11 \text{ mm}$  u 2 minute mjerenja. U periodu mjerenja zabilježeno je više desetaka oborinskih epizoda, a na *Slici 47.* prikazane su kumulativne oborine dok su na *Slici 48.* prikazana pojedinačna mjerenja.




*Slika 47. Prikaz mjerenja kumulativne količine oborina za meteorološku postaju Belgrad*



*Slika 48. Prikaz mjerenja količine oborina u dvominutnom koraku vremena za meteorološku postaju Belgrad*


Intenzitet oborine na slivu Slanog potoka ukazuje na oborinske epizode izrazito velikog intenziteta. U promatranom periodu (2. travanj - 3. prosinc 2014)

zabilježeni maksimum iznosi  $i = 303,20 \text{ mm/h}$  dok je za većinu oborinskih epizoda intenzitet veći od  $i = 50 \text{ mm/h}$ . Na *Slici 49.* prikazani su zabilježeni intenziteti oborina u promatranom razdoblju.




*Slika 49. Prikaz mjerenja intenziteta oborina u dvominutnom koraku vremena za meteorološku postaju Belgrad*

Temperatura zraka utječe na razinu evaporacije i općenito evapotranspiracije na slivu. U tom smislu temperatura zraka utječe i na uvjete otjecanja sa sliva te je stoga i ova varijabla uvrštena u model. Temperatura zraka se u promatranom razdoblju (2. travanj - 3. prosinac 2014) kreće od  $T = 5,80 \text{ }^\circ\text{C}$  do  $T = 33,30 \text{ }^\circ\text{C}$ . Mjerenja temperature zraka prikazana su na *Slici 50.*




*Slika 50. Prikaz mjerenja temperature zraka u dvominutnom koraku vremena za meteorološku postaju Belgrad*

Vlažnost zraka kao meteorološka varijabla vezana je za razinu evaporacije na slivu i upućuje na pojavu oborinske epizode. Kao takva čini značajnu varijablu koja je implementirana u model. Vlažnost zraka se u promatranom razdoblju mjerenja (2. travanj - 3. prosinac 2014) kreće od  $u = 32\%$  do  $u = 96\%$ , a srednja vlažnost zraka iznosi  $u = 69\%$ . Mjereni podaci su prikazani na *Slici 51*.




*Slika 51. Prikaz mjerenja vlažnosti zraka u dvominutnom koraku vremena za meteorološku postaju Belgrad*

Tlak zraka kao meteorološka varijabla upućuje na nastupanje ciklone (područje sniženog tlaka zraka) ili anticiklone (područje povišenog tlaka zraka). Do pada tlaka zraka dolazi prije nastupanja oborinske epizode pa je za potrebe predviđanja, za razvoj hidrološkog modela otjecanja, ova varijabla od velike važnosti. Granica između ciklone i anticiklone je određena tlakom zraka od  $p = 760 \text{ mmHg}$ . Na promatranom periodu mjerenja (2. travanj - 3. prosinac 2014) zabilježen je maksimalni tlak zraka od  $p = 773,00 \text{ mmHg}$  dok je minimalni zabilježeni tlak iznosio  $p = 750,20 \text{ mmHg}$ . Srednji tlak zraka u promatranom periodu iznosio je  $p = 762,16 \text{ mmHg}$ . Na *Slici 52*. prikazani su mjereni podaci vlažnosti zraka u promatranom periodu.



Slika 52. Prikaz mjerenja tlaka zraka u dvominutnom koraku vremena za meteorološku postaju Belgrad

Utjecaj sunčane radijacije odnosno insolacije na otjecanje sa sliva je vidljivo u obliku pojačane evaporacije s površine sliva. Tokom noći utjecaja sunčane radijacije nema te je ona jednaka  $I = 0 \text{ W/m}^2$ . Pri nadolasku naoblake insolacija se izrazito smanjuje stoga ova varijabla kao i tlak zraka upućuju na nastupanje oborinske epizode na slivu. Na promatranom periodu mjerenja (2. travanj - 3. prosinac 2014) maksimalna zabilježena insolacija iznosi  $I = 1092,00 \text{ W/m}^2$ . Na Slici 53. prikazani su mjereni podaci sunčane radijacije u promatranom periodu.



Slika 53. Prikaz mjerenja sunčane radijacije (insolacija) u dvominutnom koraku vremena za meteorološku postaju Belgrad

#### 4.1.2. Odabir i obrada izlaznih varijabli hidrološkog modela predviđanja otjecanja

Mjerenja hidrološke varijable razine vode u profilu vodotoka na istražnom području sliva Slanog potoka traju od od 2012. godine te i do danas provode se kontinuirano.

Mjereni hidrološki podaci su pročišćeni te analizirani kako bi se pronašle moguće sustavne ili slučajne pogreške na isti način kao što je učinjeno i s meteorološkim podacima.

Na pripremljenim podacima koji će činiti izlazni podatak, odnosno izlazni sloj u modelu umjetne neuronske mreže, provedena je osnovna statistička obrada podataka koje čini 132781 mjerenja hidrološke varijable razine vode (H) s vremeskim korakom mjerenja  $\Delta t = 2 \text{ minute}$ . Osnovnu statističku obradu podataka čine: (i) Maksimum, (ii) Minimum, (iii) Srednja vrijednost te (iv) Standardna devijacija, a čiji su rezultati prikazani u *Tablici 9*. Osnovna statistička obrada izlaznih varijabli meteoroloških mjerenja ukazuje na dostatnu raznolikost i raspon podataka, a što je od velike važnosti za kvalitetu modela.

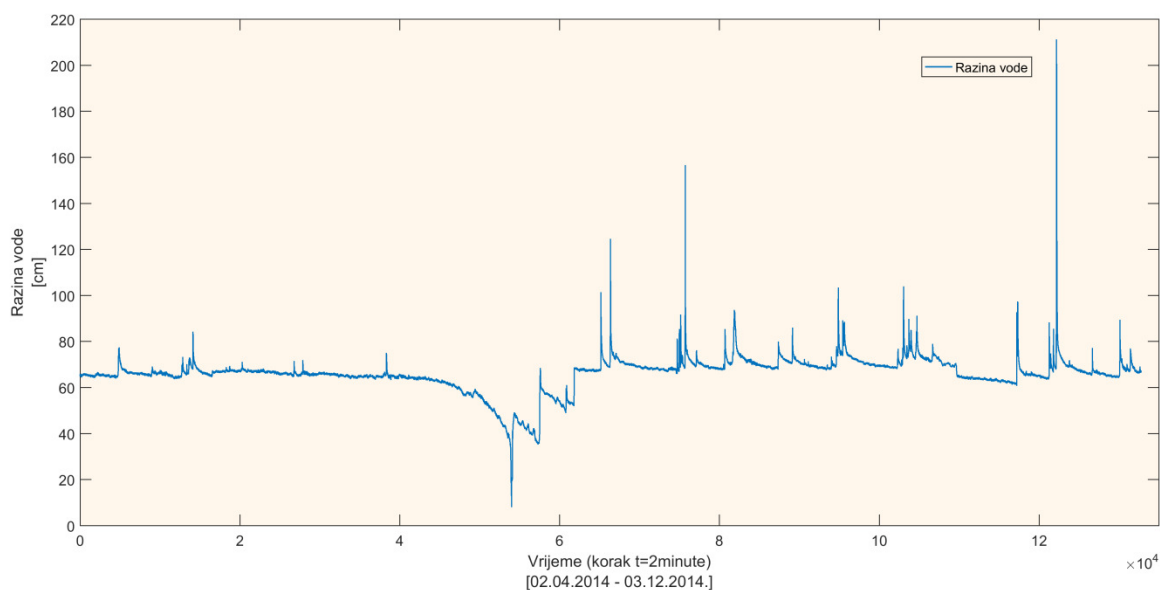
Tablica 9. Statistička obrada hidrološke varijable koja čini izlaznu varijablu modela

Izlazni sloj podataka	
Statistički parametri*	Razina vode
	H
	[cm]
<b><i>n</i></b>	132781
<b><i>Max.</i></b>	211,20
<b><i>Min.</i></b>	8,10
$\bar{x}$	66,11
$\sigma$	7,43
* <b><i>n</i></b> = Broj mjerenih podataka; <b><i>Max.</i></b> = maksimum; <b><i>Min.</i></b> = minimum; $\bar{x}$ = Srednja vrijednost; $\sigma$ = standardna devijacija.	

Cilj modela je predviđanje razine vode u određenom koraku vremena, a kako bi se provelo treniranje, validacija i evalvacija modela od velike je važnosti mjerenjima obuhvatiti što više vodnih valova na istražnom području. Uvjeti na



istražnom slivu su promjenjivi u vremenu odnosno otjecanje uvelike ovisi o razini evaporacije, saturiranosti tla i transpiraciji biljaka koja je u proljetnom periodu izražena zbog bujanja vegetacije. U promatranom periodu mjerenja (2. travanj - 3. prosinac 2014) je tako zabilježena najveća razina vode od  $H = 211,2 \text{ cm}$ , minimalna svega  $H = 8,1 \text{ cm}$ , te preko deset vodnih valova kod kojih je zabilježena razina vode preko  $H = 80 \text{ cm}$  što se za promatrani sliv Slanog potoka smatra značajnim otjecanjem sa sliva. Na *Slici 54*. prikazana su mjerenja u promatranom periodu.



*Slika 54. Prikaz mjerenja razine vode u dvominutnom koraku vremena za meteorološku postaju Belgrad*

#### **4.1.3. Arhitektura hidrološkog modela predviđanja otjecanja: Aktivacijske funkcije, skriveni sloj, podjela podataka i broj iteracija**

Za razvoj modela korišten je programski paket MATLAB R2012b (Mathworks) uz pomoć kojeg je definirana arhitektura modela višeslojnog perceptrona. Model se sastoji od tri sloja: (i) Ulazni sloj, (ii) Skriveni sloj i (iii) Izlazni sloj. Vremenska razlučivost modela je definirana korakom mjerenja podataka te iznosi  $\Delta t = 2 \text{ minute}$ .


Ulazni sloj se sastoji od meteoroloških podataka: (i) Količine oborine, (ii) Intenziteta oborine, (iii) Temperature zraka, (iv) Vlaga zraka, (v) Tlaka zraka i (vi) Insolacije u trenutku  $t=0$  te deset prethodnih podataka ( $\Delta t = 2 \text{ minute}$ ). Uvođenjem prethodnih meteoroloških podataka u ulaznom sloju omogućava se modelu uvid u meteorološko uvjete sliva u posljednjih  $\Delta t = 20 \text{ minuta}$ , odnosno

drugim riječima stvara se njegovo „pamćenje“. Ulazni sloj podataka stoga čini matrica podataka ranga  $132781 \times 60$  čiji će broj redaka u modelu ovisiti o koraku predviđanja te raspodjeli podataka u svrhu treniranja, validacije i evalvacije.

Skriveni sloj modela čini 10 neurona, a koji će zasebno, zaprimiti svaki ulazni podatak pomnožen s optimizacijskim parametrom  $w_{k+1}$  za iteraciju  $k+1$  dobivenim putem Levenberg-Marquardt -ovog algoritma. Kroz neuron podatak se kreće putem bipolarne sigmodialne aktivacijske funkcije, dok se podatak prema izlaznom sloju, odnosno odzivu modela, kreće putem linearne funkcije.

Izlazni sloj modela čine razine vode u vodotoku, a s obzirom na korak predviđanja, u koraku  $t=30$  minuta,  $t=60$  minuta i  $t=120$  minuta.

Shematski prikaz arhitekture modela prikazan je na Slici 55.




Slika 55. Shematski prikaz arhitekture modela umjetne neuronske mreže ( $x_{1,2,3,\dots,m}$ -ulazni podaci u neuron,  $w_{1,2,3,\dots,m}$ - vrijednost optimizacijskog parametra,  $v_k$ - suma umnožaka ulaznih podataka i optimizacijskog parametra u  $k$ -tom koraku računanja,  $o_k$  – odaziv neurona u  $k$ -tom koraku računanja,  $d_k$  –mjereni podaci)

Podaci su podijeljeni u tri zasebna skupa koje čine podaci za treniranje odnosno učenje modela, podaci za validaciju i podaci za evalvaciju modela. Podaci su podijeljeni u omjeru 70% za treniranje modela, 15% za validaciju modela i 15% za evalvaciju modela.

S obzirom na osnovni ustroj modela te korake predviđanja razvijena su tri modela: (i) M15 s korakom predviđanja od  $t=30$  minuta, (ii) M30 s korakom predviđanja od  $t=60$  minuta i (ii) M60 s korakom predviđanja od  $t=120$  minuta. Modeli se razlikuju po rangu ulazne i izlazne matrice te koraku predviđanja zbog

kojeg dolazi uslijed vremenskog pomaka u podacima. Na *Slici 56.* prikazana je arhitektura modela.



Slika 56. Arhitektura modela; a) Model M15 predviđanja 30 minuta, b) Model M30 predviđanja 60 minuta, c) Model M60 predviđanja 120 minuta ( $x_{1,2,3,\dots,m}$ -ulazni podaci u neuron,  $w_{1,2,3,\dots,m}$ - vrijednost optimizacijskog parametra,  $v_k$ - suma umnožaka ulaznih podataka i optimizacijskog parametra u  $k$ -tom koraku računanja,  $o_k$  – odaziv neurona u  $k$ -tom koraku računanja,  $d_k$  –mjereni podaci)

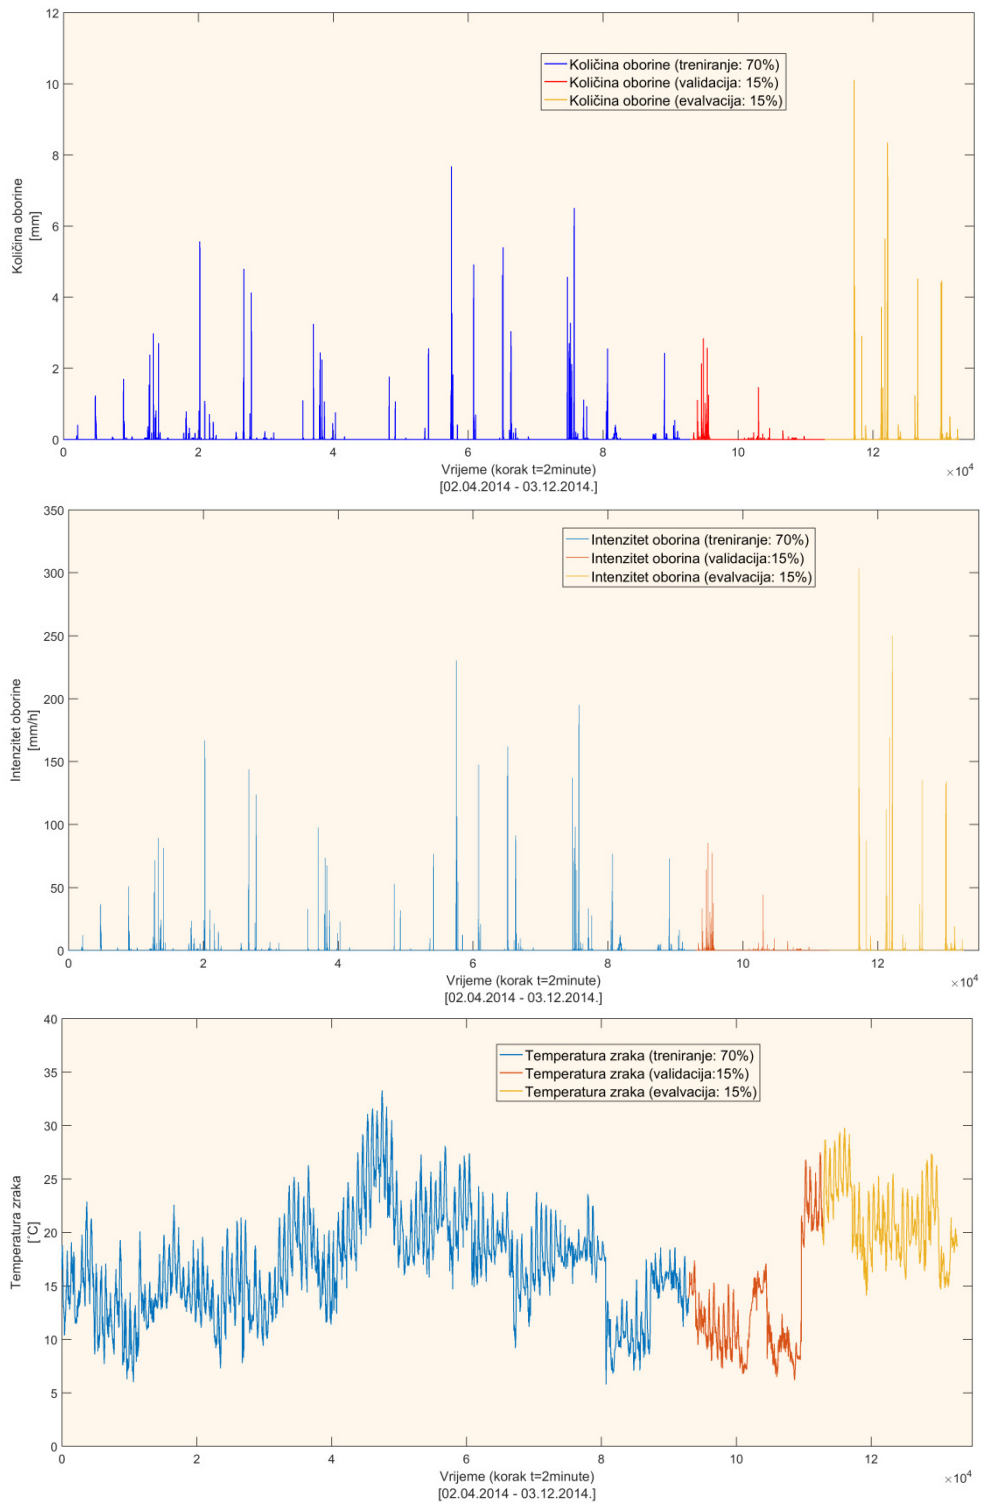
Kao što je već i ranije opisano, podaci su podjeljeni u tri skupa u svrhu treniranja (70% podataka), validacije (15% podataka) i evalvacije (15% podataka)

a s obzirom na korak predviđanja. U *Tablici 10*. Prikazana je podjela podataka za svaki model.


*Tablica 10. Podjela podataka za proces treniranja, validacije i evalvacije za modele*

Model	Korak predviđanja	PODJELA PODATAKA			UKUPNO PODATAKA
	[minuta]	TRENIRANJE	VALIDACIJA	EVALVACIJA	
<b>M15</b>	30	92928	19914	19914	132756
<b>M30</b>	60	92919	19911	19911	132741
<b>M60</b>	120	92897	19907	19907	132711


Primjer podjele ulaznih podataka za proces treniranja, validacije i evalvacije modela umjetne neuronske mreže za model M15 prikazana na *Slici 57*. i *Slici 58*. dok je na *Slici 59*. prikazana podjela izlaznih podataka modela.



Slika 57. Prikaz podjele ulaznih varijabli za model M15 (Količina oborine, Intenzitet oborine i Temperatura zraka) na skupove za treniranje, validaciju i evalvaciju modela



Slika 58. Prikaz podjele ulaznih varijabli za model M15 (Tlak zraka, Vlažnost zraka i Solarna radijacija) na skupove za treniranje, validaciju i evalvaciju modela



Slika 59. Prikaz podjele izlazne varijable za model M15 (Razina vode u vodotoku) na skupove za treniranje, validaciju i evalvaciju modela

Broj iteracija koji je potreban da model bude optimalno treniran, nastupa u trenutku kada Suma kvadratne pogreške odziva modela naspram mjerenih podataka računata prema izrazu (21) dosegne iznos prilikom kojeg ne dolazi do povećanja srednje kvadratne pogreške odziva modela u procesu validacije. Odnosno, prilikom treniranja provodi se i validacija modela koja ukoliko zabilježi porast srednje kvadratne pogreške u 6 iteracija modela zaustavlja proces treniranja. Model je razvijen uz pomoć programskog paketa MATLAB R2012b (MathWorks) unutar kojega je ovaj proces automatski implementiran te se proces treniranja i validacije modela odvijaju u isto vrijeme. Optimalno treniranje modela sprečava preveliku treniranost modela uslijed koje model može izgubiti svoja generalizirajuća svojstva. Broj iteracija koji je bio potreban za optimalno treniranje svakog modela pojedinačno, prikazan je u *Tablici 11*.

Tablica 11. Broj iteracija u procesu optimalnog treniranja modela


Model	Korak predviđanja	Broj iteracija u procesu treniranja modela	Trajanje treniranja	OPTIMALNO TRENIRANJE
	[minuta]		[minuta]	
<b>M15</b>	30	15	2,30	9
<b>M30</b>	60	14	2,32	8
<b>M60</b>	120	16	3,20	10



## 4.2. Treniranje hidrološkog modela predviđanja otjecanja

Treniranje hidrološkog modela otjecanja temeljenog na umjetnoj neuronskoj preži provedeno je za tri različita koraka predviđanja: (i) M15 s korakom predviđanja od  $t=30$  minuta, (ii) M30 s korakom predviđanja od  $t=60$  minuta i (iii) M60 s korakom predviđanja od  $t=120$  minuta. U nastavku će biti opisan postupak treniranja svakog modela pojedinačno te prikazani rezultati odziva modela dok će kvaliteta treniranja biti prikazana analizom linearne regresije.


Model M15 daje predviđanje od  $t=30$  minuta unaprijed, a proces treniranja proveden je kroz 15 iteracija modela odnosno kroz 15 promjena optimizacijskog parametra u ulaznom sloju modela do trenutka kada je model optimalno treniran u 9 iteraciji. Treniranje modela trajalo je 2,30 minuta. U procesu treniranja hidrološki model otjecanja temeljen na umjetnoj neuronskoj mreži povezuje ulazni sloj s izlaznim slojem te prilikom toga usvaja znanje. Ulazni sloj podataka za treniranje čine meteorološki podaci složeni u matricu ranga  $92928 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $92928 \times 1$ . Na *Slici 60.* prikazan je odziv modela u procesu treniranja s obzirom na mjerene podatke te pogrešku modela.



*Slika 60. Prikaz odziva modela M15 u procesu treniranja u usporedbi s mjerenim podacima i prikazom pogreške*


Kao što je vidljivo na *Slici 60.* u procesu treniranja nastale su pogreške odziva modela pa je provedena analiza linearne regresije u kojoj su uspoređeni odziv modela i mjerene podatke te izračunat koeficijent određenosti  $r^2$  prema izrazu

(27). Prikaz analize linearne regresije prikazan je na *Slici 61*. Regresijski koeficijent dobiven iz analize iznosi  $r^2 = 0,99579$ .




*Slika 61. Prikaz analize linearne regresije mjerenih podataka razine vode te odziva modela M15*

Proces treniranja reguliran je sumom kvadratne pogreške (SSE) a kretanje pogreške ovisno o iteraciji treniranja modela prikazano je na *Slici 62*.




*Slika 62. Prikaz procesa optimalnog treniranja modela M15 kroz broj iteracija u ovisnosti o sumi kvadratne pogreške (SSE) i validaciji*

Model M30 daje predviđanje 60 minuta unaprijed, a proces treniranja proveden je kroz 13 iteracija modela odnosno kroz 13 promjena optimizacijskog parametra u ulaznom sloju modela do trenutka kada je model treniran optimalno. Treniranje modela trajalo je 2,32 minute. U procesu treniranja hidrološki model otjecanja temeljen na umjetnoj neuronskoj mreži povezuje ulazni sloj s izlaznim slojem te prilikom toga usvaja znanje. Ulazni sloj podataka za treniranje čine meteorološki podaci složeni u matricu ranga  $92919 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $92919 \times 1$ . Na *Slici 63.* prikazan je odziv modela u procesu treniranja s obzirom na mjerene podatke te pogrešku modela.




*Slika 63. Prikaz odziva modela M30 u procesu treniranja u usporedbi s mjerenim podacima i prikazom pogreške*

Kao što je vidljivo na *Slici 63.* u procesu treniranja nastale su pogreške odziva modela pa je provedena analiza linearne regresije u kojoj su uspoređeni odziv modela i mjereni te izračunat koeficijent određenosti  $r^2$  prema izrazu (27). Prikaz analize linearne regresije prikazan je na *Slici 64.* Regresijski koeficijent dobiven iz analize iznosi  $r^2 = 0,9845$ .




Slika 64. Prikaz analize linearne regresije mjerenih podataka razine vode te odziva modela M30

Proces treniranja reguliran je sumom kvadratne pogreške (SSE) a kretanje pogreške ovisno o iteraciji treniranja modela prikazano je na Slici 65.




Slika 65. Prikaz procesa optimalnog treniranja modela M30 kroz broj iteracija u ovisnosti o sumi kvadratne pogreške (SSE) i validaciji

Model M60 daje predviđanje 120 minuta unaprijed. Proces treniranja proveden je kroz 17 iteracija modela odnosno kroz 17 promjena optimizacijskog parametra u ulaznom sloju modela do trenutka kada je model treniran optimalno. Treniranje modela trajalo je 3,20 minuta. U procesu treniranja hidrološki model otjecanja temeljen na umjetnoj neuronskoj mreži povezuje ulazni sloj s izlaznim slojem te prilikom toga usvaja znanje. Ulazni sloj podataka za treniranje čine meteorološki podaci složeni u matricu ranga  $92897 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $92897 \times 1$ . Na *Slici 66.* prikazan je odziv modela u procesu treniranja s obzirom na mjerene podatke te pogrešku modela.




*Slika 66. Prikaz odziva modela M60 u procesu treniranja u usporedbi s mjerenim podacima i prikazom pogreške*

Kao što je vidljivo na *Slici 66.* u procesu treniranja nastale su pogreške odziva modela pa je provedena analiza linearne regresije u kojoj su uspoređeni odziv modela i mjereni podaci te izračunat koeficijent određenosti  $r^2$  prema izrazu (27). Prikaz analize linearne regresije prikazan je na *Slici 67.* Regresijski koeficijent dobiven iz analize iznosi  $r^2 = 0,97201$ .



Slika 67. Prikaz analize linearne regresije mjerenih podataka razine vode te odziva modela M60

Proces treniranja reguliran je sumom kvadratne pogreške (SSE) a kretanje pogreške ovisno o iteraciji treniranja modela prikazano je na Slici 68.




Slika 68. Prikaz procesa optimalnog treniranja modela M60 kroz broj iteracija u ovisnosti o sumi kvadratne pogreške (SSE) i validaciji

Nakon optimalnog treniranja modela M15, M30 i M60 nastavlja se s analizom kvalitete modela u procesu validacije i evalvacije.

### 4.3. Validacija hidrološkog modela predviđanja otjecanja

Validacija modela provedena je, kao što je ranije opisano, vizualnim i numeričkim mjerama za ocjenjivanje kvalitete modela. Odziv modela je uspoređen s mjerenim podacima razine vode za modele M15, M30 i M60. Prilikom validacije modela provjerava se osnovna funkcionalnost i rad modela.


Ulazni sloj podataka za validaciju modela M15 čine meteorološki podaci složeni u matricu ranga  $19914 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $19914 \times 1$ . Na *Slici 69.* prikazana je usporedba mjerenih podataka i odziva modela M15 te su prikazane pogreške za svaki korak vremena.



*Slika 69. Prikaz odziva modela M15 u procesu validacije u usporedbi s mjerenim podacima i prikazom pogreške*


Ulazni sloj podataka za validaciju modela M30 čine meteorološki podaci složeni u matricu ranga  $19911 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $19911 \times 1$ . Na *Slici 70.* prikazana je usporedba mjerenih podataka i odziva modela M30 te su prikazane pogreške za svaki korak vremena.





Slika 70. Prikaz odziva modela M30 u procesu validacije u usporedbi s mjerenim podacima i prikazom pogreške

Ulazni sloj podataka za validaciju modela M60 čine meteorološki podaci složeni u matricu ranga  $19907 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $19907 \times 1$ . Na Slici 71. prikazana je usporedba mjerenih podataka i odziva modela M60 te su prikazane pogreške za svaki korak vremena.



Slika 71. Prikaz odziva modela M60 u procesu validacije u usporedbi s mjerenim podacima i prikazom pogreške

Vizualnom analizom moguće je uočiti da u procesu validacije modeli M15, M30 i M60 daju vremenski točan odziv, odnosno uspješno predviđaju vrijeme podizanja razine vode, no u isto vrijeme bilježe odstupanje u predviđanju maksimalnih razina vode. Pri srednjim razinama vode u vodotoku sva tri modela

daju odziv s minimalnim pogreškama. Razlika u validaciji modela M15, M30 i M60 je u apsolutnom iznosu pogreške koja se povećava u skladu s povećanjem vremenskog koraka predviđanja. U cilju kvantifikacije pogreška modela u procesu validacije te ocijeni kvalitete modela u nastavku je provedena i numerička analiza kvalitete modela.

Numerička analiza kvaliteta modela provedena je pomoću jedne apsolutne i jedne relativne mjere kvalitete. Apsolutna mjera kvalitete srednja kvadratna pogreška (MSE) izračunata je prema izrazu (22) dok je relativna mjera kvalitete koeficijent određenosti ( $r^2$ ) izračunata prema izrazu (27). Rezultati numeričke analize kvalitete modela u procesu validacije prikazani su u *Tablici 12*.

*Tablica 12. Rezultati numeričke analize kvalitete modela u procesu validacije za modele M15, M30 i M60*


MODEL	MSE	$r^2$
<b>M15 (Korak predviđanja t=30 minuta)</b>	0,603	0,960
<b>M30 (Korak predviđanja t=60 minuta)</b>	1,150	0,940
<b>M60 (Korak predviđanja t=120 minuta)</b>	1,391	0,932

Rezultati procesa validacije modela prema kriterijima za ocijenu kvalitete modela bit će obrazloženi u diskusiji rezultata (Poglavlje 4.5.). Nakon validacije potrebno je provesti evalvaciju modela prilikom koje će model biti ispitan na način da će mu biti predstavljeni ulazni podaci koji nisu korišteni u procesu treniranja i validacije.

#### 4.4. Evalvacija hidrološkog modela predviđanja otjecanja

Evalvacija modela provedena je, kao što je ranije opisano, vizualnim i numeričkim mjerama za ocjenjivanje kvalitete modela. Odziv modela je uspoređen s mjerenim podacima razine vode za modele M15, M30 i M60.

Ulazni sloj podataka za evalvaciju modela M15 čine meteorološki podaci složeni u matricu ranga  $19914 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $19914 \times 1$ . Tokom evalvacije, modelu se predstavljaju ulazni podaci koji nisu korišteni u procesu treniranja i validacije. Na *Slici 72* prikazana je usporedba mjerenih podataka i odziva modela M15 te su prikazane pogreške za svaki korak vremena.




*Slika 72. Prikaz odziva modela M15 u procesu evalvacije u usporedbi s mjerenim podacima i prikazom pogreške*

Vizualnom analizom moguće je uočiti da u procesu evalvacije model daje vremenski točan odziv, odnosno relativno uspješno predviđa vrijeme podizanja razine vode kao što se moglo zamijetiti i u procesu validacije modela. Model također bilježi i odstupanje u predviđanju maksimalnih razina vode. Pri ujednačenim razinama vode u vodotoku model daje odziv s minimalnim pogreškama.

Ulazni sloj podataka za evalvaciju modela M30 čine meteorološki podaci složeni u matricu ranga  $19911 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $19911 \times 1$ . Tokom evalvacije, modelu se predstavljaju ulazni podaci koji nisu korišteni u procesu treniranja i validacije. Na *Slici 73*.


prikazana je usporedba mjerenih podataka i odziva modela M30 te su prikazane pogreške za svaki korak vremena.



Slika 73. Prikaz odziva modela M30 u procesu evalvacije u usporedbi s mjerenim podacima i prikazom pogreške

Vizualnom analizom moguće je uočiti da u procesu evalvacije model M30 daje vremenski točan odziv, odnosno relativno uspješno predviđa vrijeme podizanja razine vode kao i model M15. Model također bilježi i odstupanje u predviđanju maksimalnih razina vode. Za razliku od modela M15, model M30 bilježi puno izraženije pogreške u predviđanju maksimalne razine vode u vodotoku, dok za manja podizanja razine vode daje odziv s malim pogreškama.

Ulazni sloj podataka za evalvaciju modela M60 čine meteorološki podaci složeni u matricu ranga  $19907 \times 60$  podataka dok izlazni sloj čine razine vode složene u matrici ranga  $19907 \times 1$ . Na Slici 74. prikazana je usporedba mjerenih podataka i odziva modela M60 te su prikazane pogreške za svaki korak vremena.



Slika 74. Prikaz odziva modela M60 u procesu evalvacije u usporedbi s mjerenim podacima i prikazom pogreške

Vizualnom analizom moguće je uočiti da u procesu evalvacije model daje vremenski točan odziv, odnosno relativno uspješno predviđa vrijeme podizanja razine vode kao i modeli M15 i M30. Model također bilježi i podbačaj u predviđanju maksimalnih razina vode koji je puno izraženiji u modelu M60 nego u modelima s manjim korakom predviđanja. Model M60 također bilježi pogreške i pri predviđanju manjih podizanja razina vode u vodotoku za razliku od modela M15 i M30.

Kao što je opisano ranije za potrebe numeričke evalvacije koristiti će se apsolutne i relativne mjere. Uobičajeno je i preporučljivo koristiti više mjera kvaliteta pri evalvaciji modela. Evalvacija modela apsolutnim mjerama kvalitete provela se mjerama: (i) Srednja kvadratna pogreška (MSE) koja se računa prema izrazu (22), (ii) Korijen srednje kvadratne pogreške (RMSE) koji se računa prema izrazu (24) i Srednja apsolutna pogreška (MAE) koja se računa prema izrazu (25). Rezultati evalvacije modela apsolutnim mjerama kvalitete prikazani su u *Tablici 13*.

Tablica 13. Rezultati numeričke analize kvalitete modela apsolutnim mjerama u procesu evalvacije za modele M15, M30 i M60

APSOLUTNE MJERE KVALITETE			
MODEL	MSE	RMSE	MAE
	[ $cm^2$ ]	[ $cm$ ]	[ $cm$ ]
<b>M15</b>	5,737	2,934	0,487
<b>M30</b>	9,359	3,769	0,808
<b>M60</b>	11,656	4,738	1,046

Rezultati procesa evaluacije modela prema kriterijima za ocijenu kvalitete modela apsolutnim mjerama bit će obrazloženi u diskusiji rezultata (Poglavlje 4.5.).


Evalvacija modela relativnim mjerama kvalitete provela se mjerama: (i) Srednja kvadratna relativna pogreška (MSRE) koja se računa prema izrazu (26), (ii) Koeficijent određenosti ( $r^2$ ) koji se računa prema izrazu (27), (iii) Koeficijent učinkovitosti (CE) koji se računa prema izrazu (28), (iv) Indeks podudarnosti ( $d$ ) koja se računa prema izrazu (29), (v) Postotno odstupanje (PBIAS) koje se računa prema izrazu (31) i (vi) Omjer srednje kvadratne pogreške i standardne devijacije (RSR) koji se računa prema izrazu (32). Rezultati evaluacije modela relativnim mjerama kvalitete prikazani su u *Tablici 14*.

*Tablica 14. Rezultati numeričke analize kvalitete modela apsolutnim mjerama u procesu evaluacije za modele M15, M30 i M60*

RELATIVNE MJERE KVALITETE						
MODEL	MSRE	$r^2$	CE	$d$	PBIAS	RSR
	[–]	[–]	[–]	[–]	[%]	[–]
<b>M15</b>	0,0003	0,902	0,833	0,9999	-0,1901	0,5011
<b>M30</b>	0,0005	0,849	0,728	0,9994	-0,1818	0,6427
<b>M60</b>	0,0007	0,809	0,661	0,9998	-0,0419	0,8094

Rezultati procesa evaluacije modela prema kriterijima za ocijenu kvalitete modela relativnim mjerama bit će obrazloženi u diskusiji rezultata (Poglavlje 4.5.).

Kako bi se bolje ocijenila kvaliteta razvijenih modela te kvantificirale pogreške identificirane u procesu vizualne evaluacije modela, podaci korišteni za evaluaciju modela podijeljene su u razrede za evaluaciju na koje je primijenjena numerička mjera kvalitete modela srednja apsolutna pogreška (MAE) prema izrazu (25). Podaci su podijeljeni u razrede prema postotku, od srednje vrijednosti niza podataka, od 100% do -100% kao što je prikazano na *Slici 75*.



Slika 75. Prikaz raspodjele mjerenih podataka u postotne razrede

Nakon podjele podataka u razrede, na svaki je skup podataka u razredu primijenjena mjera kvalitete MAE, a rezultati izračuna prikazani su u *Tablici 15*. Prema prikazanim rezultatima može se zaključiti da u razredima od 1 do 4 postoje značajne pogreške s obzirom na raspon podataka dok u razredima od 4 do 8 pogreška modela bilježi iznose puno manjeg iznosa (bliske nuli). Rezultati procesa evaluacije modela prema dodatnom kriteriju za ocijenu kvalitete modela bit će obrazloženi u diskusiji rezultata (Poglavlje 4.5.).

Tablica 15. Rezultati numeričke analize kvalitete modela primjenom srednje apsolutne pogreške na postotne razrede podataka

Podjela mjerenih podataka u razrede			MODEL		
Razred	Postotak [%]	Granice razine vode [cm]	M15	M30	M60
1	[100, 75>	[211.2, 174.65>	82.54	100.47	101.32
2	[75, 50>	[174.65, 138.76>	38.7	53.30	59.80
3	[50, 25>	[138.76, 102.88>	13.55	24.94	34.39
4	[25, 0>	[102.88, 66.99>	0.56	0.74	0.84
5	[0, -25>	[66.99, 65.61>	0.29	0.44	0.71
6	[-25, -50>	[65.61, 64.23>	0.23	0.67	1.35
7	[-50, -75>	[64.23, 62.85>	0.23	0.41	0.44
8	[-75, -100]	[62.85, 61.47]	0.21	0.28	0.45



#### **4.5. Diskusija rezultata razvoja hidrološkog modela predviđanja otjecanja s sliva Slani potok temeljenog na umjetnoj neuronskoj mreži**

Hidrološki model predviđanja otjecanja s malih slivova je temeljen na umjetnoj neuronskoj mreži i razvijen za potrebe predviđanja otjecanja na istražnom području sliva Slani potok. Kako je model razvijen za mali sliv na kojemu se ne mogu očekivati dugoročna predviđanja, cilj je postići dostatne mogućnosti predviđanja kako bi bilo moguće implementirati sustav ranog uzbunjivanja. Vremenska razlučivost modela je  $\Delta t = 2 \text{ minute}$ , a za potrebe predviđanja razvijen je model koji je ispitan na tri vremenska koraka: Model je : (i) M15 s korakom predviđanja od  $t=30 \text{ minuta}$ , (ii) M30 s korakom predviđanja od  $t=60 \text{ minuta}$  i (iii) M60 s korakom predviđanja od  $t=120 \text{ minuta}$ .

Hidrološki model otjecanja izrađen je na temelju umjetne neuronske mreže arhitekture višeslojnog perceptrona, a koji se sastoji od ulaznog, skrivenog i izlaznog sloja (*Slika 55.*) Za potrebe treniranja koristio se Levenberg – Marquardt algoritam, a skriveni sloj čini deset neurona. Ulazni sloj u modelu se sastoji od meteoroloških podataka: (i) Količine oborine, (ii) Intenziteta oborine, (iii) Temperature zraka, (iv) Vlage zraka, (v) Tlaka zraka i (vi) Insolacije. Svaki redak ulaznog podatka sastoji se od nabrojanih meteoroloških podataka u trenutku  $t=0$  te podataka iz prethodnih 20 minuta čime se modelu omogućava pamćenje meteorološkog stanja na slivu. Izlazni sloj modela čine hidrološki podaci razine vode u vodotoku za određeni korak predviđanja.

Razvijeni modeli su podvrgnuti procesu treniranja (*Slika 60.*, *Slika 63.*, *Slika 66.*). U procesu treniranja modela M15, M30 i M60 od velike je važnosti optimalno trenirati model. Kako bi se ocijenio proces treniranja odziv modela je uspoređen s mjerenim podacima linearnom regresijom te je izračunat i koeficijent određenosti  $r^2$  (*Slika 61.*, *Slika 64.*, *Slika 67.*). Analiza procesa treniranja ukazala je da modeli daju odgovarajući odziv. Rezultati izračunatog koeficijenta određenosti za modele M15, M30 i M60 ukazuju na postojanje gotovo potpuno definiranog linearnog odnosa između odziva modela i mjerenih podataka, odnosno postoji čvrsta regresijska veza. Umjetne neuronske mreže imaju svojstvo univerzalnog aproksimatora, odnosno drugim riječima imaju mogućnost da bilo kakve ulazne podatke preslikaju u izlazne. U ovom slučaju proces treniranja zaustavljen je u

trenutku kada je ostvareno optimalno treniranje (regulirano sumom kvadratne pogreške SSE) kako bi se izbjegla pretreniranost modela koja može dovesti do gubitka generalizacijskih svojstava modela na što ukazuju i rezultati linearne regresije koji nisu jednaki 1 (*Slika 62.*, *Slika 65.*, *Slika 68.*).

Validacija modela provedena je vizualnim i numeričkim mjerama za ocjenjivanje kvalitete modela. Odziv modela je uspoređen s mjerenim podacima razine vode za modele M15, M30 i M60 (*Slika 69.*, *Slika 70.*, *Slika 71.*). Prilikom validacije modela provjerila se osnovna funkcionalnost i rad modela.

Vizualnom analizom modeli M15, M30 i M60 daju vremenski točan odziv, odnosno uspješno predviđaju vrijeme kada će nastupiti podizanje razine vode, no u isto vrijeme bilježe odstupanje u predviđanju maksimalnih razina vode. Pri srednjim razinama vode u vodotoku sva tri modela daju odziv s minimalnim pogreškama. Razlika u validaciji modela M15, M30 i M60 je u apsolutnom iznosu pogreške koja se očekivano povećava u skladu s povećanjem vremenskog koraka predviđanja. Rezultati vizualne analize modela pri procesu validacije su više nego zadovoljavajući ukoliko se uzme u obzir da su modeli razvijeni za mali sliv čija je karakteristika brz odziv na pale oborine te mogućnost nastanka štetne pojave.

Numerička analiza kvalitete modela M15, M30 i M60 (*Tablica 12.*) u procesu validacije provedena je pomoću jedne apsolutne i jedne relativne mjere kvalitete: srednja kvadratna pogreška (MSE) i koeficijent određenosti ( $r^2$ ). Prema kriterijima kvalitete modela (*Tablica 6.*) koeficijent određenosti je za sve modele u granicama koji upućuje da su modeli „vrlo dobri“. Granice za ocjenu kvalitete modela za srednju kvadratnu pogrešku nisu jasno određene no poželjno je da budu što manjeg iznosa, a u ovom slučaju su manje od 1,5 za sva tri modela. Temeljem numeričke analize kvalitete modela može se zaključiti da su modeli M15, M30 i M60 zadovoljili kriterije te da su modeli funkcionalni.

Nakon validacije provedena je evalvacija modela prilikom koje je model ispitan na način da su mu predstavljeni ulazni podaci koji nisu korišteni u procesu treniranja i validacije. Evalvacija modela provedena je vizualnim i numeričkim mjerama za ocjenjivanje kvalitete modela. Odziv modela je uspoređen s mjerenim podacima razine vode za modele M15, M30 i M60 (*Slika 72.*, *Slika 73.*, *Slika 74.*). U ovom slučaju modelima su predstavljeni podaci u kojima je zabilježen najveći

vodni val tokom razdoblja mjerenja kako bi se u procesu evalvacije ispitala generalizacijska svojstva modela.

Vizualna analiza kvalitete modela u procesu evalvacije modela u sva tri slučaja predviđanja za modele M15, M30 i M60 pokazuje dobar vremenski odziv modela, odnosno modeli dobro predviđaju točno vrijeme kada će nastupiti podizanje razine vode. Sva tri modela ipak ukazuju na odstupanje kada je u pitanju predviđanje točne razine u maksimumu razine vode, a posebice u slučaju kada se odziv modela traži za predviđanje maksimalne razine vode koja je ikad zabilježena na vodotoku. Modeli imaju dobro generalizacijsko svojstvo jer u slučaju predviđanja maksimalne razine vode u vodotoku predviđaju veću razinu vode od one usvojene u procesu treniranja. Vizualnom analizom se također može zamjetiti i povećanje iznosa apsolutne pogreške u skladu s povećanjem koraka predviđanja. Kako bi se mogla kvantificirati kvaliteta modela u procesu evalvacije provedena je i numerička analiza kvalitete modela.

Evalvacija modela apsolutnim mjerama kvalitete provela se mjerama: (i) Srednja kvadratna pogreška (MSE), (ii) Korijen srednje kvadratne pogreške (RMSE) i Srednja apsolutna pogreška (MAE) (*Tablica 13.*). Prema kriterijima kvalitete modela za apsolutne mjere kvalitete (*Tablica 6.*) granice kvalitete za MSE, RMSE i MAE nisu jasno definirane no poželjni su iznosi što bliži nuli. S obzirom da zabilježene razine vode u vodotoku imaju raspon od 8,1 cm do 211,2 cm rezultati se za sve apsolutne mjere mogu smatrati zadovoljavajućim. Temeljem numeričke analize kvalitete modela može se zaključiti da su modeli M15, M30 i M60 zadovoljili kriterije, odnosno da imaju adekvatne mogućnosti predviđanja.

Evalvacija modela relativnim mjerama kvalitete provela se mjerama: (i) Srednja kvadratna relativna pogreška (MSRE), (ii) Koeficijent određenosti ( $r^2$ ), (iii) Koeficijent učinkovitosti (CE), (iv) Indeks podudarnosti ( $d$ ), (v) Postotno odstupanje (PBIAS) i (vi) Omjer srednje kvadratne pogreške i standardne devijacije (RSR) (*Tablica 14.*). Prema kriterijima kvalitete modela za relativne mjere kvalitete (*Tablica 6.*) granice kvalitete za MSRE i RSR nisu jasno definirane no poželjni su također iznosi što bliži nuli. S obzirom da zabilježene razine vode u vodotoku imaju raspon od 8,1 cm do 211,2 cm rezultati se za ove relativne mjere mogu smatrati zadovoljavajućim. Granice relativne mjere kvalitete  $d$  nisu jasno određene no poželjno je da iznos bude što bliži broju 1. Temeljem toga može se zaključiti da

su modeli M15, M30 i M60 zadovoljili kriterije evaluacije. Koeficijent određenosti ( $r^2$ ) ima jasno definirane kriterije kvalitete (*Tablica 6.*) te se prema njima modeli M15, M30 i M60 mogu okarakterizirati kao „vrlo dobri“. Prema kriteriju koeficijenta učinkovitosti (CE) model M15 se može okarakterizirati kao „vrlo dobar“, a modeli M30 i M60 kao „dobri“ dok prema postotnom odstupanju (PBIAS) se sva tri modela mogu okarakterizirati kao „vrlo dobri“. Numeričkom evaluacijom modela može se zaključiti da model M15 po svim kriterijima zadovoljava te se karakterizira kao „vrlo dobar“ dok su modeli M30 i M60 po svim kriterijima ocijenjeni kao „vrlo dobri“ osim po mjeri kvalitete modela CE kojom su ocijenjeni kao „dobri“. Prema primjenjenim numeričkim mjerama kvalitete modela sva tri modela imaju adekvatne mogućnosti predviđanja dok kod modela M30 i M60 jedino mjera kvalitete CE upućuje na prisutnost pogrešaka u modelima.

Iako su vizualnom analizom modela u procesu evaluacije prepoznate pogreške odnosno odstupanja modela, može se zaključiti da korištene mjere kvalitete nisu uputile na postojanje pogrešaka već su rezultati evaluacije i više nego zadovoljavajući. Razlog tome može se pronaći u velikom broju podataka koji su primijenjeni u modelu te činjenici da u izlaznom sloju podataka modela prevladavaju podaci koji opisuju srednju razinu vode. S druge strane cijeli niz znanstvenika upućuje na neujednačenost korištenja niza različitih mjera kvaliteta modela u procesu evaluacije te nepostojanje definiranog postupka evaluacije ovakve vrste modela, pa je na kraju ocijena modela prepuštena procijeni autora.

S obzirom da su vizualnom evaluacijom uočena određena odstupanja modela pri predviđanju maksimalnih razina vode, a na koja numerička evaluacija nije ukazala, unutar disertacije primjenjena je dodatna numerička mjera ocjene kvalitete. Podaci korišteni za evaluaciju modela podijeljeni su u razrede na koje je primijenjena numerička mjera kvalitete modela srednja apsolutna pogreška (MAE) (*Slika 75.*). Ovim načinom evaluacije modela bilo je moguće kvantificirati pogreške i odrediti pri kojim razinama vode je pogreška modela učestalija. Rezultati su ukazali na povećanje odstupanja modela pri vršnim razinama vode te ukazali na značajnije pogreške modela M60. Model M60 je i pri predviđanju manjim razina vode ukazao na postojanje značajnih pogrešaka. Na temelju dodatne numeričke evaluacije modela M15, M30 i M60 (*Tablica 15.*) može se zaključiti da se modeli M15 i M30, za razliku od modela M60, mogu koristiti u svrhu predviđanja.

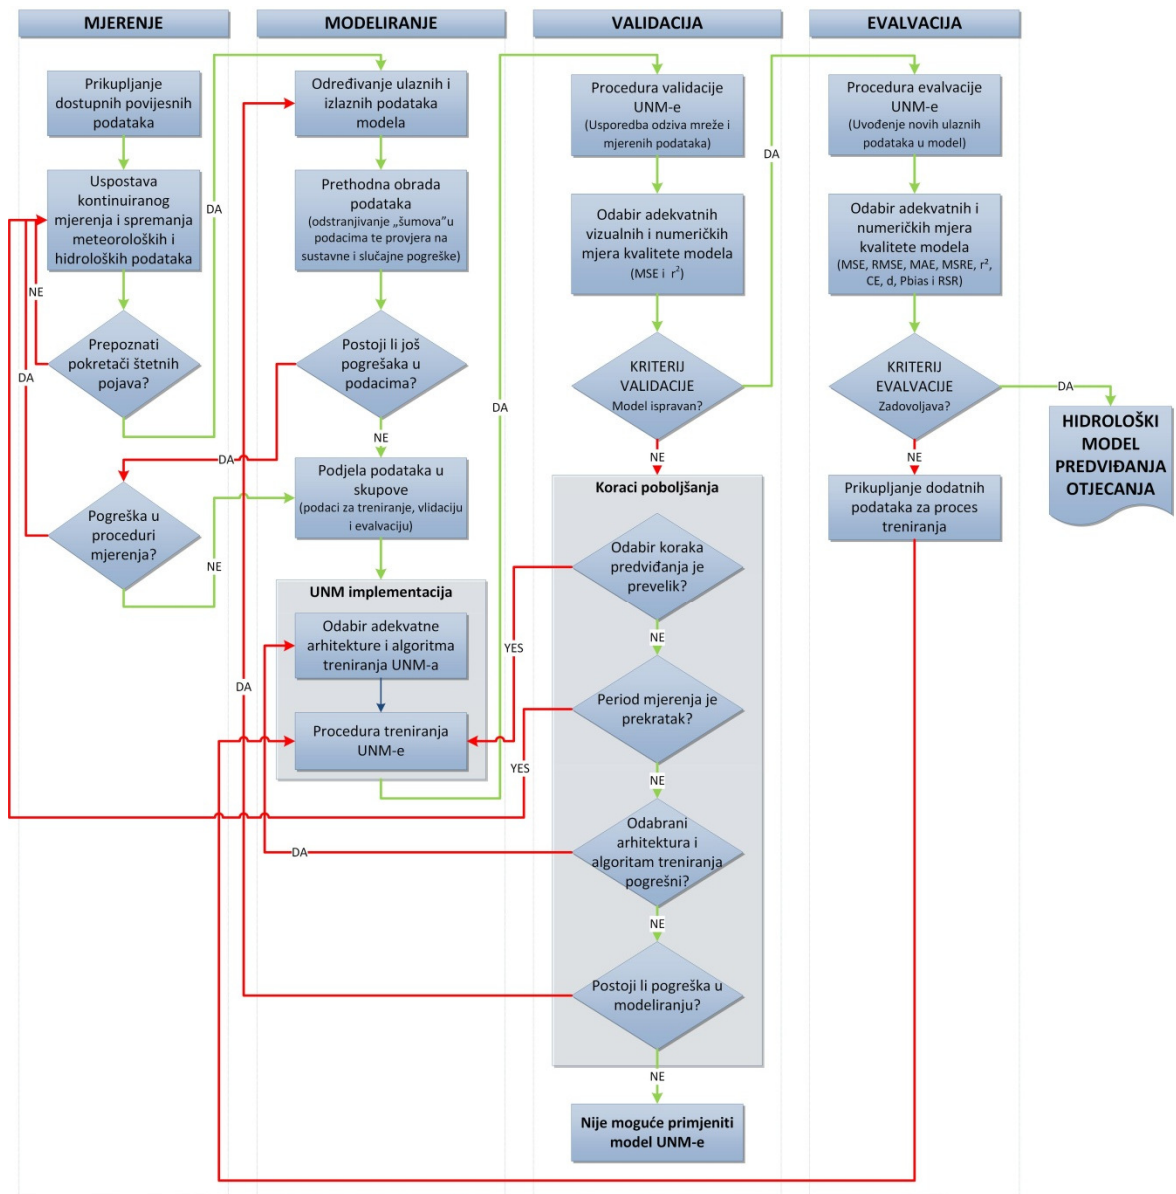
Razvoj modela otjecanja temeljenog na umjetnoj neuronskoj mreži za mali sliv u disertaciji je izrađen za potrebe moguće implementacije sustava za rano uzbunjivanje te pod pretpostavkom da je na malim slivovima moguće ostvariti predviđanje hidroloških varijabli. Ukoliko se analiziraju rezultati evaluacije, s obzirom na primjenu ovog modela, može se zaključiti da dobar vremenski odziv modela na iznenadno podizanje razine vode u vodotoku daje dobar preduvjet za implementaciju sustava ranog uzbunjivanja. S obzirom da je dodatna evaluacijska mjera kvalitete ukazala da odziv modela M60 ima značajna odstupanja te da ga je iz tog razloga potrebno odbaciti, može se zaključiti da se za potrebe predviđanja razina vode u vodotoku Slani potok mogu koristiti modeli M15 i M30. Kako je cilj predviđanja što veći vremenski korak u tom slučaju za sliv Slanog potoka se može primjeniti model M30 čiji je korak predviđanja  $t=60$  minuta. Iako vremenski korak predviđanja od  $t=60$  minuta ne izgleda dovoljno dugim vremenskim periodom u kojem je moguće provesti proceduru koju zahtijeva sustav ranog uzbunjivanja, u ovom je slučaju i više nego moguć. Naime, sustav ranog uzbunjivanja bi u ovom slučaju obuhvaćao samo područje sliva Slani potok, prilikom čega bi u slučaju predviđanja štetne pojave u obliku bujice, muljnog toka ili debratne poplave, bilo moguće u vremenskom periodu od  $t=60$  minuta ograničiti pristup prometnoj infrastrukturi na slivu te obavijestiti kućanstva koja su u neposrednoj blizini potencijalne štetne pojave.

Za potrebe razvoja modela korišteni su meteorološki i hidrološki podaci u periodu od 2. travnja do 3. prosinca 2014. Sa gledišta izrade hidroloških analiza ovaj period se smatra veoma kratkim. S druge strane, u ovom periodu zabilježen je velik broj ekstremnih oborinskih epizoda čiji su podaci činili dobru osnovu za razvoj modela. Modeli su već i sa tako kratkim periodom podataka dali dobre rezultate predviđanja no također su ukazali i na odstupanja pri predviđanju maksimalnih razina vode. Osnova kvalitetnog modela temeljenog na umjetnoj neuronskoj mreži je implementacija što većeg broja podataka u procesu treniranja. Shodno tome se, kod razvijenih modela, može očekivati još točnije rezultate predviđanja razina vode pri dodavanju novih mjerenih podataka u procesu treniranja.

## **5. METODOLOGIJA ZA IMPLEMENTACIJU HIDROLOŠKOG MODELA OTJECANJA NA MALIM SLIVOVIMA TEMELJENOG NA UMJETNOJ NEURONSKOJ MREŽI**

Temeljem provedenog prethodnog istraživanja utvrđen je nedostatak detaljnije razrađenih metodologija i procedura za razvoj hidroloških modela temeljenih na umjetnim neuronskim mrežama. Preciznije definiranje koraka metodologije razvoja hidroloških modela temeljenih na umjetnim neuronskim mrežama preduvjet su povećanju kvalitete modela općenito te put ka ujednačavanju procedura pri korištenju umjetnih neuronskih mreža koje su prijeko potrebne.

Razvijenim modelom i istraživanjem moguće implementacije modela umjetne neuronske mreže za potrebe izrade hidrološkog modela otjecanja na malom slivu utvrđeni su detaljni proceduralni koraci za razvoj modela. Definirani koraci pri razvoju modela čine temelj metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži u cilju razvoja sustava za rano uzbunjivanje. Koraci metodologije razvijeni su na temelju općih smjernica koje su postavili Maier i drugi (2010). Na *Slici 76.* je prikazan dijagram toka koji se dijeli na četiri glavne grupe koraka: (i) Mjerenje, (ii) Modeliranje (iii) Validacija i (iv) Evalvacija dok će proces implementacije umjetne neuronske mreže biti prikazan u zasebnom dijagramu toka. U nastavku rada će svaki od koraka metodologije biti detaljno objašnjeni.



Slika 76. Dijagram toka metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži



## **5.1. Mjerenje za potrebe razvoja hidrološkog modela predviđanja otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži**

Prvu grupu koraka metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži čine mjerenja koja se sastoje od nekoliko izrazito važnih koraka od kojih će svaki biti zasebno objašnjen.

### ***5.1.1. Prikupljanje dostupnih povijesnih podataka***

Na samom početku važno je prikupiti sve dostupne podatke vezane za istražno područje provođenjem prethodnog istraživanja. Prethodno istraživanje obuhvaća prikupljanje svih povijesnih istraživanja, podatke (klimatološka, geološka, hidrogeološka i hidrološka istraživanja) te kartografske prikaze vezane za predmetni sliv. Potom je potrebno utvrditi trenutno stanje slivnog područja te samog vodotoka, analizirati fizičke osobine sliva i čimbenike otjecanja. Ova procedura omogućava istraživaču uvid u problematiku i definira nastavak istraživanja.

### ***5.1.2. Uspostava kontinuiranog mjerenja i spremanja meteoroloških i hidroloških podataka***

Temeljem provedenih prethodnih istraživanja te prikupljanja dostupnih povijesnih podataka moguće je odrediti mjesto postavljanja mjernih instrumenata i vremenski korak mjerenja meteoroloških ili hidroloških podataka za istražni sliv. Na malim slivovima se predlaže postavljanje minimalno dvije automatske meteorološke postaje na prostoru sliva te određivanje minimalno jednog mjernog profila u vodotoku za kontinuirano mjerenje razina vode. Postavljanje dvije meteorološke postaje potrebno je zbog utvrđivanja jednolike raspodjele oborina na površini sliva. Mjerenja meteoroloških i hidroloških podataka na malom slivu je potrebno provoditi kontinuirano s odgovarajućim vremenskim korakom od minimalno  $t=1$  minuta do maksimalno  $t=10$  minuta kako bi bilo moguće mjerenjima obuhvatiti sve promjene meteoroloških i hidroloških podataka koji se na malim slivovima odvijaju u kratkim vremenskim razdobljima. Odgovarajući vremenski korak mjerenja moguće je odrediti prethodnim usporednim pokusnim mjerenjima s različitim vremenskim korakom pohrane podataka te njihovom usporedbom točnosti.

### **5.1.3. Prepoznavanje pokretača štetnih pojava**

Nakon uspostave kontinuiranih mjerenja meteoroloških i hidroloških podataka, potrebno je također i kontinuirano pratiti raznovrsnost prikupljenih podataka. U području hidroloških istraživanja od velike je važnosti dužina niza podataka koji se analiziraju te se njihov značaj određuje prema odlikama niza. Smatra se da je niz od 30 godina mjerenja dovoljno dug niz za relevantne analize podataka. S druge strane, kada se mjere meteorološki i hidrološki podaci na malim slivovima, u kratkom razdoblju od nekoliko godina, cilj je mjerenjima postići što veću raznovrsnost. Za izradu hidrološkog modela otjecanja u cilju implementacije sustava ranog uzbunjivanja značajne podatke čine oni koji su izazvali štetnu pojavu. Poželjno je da se niz prikupljenih podataka sastoji od minimalno desetak značajnih oborinskih epizoda iz različitih godišnjih doba godine kako bi se moglo analizirati uvjete otjecanja i nastanka štetnih pojava. Mjerenja se prije nastavka razvoja modela trebaju provoditi do trenutka kada su prepoznati pokretači štetnih pojava.

## **5.2. Modeliranje predviđanja otjecanja s malih slivova temeljem umjetne neuronske mreže**

Drugu grupu koraka metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži čini modeliranje predviđanja otjecanja s malih slivova upotrebom umjetne neuronske mreže, a sastoji se od važnih koraka koji će u nastavku biti objašnjeni.

### **5.2.1. Određivanje ulaznih i izlaznih podataka modela**

Nakon što su prepoznati pokretači štetnih pojava na istražnom slivu valja odrediti ulazne i izlazne podatke modela odnosno odabrati one podatke koji su fizikalnim procesom povezani odnosno utječu na izlazne podatke modela, primjer čega je meteorološki podatak količine oborine povezan s procesom otjecanja sa sliva koji uzrokuje povećanje razine vode u vodotoku. U cilju razvoja hidrološkog modela otjecanja ulazne podatke predstavljaju meteorološki podaci (količina oborine, intenzitet oborine, temperatura zraka, vlažnost zraka, tlak zraka, insolacija itd.) dok izlazne podatke predstavljaju hidrološki podaci (razina vode ili protok).

### **5.2.2. Prethodna obrada podataka**

Podatke koji su prikupljeni mjernim instrumentima te odabrani za razvoj modela prethodno je potrebno obraditi. U prethodnu obradu podataka spadaju otklanjanje pogrešaka i takozvanih „šumova“ podataka. Pogreške u podacima mogu biti sustavne i slučajne pogreške mjerenja te je takve podatke potrebno otkloniti iz skupa podataka. Kada je vremenski korak mjerenja kratak ( $t=2$  minute) u podacima nastaju takozvani „šumovi“ odnosno smetnje koje su vidljive u obliku minimalnih oscilacija oko srednje vrijednosti izmjenjenog podatka. Smetnje u podacima je potrebno također, kao i pogreške mjerenja, otkloniti, kako model ne bio nepotrebno opterećen oscilacijom podataka koja na nikakav način ne pridonosi točnosti modela. Otklanjanje smetnji u podacima moguće je provesti primjenom lokalne nelinearne regresijske metode (*eng. Loess method*) na intervalu od 10 podataka.

### **5.2.3. Postojanje dodatnih pogrešaka u podacima**

Ukoliko su nakon sveobuhvatne obrade podataka, otklanjanjem pogreški mjerenja i smetnji u podacima, vidljive pogreške u mjerenim podacima postoji mogućnost da procedura mjerenja nije primjerena odnosno da postoji pogreška u proceduri. Ukoliko je utvrđena pogreška u proceduri mjerenja uputno je preispitati proceduru pod kojom su uspostavljena mjerenja te uspostaviti nova mjerenja određenih meteoroloških i/ili hidroloških podataka.

Ako se nakon obrade podataka, otklanjanjem pogreški mjerenja i smetnji u podacima, ne uočava dodatne pogreške može se prijeći na sljedeći korak procedure u kojem se podaci dijele u skupove.

### **5.2.4. Podjela podataka u skupove**

Prethodno pripremljene podatke koji čine ulazne i izlazne podatke modela umjetne neuronske mreže potrebno je podijeliti u skupove. Za razvoj modela umjetne neuronske mreže potrebno je razdijeliti podatke u tri skupa koji čine skup podataka za treniranje, validaciju i evalvaciju. Omjer razdjele podataka čine 70% podataka za potrebe treniranja, 15% podataka za potrebe validacije te 15% podataka za potrebe evalvacije. Nakon što su utvrđeni skupovi podataka prelazi se na implementaciju umjetne neuronske mreže na pripremljene podatke.

### **5.2.5. Implementacija umjetne neuronske mreže**

Implementacija umjetne neuronske mreže na prethodno obrađene te razdijeljene podatke u skupove za potrebe razvoja modela otjecanja sastoji se od odabira arhitekture umjetne neuronske mreže te odabira algoritma treniranja s ciljem treniranja modela na unaprijed određeni vremenski korak predviđanja. Kao što je ranije opisano, procedura implementacije umjetne neuronske mreže bit će detaljnije opisana zasebnom procedurom. Kada je odabrana adekvatna arhitektura modela te algoritam treniranja i provedeno treniranje modela, moguće je započeti s trećom grupom koraka metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima.

## **5.3. Validacija hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži**

Treću grupu koraka metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži čini postupak validacije modela čiji će koraci u nastavku biti detaljnije opisani.

### **5.3.1. Procedura validacije modela umjetne neuronske mreže**

Sa procedurom validacije koja se definira kao procjena kvalitete odziva modela za vrijeme treniranja modela, nastupa se nakon što je model završio proces treniranja. Razvijeni model se provjerava ranije pripremljenim skupom ulaznih i izlaznih podataka u tu svrhu (15% podataka) tako da se odziv modela uspoređuje s mjerenim podacima.

### **5.3.2. Odabir adekvatnih vizualnih i numeričkih mjera kvalitete**

Odziv koji je model dao na temelju validacijskog skupa podataka potrebno je ocijeniti vizualno te primjenom numeričkih mjera kvalitete modela. Vizualnom usporedbom odziva modela i mjerenih podataka moguće je identificirati pogreške modela koje će se potom ocijeniti numeričkim mjerama kvalitete modela. Za potrebe razvoja hidrološkog modela otjecanja na malim slivovima uputno je koristiti barem jednu apsolutnu (srednja kvadratna pogreška (MSE)) i jednu relativnu (koeficijent određenosti ( $r^2$ )) mjeru kvalitete modela no nije isključena upotreba i drugih mjera kvalitete koja će s obzirom na veličinu niza dati jasniji uvid u rasporostranjenje pogreški modela.

### **5.3.3. Kriterij validacije**

Rezultate numeričkih mjera kvalitete modela prilikom procesa validacije je potrebno ocijeniti. S obzirom da se danas pri validaciji modela temeljenih na umjetnim neuronskim mrežama koristi cijeli niz različitih mjera kvalitete modela, a neke od njih imaju, dok druge nemaju, jasno određene kriterije za ocjenu modela, od presudne je važnosti pristupiti rezultatima mjera kvalitete modela oprezno te rezultate promatrati objektivno i kritički.

Ukoliko model zadovolji kriterije validacije moguće je krenuti na sljedeći korak u razvoju modela no ako model nije zadovoljio kriterije validacije te kao takav je ocijenjen kao „loš“ moguće je provesti nekoliko mogućih koraka u cilju poboljšanja modela. Loš rezultat ocijene kvalitete modela pri procesu validacije može biti izazvan odabranim prevelikom vremenskim korakom predviđanja prilikom implementacije umjetne neuronske mreže pa se poboljšanje može postići skraćivanjem vremena predviđanja nakon čega se ponavlja cijela procedura treniranja modela te validacije modela. Ukoliko smanjenje vremenskog koraka predviđanja nije rezultiralo poboljšanjem kvalitete modela, moguće je da je za izradu modela, a posebice za proces treniranja korišten prekratak period mjerenja odnosno da je implementiran premali skup podataka te valja u cilju poboljšanja modela nastaviti prikupljati podatke te nakon toga ponoviti cijelu proceduru koja obuhvaća prethodnu obradu podataka i implementaciju umjetne neuronske mreže. Ukoliko veći skup podataka u procesu treniranja modela nije utjecao na kvalitetu modela pri validaciji, moguće je odabrati drugu arhitekturu umjetne neuronske mreže i/ili algoritam treniranja te ponoviti daljnju proceduru. Zadnji mogući korak poboljšanja kvalitete modela odnosi se na provjeru u samom procesu modeliranja što se odnosi na moguće pogreške pri jednom od koraka procedure kao što su pogrešni odabir ulaznih i izlaznih podataka, pogrešna obrada podataka itd. Provedena procedura poboljšanja kvalitete trebala bi dovesti do poboljšanja kvalitete modela no ukoliko niti jedan od koraka nije utjecao na poboljšanje modela moguće je jedino konstatirati da u tom slučaju nije moguće primijeniti model umjetne neuronske mreže.

## **5.4. Evalvacija hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži**

Četvrtu grupu koraka metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži čini postupak evalvacije, a koji se može smatrati najvažnijim korakom pri razvoju modela. U nastavku će detaljno biti objašnjen postupak evalvacije.

### ***5.4.1. Procedura evalvacije modela umjetne neuronske mreže***

Sa procedurom evalvacije, koja se definira se kao procjena kvalitete odziva modela na temelju podataka koji nisu korišteni u procesu treniranja i validacije, nastupa se nakon što je model zadovoljio kriterije kvalitete modela pri validaciji. Razvijeni model se provjerava ranije pripremljenim skupom ulaznih i izlaznih podataka u tu svrhu (15% podataka) tako da se odziv modela uspoređuje s mjerenim podacima.

### ***5.4.2. Odabir adekvatnih vizualnih i numeričkih mjera kvalitete***

Odziv koji je model dao na temelju evalvacijskog skupa podataka potrebno je ocijeniti vizualno te primjenom numeričkih mjera kvalitete modela. Vizualnom usporedbom odziva modela i mjerenih podataka moguće je identificirati pogreške modela koje će se potom ocijeniti numeričkim mjerama kvalitete modela. Za potrebe razvoja hidrološkog modela otjecanja na malim slivovima uputno je koristiti veći broj apsolutnih mjera kvalitete modela kao što su srednja kvadratna pogreška (MSE), Korijen srednje kvadratne pogreške (RMSE) i Srednja apsolutna pogreška (MAE) te veći broj relativnih mjera kao što su Srednja kvadratna relativna pogreška (MSRE), Koeficijent određenosti ( $r^2$ ), Koeficijent učinkovitosti (CE), Indeks podudarnosti (d), Postotno odstupanje (PBIAS) i Omjer srednje kvadratne pogreške i Standardna devijacija (RSR), no nije isključena upotreba i drugih mjera kvalitete koje će bolje s obzirom na veličinu niza dati uvid u rasporostranjenje pogreški modela.

### ***5.4.3. Kriterij evalvacije***

Rezultate numeričkih mjera kvalitete modela prilikom procesa evalvacije je potrebno ocijeniti. S obzirom da se danas pri evalvaciji modela temeljenih na umjetnim neuronskim mrežama koristi cijeli niz različitih mjera kvalitete modela, od kojih neke imaju dok druge nemaju, jasno određene kriterije za ocjenu modela, od

iznimne je važnosti pristupiti analizi rezultata mjera kvalitete modela s oprezom. Rezultate je potrebno analizirati objektivno te kritički.


Kada je model zadovoljio kriterije evalvacije tada se može zaključiti da je razvijeni hidrološki model predviđanja otjecanja na malim slivovima temeljen na umjetnoj neuronskoj mreži spreman za daljnje korištenje odnosno predviđanje otjecanja sa sliva na temelju trenutačnih ulaznih podataka.

Bez obzira na pozitivnu evalvaciju modela uputno je kontinuirano nadopunjavati model novim izmjerenim podacima, odnosno povećavati skup za treniranje modela, jer će se tim postupkom i dalje poboljšavati kvaliteta modela.



## 5.5. Implementacija umjetne neuronske mreže za potrebe razvoja hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži

Kao što je ranije opisano, implementacija umjetne neuronske mreže opisat će se kao zasebna procedura, a koja ima u potpunosti definirane korake. Dijagram toka implementacije umjetne neuronske mreže prikazan je na *Slici 77*.



Slika 77. Dijagram toka implementacije umjetne neuronske mreže

Procedura implementacije umjetne neuronske mreže na prethodno obrađene te razdijeljene podatke u skupove za potrebe razvoja modela otjecanja sastoji se od odabira arhitekture umjetne neuronske mreže, odabira algoritma treniranja s ciljem treniranja modela na unaprijed određeni vremenski korak

predviđanja te odabira programskog paketa u kojem će umjetna neuronska mreža biti razvijena.

Prvi korak procedure čini adekvatan odabir arhitekture umjetne neuronske mreže. Iako se za potrebe razvoja hidroloških modela koriste različite arhitekture kao što su primjerice Višeslojni perceptron (MLP), Mreže radijalne baze (RFB), Samoorganizirajuće mape (SOM) te druge, za razvoj hidroloških modela otjecanja najučestalije se koristi arhitektura višeslojnog perceptrona. Arhitektura višeslojnog perceptrona se zato i u slučaju razvoja modela predviđanja otjecanja na malim slivovima također preporuča kao početni odabir koji se s obzirom na daljnji razvoj i kvalitetu modela može promijeniti.

Sljedeći je korak pri implementaciji umjetne neuronske mreže, ukoliko je izabrana arhitektura višeslojnog perceptrona koja se sastoji od ulaznog, skrivenog i izlaznog sloja, slaganje numeričke matrice ulaznih podataka, odabir broja neurona u skrivenom sloju te odabir vremenskog koraka predviđanja izlaznog podatka. S obzirom da je cilj razviti model predviđanja otjecanja na malom slivu od velike je važnosti u svaki redak matrice ulaznog sloja uvrstiti minimalno deset prijašnjih koraka mjerenja što će modelu u procesu treniranja dati uvid u stanje meteoroloških podataka u određenom prethodnom vremenskom periodu. Skriveni sloj čine neuroni koji u procesu treniranja aktivacijskim funkcijama pokreću podatke umnožene s optimizacijskim parametrom iz ulaznog prema izlaznom sloju. Kapacitet treniranja modela ovisi o vrsti aktivacijskih funkcija i broju neurona. Za razvoj hidrološkog modela predviđanja otjecanja na malim slivovima uputno je koristiti minimalno 10 neurona koji posjeduju nelinearne aktivacijske funkcije. Korištenje većeg broja neurona ne mora nužno povećati kvalitetu modela, pa s odabirom broja neurona treba biti oprezan. Povećanje broja neurona, kada je u modelu implementirana značajna količina podataka, može dovesti do usporenja u procesu treniranja. Ne postoji direktno pravilo za odabir broja neurona pa se stoga predlaže da se u početnoj fazi razvoja modela koristi 10 neurona čiji se broj s obzirom na tijek i kvalitetu modela može korigirati.

Odabir odgovarajućeg algoritma treniranja, koji upravlja optimizacijskim koeficijentima umjetne neuronske mreže, je veoma važno iz stajališta efikasnog i brzog treniranja modela. Pri razvoju modela umjetne neuronske mreže koriste se algoritmi prvoga i drugoga reda. Algoritmi drugoga reda se bolje prilagođavaju

nelinearnim problemima koji su prisutni u slučaju razvoja hidroloških modela otjecanja. Levenberg-Marquard algoritam je algoritam drugoga reda te je posebno razvijen za potrebe treniranja umjetnih neuronskih mreža, a karakterizira ga velika brzina i preciznost u prilagodbi nelinearnim problemima. Upravo iz tih razloga za treniranje hidrološkog modela predviđanja otjecanja na malim slivovima predlaže se upotreba Levenberg-Marquardt algoritma.

Nakon definiranja arhitekture modela, algoritma treniranja te odabranog koraka predviđanja potrebno je odabrati programski paket u kojem će se model programirati. Danas je na raspolaganju veliki broj već pripremljenih programskih paketa koji imaju već unaprijed pripremljene arhitekture umjetne neuronske mreže i pridružene algoritme treniranja kod kojih nije moguće imati uvid u cijeli proces rada modela te pojedine elemente nije moguće mijenjati. Stoga je bolje koristiti programske pakete u kojima se može programirati model u cijelosti. Jedan od programskih paketa koji imaju takvu mogućnost je MATLAB (MathWorks) koji ima implementirane zasebne elemente umjetnih neuronskih mreža kao što su vrste i elementi arhitekture, algoritme treniranja, načine treniranja, validacije i evalvacije modela pa se u procesu programiranja modela može definirati svaki element arhitekture zasebno te u potpunosti upravljati modelom. Stoga se preporučuje korištenje ovog programskog paketa ili nekoga koji također ima mogućnosti programiranja.

Nakon što je pripremljen programski kod modela umjetne neuronske mreže u model se implementira skup podataka pripremljen za proces treniranja (70% ukupnih podataka). U procesu treniranja dolazi do promjena optimizacijskog parametra pod utjecajem algoritma treniranja u više iteracija izračuna. Cilj procesa je optimalno treniranje modela u cilju izbjegavanja stanja pretreniranosti koji dovodi do gubitka generalizirajućih svojstava modela. Iako ne postoji jasno definiran način za izračun broja iteracija kroz koje model treba proći da bi bio optimalno treniran jedan od sigurnih načina je da zaustavljanje procesa treniranja nastupa u trenutku kada Suma kvadratne pogreške (SSE) odziva modela naspram mjerenih podataka računata prema izrazu (21) dosegne iznos prilikom kojeg ne dolazi do povećanja sume kvadratne pogreške odziva modela u procesu validacije. Po završetku procesa treniranja hidrološkog modela predviđanja otjecanja prelazi se na procese validacije i evalvacije modela.

## 6. ZAKLJUČCI

Motivacija za izradu disertacije naslova „Razvoj hidrološkog modela otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži,“ temelji se na istraživanju mogućnosti predviđanja štetnih pojava uzrokovanih vodom na malim slivovima u cilju implementacije sustava za rano uzbunjivanje.

U samom uvodu disertacije postavljena su četiri cilja istraživanja. Prvi cilj istraživanja odnosio se na uspostavu kontinuiranih mjerenja meteoroloških i hidroloških podataka na istražnom području sliva Slani potok. Ovaj cilj je ispunjen uspostavom kontinuiranih dvominutnih ( $\Delta t = 2 \text{ minute}$ ) mjerenja meteoroloških podataka postavljanjem dvije automatske meteorološke postaje Vantage Pro 2 proizvođača Davis Instruments Corporation dok je kontinuirano mjerenje hidroloških podataka ostvareno postavljanjem tlačne sonde miniDiver (DI502 – 20m) proizvođača Schlumberg Water Services. Sljedeći cilj istraživanja bio je ispitati mogućnost razvoja hidrološkog modela predviđanja otjecanja na malom slivu, a koji je temeljen na umjetnoj neuronskoj mreži, upotrebom meteoroloških i hidroloških mjerenih podataka. Hidrološki model predviđanja otjecanja na malom slivu razvijen je za istražno područje sliva Slani potok upotrebom umjetne neuronske mreže arhitekture višeslojnog perceptona te treniran upotrebom Levenberg-Marquardt algoritma. Vremenska rezolucija modela je shodno koraku mjerenja podataka definirana dvominutnim korakom ( $\Delta t = 2 \text{ minute}$ ). Ulazni sloj su u modelu činili meteorološki podaci: (i) Količina oborine, (ii) Intenzitet oborine, (iii) Temperatura zraka, (iv) Vlaga zraka, (v) Tlak zraka i (vi) Insolacija u trenutku  $t=0$  zajedno s deset prijašnjih podataka ( $\Delta t = 2 \text{ minute}$ ). Uvođenjem prethodnih meteoroloških podataka u ulaznom sloju omogućilo se modelu uvid u meteorološko uvjete sliva u posljednjih  $\Delta t = 20 \text{ minuta}$ . Izlazni sloj modela činili su hidrološki podaci razine vode u vodotoku za određeni korak predviđanja. Temeljem osnovnog modela, za potrebe predviđanja razvijeni su modeli s tri različita koraka predviđanja: (i) M15 s korakom predviđanja od  $t=30 \text{ minuta}$ , (ii) M30 s korakom predviđanja od  $t=60 \text{ minuta}$  i (iii) M60 s korakom predviđanja od  $t=120 \text{ minuta}$ . Daljnje istraživanje u sklopu disertacije bilo je usmjereno ka definiranju postupaka validacije i evalvacije mogućnosti predviđanja hidrološkog modela otjecanja u svrhu implementacije sustava ranog uzbunjivanja. Provedenom validacijom i evalvacijom modela dokazana je mogućnost

predviđanja otjecanja na malim slivovima uz pomoć hidrološkog modela otjecanja temeljenog na umjetnoj neuronskoj mreži. Rezultati ocjene kvalitete modela su ukazali da je za istražno područje sliva Slani potok moguće predviđati nastanak štetne pojave pod utjecajem bujice, muljnog toka ili debratne poplave, 60 minuta unaprijed. Zadnji cilj prilikom istraživanja u sklopu disertacije bio je usmjeren ka razvoju metodologije implementacije hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži. Ovaj cilj je ostvaren upotunjavanjem općih smjernica za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži tako što su na temelju razvijenog modela u sklopu disertacije utvrđeni detaljniji koraci procedure za implementaciju hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj mreži.

U sklopu rada bile su definirane dvije hipoteze. Hipoteze rada proizašle su iz utvrđenih ciljeva istraživanja u sklopu disertacije. Prva hipoteza rada temeljila se na pretpostavci da je na malim slivovima moguće razviti hidrološki model predviđanja otjecanja upotrebom umjetne neuronske mreže, a koji ima dostatne mogućnosti predviđanja kako bi na slivovima pod utjecajem hidrotehničkog hazarda bilo moguće implementirati sustav ranog uzbunjivanja. Ova hipoteza je potvrđena razvojem hidrološkog modela predviđanja otjecanja na istražnom području sliva Slani potok. Hidrološki model predviđanja otjecanja je razvijen upotrebom umjetne neuronske mreže na prikupljenim podacima hidroloških i meteoroloških mjerenja te validiran i evalviran definiranim mjerama kvalitete modela čime su utvrđene njegove mogućnosti predviđanja. Model je razvijen na, sa hidrološkog stajališta, relativno kratkom periodu mjerenja u kojemu su zabilježene značajne i učestale oborinske epizode te nastanak štetnih pojava. S obzirom na količinu implementiranih podataka u model, njegove mogućnosti predviđanja pokazale su se i više nego zadovoljavajuće. Naime, model izvrsno predviđa 60 minuta unaprijed vrijeme nastupanja podizanja razine vode u vodotoku dok pri prognoziranju maksimalnih razina vode pokazuje odstupanja. U smislu implementacije sustava ranog uzbunjivanja, točno predviđanje vremena podizanja vodnog vala je od velike važnosti pa se stoga može zaključiti da se ovakav model može koristiti u te svrhe. S druge strane, 60 minutno predviđanje na malom slivu dovoljno je za pravovremeno obznanjivanje obavijesti o nastupanju

moгуće štetne pojave te osiguranje prometne infrastrukture pod utjecajem štetne pojave. Kod predviđanja maksimalnih razina vode u razvijenom modelu poboljšanje preciznosti se može očekivati dodatnom implementacijom mjerenih podataka u procesu treniranja modela.

Druga hipoteza rada temeljila se na pretpostavci da je procedura razvoja hidrološkog modela temeljenog na umjetnoj neuronskoj mreži primjenjiva i na drugim malim slivovima, zbog čega je moguće razviti metodologiju za implementaciju hidrološkog modela predviđanja otjecanja s malih slivova, a koji je temeljen na umjetnoj neuronskoj mreži. Ova hipoteza rada potvrđena je definiranjem jasnih koraka postupka kojim je moguće ovakav model primjeniti i na drugim malim slivovima. Postojeća općenita metodologija za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži upotpunjena je preciznim koracima koji su proizašli i razvoja hidrološkog modela predviđanja otjecanja u sklopu disertacije. Naime, precizno definirani koraci metodologije implementacije hidrološkog modela predviđanja otjecanja s malih slivova omogućuju istoznačnu primjenu i na drugim malim slivovima upotrebom umjetne neuronske mreže.

Istraživanja i rezultati koji su obuhvaćeni ovom disertacijom stvorili su motivaciju za buduća istraživanja. S obzirom da je hidrološki model predviđanja otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži, razvijen s ciljem uspostave sustava ranog uzbunjivanja na slivu Slanog potoka, svakako je jedan od budućih ciljeva upotreba modela u tu svrhu. Nadalje, u ovakav hidrološki model predviđanja otjecanja moguće je implementirati i prognostičke materijale vremenske prognoze prilikom čega se može očekivati povećanje mogućnosti predviđanja modela.

U planu je svakako i primjena razvijene metodologije za implementaciju hidrološkog modela predviđanja otjecanja s malih slivova temeljenog na umjetnoj neuronskoj i na drugim malim slivovima s ciljem analize primjenjivosti predložene metodologije.

## 7. LITERATURA

- Abbott, M.B., Bathurst, J.C., Cunge, J.A., O'Connell, P.E. i Rasmussen, J. (1986). *An introduction to the European Hydrological System - Systeme Hydrologique Europeen, "SHE", 1: History and philosophy of a physically-based distributed modelling system i 2: Structure of a physically-based distributed modelling system*, Journal of Hydrology, 87(1), 45-59 i 61-77.
- Abrahart, R., Kneale, P. E. i See, L. M., (Urednici), (2004). *Neural networks for hydrological modelling*, CRC Press.
- Abrahart, R.J. i See, L. (2002). *Multi-model data fusion for river flow forecasting: an evaluation of six alternative methods based on two contrasting catchments*, Hydrology and Earth System Sciences, 6(4), 655-670.
- Aleksander, I. i Morton, H. (1990). *An introduction to neural computing* (Vol. 240), London: Chapman and Hall.
- Aljinović, D., Jurak, V., Mileusnić, M., Slovenec, D. i Presečki, F. (2010). *The origin and composition of flysch deposits as an attribute to the excessive erosion of the Slani Potok valley ("Salty Creek ")*, Croatia, Geologia Croatica, 63(3), 0-0.
- Anderson, M. P. i Woessner, W. W. (1992). *The role of the postaudit in model validation*, Advances in Water Resources, 15(3), 167-173.
- Arnell, N. W. (1999). *A simple water balance model for the simulation of streamflow over a large geographic domain*, Journal of Hydrology, 217(3), 314-335.
- Balada, M. (2014). *An algorithm for nonlinear least squares*, Institute of Thermomechanics, Academy of Science of the Czech Republic, Plzeň, Czech Republic, (interna skripta).
- Barbalić, D. i Rajčić, V. (2003). *Identifikacija vodenih površina na satelitskim snimcima neuralnom mrežom*, Građevinar, (55), 513-518.
- Beale, M. H., Hagan, M. T. i Demuth, H. B. (2004). *Neural network toolbox™ user's guide*, The MathWorks, Inc., 3 Apple Hill Drive Natick, MA 01760-2098.
- Benac, Č. (2016). *Rječnik pojmova u općoj i primjenjenoj geologiji*, Rijeka, Republika Hrvatska: Sveučilište u Rijeci, Građevinski fakultet.
- Benac, Č., Jurak, V., Oštrić, M., Holjević, D. i Petrović, G. (2005). *Pojava prekomjerne erozije u području Slanog potoka (Vinodolska dolina)*, Opatija, Republika Hrvatska: I. Velić, I. Vlahović, R. Biondić (urednici): Knjiga sažetaka 3. Hrvatski geološki kongres, 173-174.
- Bergström, S. i Forsman, A. (1973). *Development of a conceptual deterministic rainfall-runoff model*, Hydrology Research, 4(3), 147-170.
- Beven, K.J. i Kirkby, M.J. (1979). *A physically based, variable contributing area model of basin hydrology*, Hydrological Sciences Bulletin 24: 43-69.
- Blašković, I. (1997). *The Helicoidal Fault Systems of Vinodol (Croatia) and Their Genesis*, Geologia Croatica, 50(1), 49–56.
- Blašković, I. i Tišljar, J. (1983). *Prominske i Jelar naslage u Vinodolu (Hrvatsko primorje) [Promina and Jelar deposits in the Vinodol area – in Croatian]*, Geološki vjesnik, 36, 37–50.
- Box, G.E.P. i Jenkins, G.M. (1970). *Time series analysis forecasting and control*, San Francisco, USA: Holden-day.
- Brutsaert, W. i Mawdsley, J.A. (1976). *The applicability of planetary boundary layer theory to calculate regional evapotranspiration*, Water Resources, 12, 852-858.
- Carević, D., Bekić, D. i Vouk, D. (2008). *Primjena neuralnih mreža za predviđanje vodostaja*, Hrvatske vode, 16(62), 1-5.
- Carriere, P., Mohaghegh, S. i Gaskari, R. (1996). *Performance of a virtual runoff hydrograph system*, Journal of Water Resources Planning and Management, 122(6), 421-427.
- Chow, V.T., Maidment, D.R. i Mays, L.W. (1988). *Applied Hydrology*, McGraw-Hill series in Water Resources.



- Corzo Perez, G.A. (2009). *Hybrid models for hydrological forecasting: Integration of data-driven and conceptual modelling techniques*, Delft, Netherlands: CRC Press/Balkema (Taylor & Francis group).
- Crawford, N.H. i Linsley, R.K. (1966). *Digital simulation in hydrology, Stanford Watershed Model IV*, Stanford, USA: Dept of Civil Engineering, University of California, Technical Report No 39.
- Daniell, T. M. (1991). *Neural networks. Applications in hydrology and water resources engineering, Australia*: In National Conference Publication- Institute of Engineers.
- Dawdy, D.R. i O'Donnell, T. (1965). *Mathematical models of catchment behaviour*, Proceedings of American Society of Civil Engineers: Journal of the Hydraulics Divisions of the ASCE 91(HY4), 123-137.
- Dawson, C.W. i Wilby, R.L. (1999). *A comparison of artificial neural networks used for river flow forecasting*, Hydrology and Earth System Sciences, 3(4), 529-540.
- Dawson, C.W. i Wilby, R.L. (2001). *Hydrological modelling using artificial neural networks*, Progress in physical Geography, 25(1), 80-108.
- Deduš, B. (1994). *Neuralni model upravljanja kanalskim sustavima*, Umag, Republika Hrvatska: Ž-Makvić i F. Vančina (urednici): Zbornik radova: Drugi stručni skup Sekcije za vodoopskrbu i odvodnju, Hrvatsko društvo za zaštitu voda i mora, 149-161.
- Demuth, H.B. i Beale, M.H. (2004). *Neural Network Toolbox™ User's Guide*, The MathWorks, INC.
- Dooge, J.C. (1972). *Mathematical models of hydrologic systems*, Ottawa, Canada: Proceedings of the International Symposium on Modelling Techniques in Water Resources Systems, (1), 171-189.
- Dooge, J.C. (1973). *Linear theory of hydrologic system*, Washington D.C., USA: Technical Buletin No 1468., Agricultural Research Service.
- Dooge, J.C. (1977). *Problems and methods of rainfall-runoff modelling*, London, England: T.A. Ciriani, V. Malone i J.R. Wallis (Urednici): Mathematical models for surface water hydrology, John Wiley and Sons Ltd.
- Eagleson, P.S., Mejia, R. i March, F. (1965). *The computation of optimum realizable unit hydrographs from rainfall and runoff data*, New York, USA: Hydrodynamic Laboratory Report No 84, MIT.1970 Dynamic Hydrology.
- Fernando, D. A. K. i Jayawardena, A. W. (1998). *Runoff forecasting using RBF networks with OLS algorithm*, Journal of hydrologic engineering, 3(3), 203-209.
- Freeze, R.A. (1971). *Three-dimensional, transient, saturated-unsaturated flow in a groundwater basin*, Water Resources, 7(2), 347-366.
- French, M. N., Krajewski, W. F. i Cuykendall, R. R. (1992). *Rainfall forecasting in space and time using a neural network*. Journal of hydrology, 137(1-4), 1-31.
- Gavin, H.P. (2013). *The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems*, Durham, USA: Department of Civil and Environmental Engineering, Duke University, (interna skripta).
- Georgakakos, K.P. (1992). *Advances in forecasting flash floods*, Taipei, Taiwan: Proceedings of the CCNAA-AIT Joint Seminar on Prediction and Damage Mitigation of Meteorologically Induced Natural Disasters, 21–24 May 1992, National Taiwan University, 280–293.
- Govindaraju, R. S. i Rao, A. R., (Urednici), (2013). *Artificial neural networks in hydrology (36)*, Springer Science & Business Media.
- Gupta, H.V., Sorooshian, S. i Yapo, P.O. (1999). *Status of Automatic Calibration for Hydrologic Models: Comparison with Multilevel Expert Calibration*, Journal of Hydrologic Engineering, 4(2), 135-143.
- Hagan, M. T., Demuth, H. B., Beale, M. H. i De Jesús, O. (1996). *Neural network design (20)*, Boston, USA: PWS publishing company.

- Halff, A. H., Halff, H. M. i Azmoodeh, M. (1993). *Predicting runoff from rainfall using neural networks*, Engineering Hydrology, 760-765.
- Hall, M. J. i Minns, A. W. (1993). *Rainfall-runoff modelling as a problem in artificial intelligence: experience with a neural network*, Cardiff, England: BHS 4th National Hydrology Symposium, 5-51.
- Haykin, S. (2004). *Neural Networks: A comprehensive foundation (2)*, Upper Saddle River, NJ, USA: Pearson.
- Haykin, S. (2009). *Neural networks and learning machines (3)*, Upper Saddle River, NJ, USA: Pearson.
- Holjević, D. (1996). *Landslide Slani potok and Mala Dubračina*, Hrvatska vodoprivreda, 43(04/96), 42-44.
- Hrvatske vode, Vodnogospodarski odjel Primorsko-Istarskih slivova (2004a). *Analiza slivnog područja Vinodolske doline: klimatske i hidrološke prilike – radna verzija*, Rijeka, Republika Hrvatska: Stručna dokumentacija, (nepublicirano).
- Hrvatske vode, Vodnogospodarski odjel Primorsko-Istarskih slivova (2004b). *Kartiranje pokrova/korištenja zemljišta na području Vinodolske doline*, Rijeka, Republika Hrvatska: Stručna dokumentacija, (nepublicirano).
- Hrvatski geološki institut (2007). *Geološko- tektonska osnova za studij pojačane erozije u slivu Dubračine*, Zagreb, Republika Hrvatska, Stručna dokumentacija, (nepublicirano).
- <http://www.cactusnav.com/images/ZDAV6152CA.jpg> (rujan 2016).
- [http://www.swstechnology.com/novamatrix/index.php?option=com\\_k2&view=item&id=61:mini-diver&Itemid=220](http://www.swstechnology.com/novamatrix/index.php?option=com_k2&view=item&id=61:mini-diver&Itemid=220) (rujan 2016).
- Hungr, O., Leroueil, S. i Picarelli, L. (2014). *The Varnes classification of landslide types, an update*, Landslides, (11), 167-194.
- Jain, S.K. (2001). *Development of Integrated Sediment rating Curves Using ANNs*, Journal of Hydraulic Engineering, 127(1), 30-37.
- Jurković, J. Goluža, D. Tajić, Z. Ivanković, Šutić, I., Rališ, R.V., Cahun, M. i Sabolić, Đ. (2010). *Idejno rješenje uređenja sliva Slani potok*, Zagreb, Republika Hrvatska: Elaborat, Institut za elektroprivredu i energetiku d.d., (nepublicirano).
- Kalman, R.E., (1960). *A new approach to linear filtering and prediction problems*, Journal of basic Engineering, 82(1), 35-45.
- Karunanithi, N., Grenney, W. J., Whitley, D. i Bovee, K. (1994). *Neural networks for river flow prediction*, Journal of Computing in Civil Engineering, 8(2), 201-220.
- Krzhizhanovskaya, V. V., Shirshov, G. S., Melnikova, N. B. i sur. (2011). *Flood early warning system: design, implementation and computational modules*, Procedia Computer Science, (4), 106-115.
- Kuichling, E. (1889). *The relation between the rainfall and the discharge of sewers in populous districts*, Transactions of the American Society of Civil Engineers, 20(1), 1-56.
- Legates, D. R. i McCabe, G. J. (1999). *Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation*, Water resources research, 35(1), 233-241.
- Maier, H. R. i Dandy, G. C. (2001). *Neural network based modelling of environmental variables: a systematic approach*, Mathematical and Computer Modelling, 33(6), 669-682.
- Maier, H.M., Jain, A., Dandy, G.C. i Sudheer, K.P. (2010). *Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions*, Environmental Modelling & Software, 25, 891-909.
- Maier, H.R. i Dandy, G.C. (2000). *Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications*, Environmental Modelling & Software, 15, 101-124.

- Maren, A. J. (1991). *A logical topology of neural networks*, Auburn, Alabama: Proceedings of the Second Workshop on Neural Networks, Academic/Industrial/NASA/Defense, Auburn University.
- Marquardt, D. W. (1963). *An algorithm for least-squares estimation of nonlinear parameters*, Journal of the society for Industrial and Applied Mathematics, 11(2), 431-441.
- Mason, J.C., Tem'ne, A. i Price, R.K. (1996). *A neural network model of rainfall-runoff using radial basis functions*, Journal of Hydraulic Reseach, 34(4), 537-548.
- Matić, P. (2014). *Kratkoročno predviđanje hidrološkog dotoka pomoću umjetne neuronske mreže*, Split, Hrvatska: Sveučilište u Splitu, Fakultet Elektrotehnike strojarstva i brodogradnje u Splitu, Doktorski rad, (nepublicirano).
- Matičec, D., Fuček, L. i Palenik, D. (2007). *Geološko-tektonska osnova za studij pojačane erozije u slivu Dubračine*, Zagreb, Hrvatska: Hrvatski geološki institute, (nepublicirano).
- McCulloch, W. S. i Pitts, W. (1943). *A logical calculus of the ideas immanent in nervous activity*, The bulletin of mathematical biophysics, 5(4), 115-133.
- Mileusnić, M., Slovenec, D. i Jurak, V. (2004). *Thenardite- efflorescence indicating cause of the excessive flysch erosion, Slani Potok, Croatia*, Acta Mineralogica-Petrographica, Abstract Series, Szeged, 75-75.
- Minns, A. W. i Hall, M. J. (1996). *Artificial neural networks as rainfall-runoff models*, Hydrological sciences journal, 41(3), 399-417.
- Minski, M. L. i Papert, S. A. (1969). *Perceptrons: an introduction to computational geometry*, Cambridge, England: MA: MIT Press.
- Moldan, B. i Černy, J. (1994). *Biogeochemistry of Small Catchments: A Tool fo Enviromental Research*, Chichester, UK: John Wiley & Sons Ltd.
- Moradkhani, H. i Sorooshian, S. (2009). *General review of rainfall-runoff modeling: model calibration, data assimilation, and uncertainty analysis*, Hydrological modelling and the water cycle, Springer Berlin Heidelberg, 1-24.
- Morel Seytoux, H. J. (1978). *Derivation of equations for variable rainfall infiltration*, Water Resources Research, 14(4), 561-56.
- Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D. i Veith, T.L. (2007). *Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations*, Transactions of the ASABE (American Society of Agricultural and Biological Engineers), 50(3), 885-900.
- Mulvaney, T. J. (1851). *On the use of self-registering rain and flood gauges in making observations of the relations of rainfall and flood discharges in a given catchment*, Proceedings of the institution of Civil Engineers of Ireland, 4(2), 18-33.
- Natale, L. i Todini, E., (1977). *A constrained parameter estimation technique for linear models in hydrology*, New York, USA: Ciridni, T.A. i sur. (Urednici): Mathematical models for Surface Water Hydrology, Wiley.
- Norbiato, D., Borga, M., Esposti, S., Gaume, E. i Anquetin, S. (2008). *Flash flood warning based on rainfall thresholds and soil moisture conditions: an assessment for gauged and ungauged basins*, Journal of Hydrology, 362(3-4), 274-290.
- Papa, M.N., Medina, V., Ciervo, F. i Bateman, A. (2013). *Derivation of critical rainfall thresholds for shallow landslides as a tool for debris flow early warning system*, Hydrology and Eart System Science, (17), 4095-4107.
- Rabi, A., Hadzima-Nyarko, M. i Šperac, M. (2015). *Modelling river temperature from air temperature: case of the River Drava (Croatia)*, Hydrological sciences journal, 60(9), 1490-1507.
- Refsgaard, J. C. i Abbott, M. B. (Urednici). (1996). *Distributed hydrological modelling*, Kluwer Academic.

- Rosenblatt, F. (1957). *The perceptron, a perceiving and recognizing automaton Project Para*, Cornell Aeronautical Laboratory.
- Rubinić, A. (2010). *Hidrologija sliva Dubračine*, Rijeka, Hrvatska: Sveučilište u Rijeci, Građevinski fakultet, Zbornik radova Građevinskog fakulteta, 13, 33-68.
- Rubinić, J. (2014). *Water Regime of Vransko Lake in Dalmatia and Climate Impacts*, Rijeka, Hrvatska: Sveučilište u Rijeci, Građevinski fakultet, Doktorski rad (nepublicirano).
- Rumelhart, D. E., Hinton, G.E. i Williams R.J. (1986). *Learning representations by back-propagating errors*, Nature, 323, 533-536.
- Ružić I., Sušanjanj I. i Ožanić N. (2010). *Analyses of event runoff coefficients: Slani potok and Dubračina river*, Dubrovnik, Hrvatska: Croatia–Japan Project on Risk Identification And Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia: 1st project workshop: „INTERNATIONAL EXPERIENCE“.
- Ružić, I. Sušanjanj, I., Ožanić, N. i Žic, E. (2011). *Otjecanja sa sliva Slanog potoka i izvora rijeke Dubračine na području Vinodolske doline*, Zagreb, Hrvatska: D. Biondić, D. Holjević, L.J. Tropan (Urednici): Znanstveni skup: Hrvatske vode pred izazovom klimatskih promjena, Hrvatske vode, 226-237.
- Shamseldin, A.Y. i O'Connor, K.M. (2001). *A non-linear neural network technique for updating of river flow forecasts*, Hydrology and Earth System Sciences, 6(4), 671-684.
- Sherman, L.K. (1932). *Streamflow from rainfall by the unit-graph method*, Engineering News Record, 108, 501-505.
- Singh, V.P. (1988). *Hydrologic Systems, Volume 1: Rainfall-runoff modelling*, New Jersey, USA: Prentice Hall.
- Šperac, M. (2004). *Upotrebljivost neuralnih mreža za određivanje otjecanja u sustavu urbane odvodnje*, Zagreb, Hrvatska: Sveučilište u Zagrebu, Građevinski fakultet, doktorski rad, (nepublicirano).
- Srebrenović, D. (1986). *Primenjena hidrologija*, Zagreb, Hrvatska: Tehnička knjiga.
- Sušanj, I., Dragičević, N., Karleuša, B. i Ožanić, N. (2013). *Gis based monitoring database for dubračina river catchment area as a tool for mitigation and prevention of flash flood and erosion*, Bratislava, Slovakia: Šoltész, A., Baraková, D., Orfánus, M. i Holubec, M. (Urednici): Book of proceedings: Thirteenth International Symposium on water management and hydraulic engineering, 637-652.
- Sušanj, I., Ožanić, N., i Marović, I. (2016). *Methodology for developing hydrological models based on an artificial neural network to establish an early warning system in small catchments*, Advances in Meteorology, 2016, 0-14.

---

## POPIS TABLICA

<b>NAZIV TABLICE:</b>	<b>str.:</b>
TABLICA 1. <i>Kronološki pregled razvoja hidroloških modela kroz povijest.....</i>	26
TABLICA 2. <i>Primjeri prvih matematičkih modela i njihovih autora.....</i>	28
TABLICA 3. <i>Osnovne značajke opažanja na klimatološkim i oborinskim postajama u slivu Dubračine i okolici.....</i>	57
TABLICA 4. <i>Kronološki pregled geoloških, inženjerskogeoloških, hidrogeoloških i geomehaničkih istraživanja na slivu Slanog potoka; izračeno prema Jurković i sur. (2010).....</i>	68
TABLICA 5. <i>Foto dnevnik stanja sliva i vodotoka Slanog potoka 2012. Godine; autor fotografija: Ivana Sušan.....</i>	78
TABLICA 6. <i>Mjere kvalitete modela te njihove granice za ocjenu kvalitete; Izradila: Ivana Sušan prema Morisai i sur. (2007), Matić (2014) i Žugaj (2000).....</i>	99
TABLICA 7. <i>Odabrane numeričke mjere kvalitete modela za proces validacije i evalvacije modela.....</i>	100
TABLICA 8. <i>Statistička obrada meteoroloških varijabli koje čine ulazne varijable modela...</i>	102
TABLICA 9. <i>Statistička obrada hidrološke varijable koja čini izlaznu varijablu modela.....</i>	107
TABLICA 10. <i>Podjela podataka za proces treniranja, validacije i evalvacije za modele.....</i>	111
TABLICA 11. <i>Broj iteracija u procesu optimalnog treniranja modela.....</i>	114
TABLICA 12. <i>Rezultati numeričke analize kvalitete modela u procesu validacije za modele M15, M30 i M60.....</i>	123
TABLICA 13. <i>Rezultati numeričke analize kvalitete modela apsolutnim mjerama u procesu evalvacije za modele M15, M30 i M60.....</i>	126
TABLICA 14. <i>Rezultati numeričke analize kvalitete modela apsolutnim mjerama u procesu evalvacije za modele M15, M30 i M60.....</i>	127
TABLICA 15. <i>Rezultati numeričke analize kvalitete modela primjenom srednje apsolutne pogreške na postotne razrede podataka.....</i>	128

## POPIS SLIKA

<b>NAZIV SLIKE:</b>	<b>str.:</b>
SLIKA 1. <i>Prikaz primjera bujice (autor: Ivana Sušanjanj).....</i>	9
SLIKA 2. <i>Prikaz primjera muljnog toka (autor: Ivana Sušanjanj).....</i>	10
SLIKA 3. <i>Prikaz primjera debratne poplave 1 (autor: Ivana Sušanjanj).....</i>	11
SLIKA 4. <i>Prikaz primjera debratne poplave 2 (autor: Ivana Sušanjanj).....</i>	11
SLIKA 5. <i>Elementi sustava ranog uzbunjivanja; prikaz izradila: Ivana Sušanjanj prema (UN/ISDR, 2009).....</i>	13
SLIKA 6. <i>Sliv kao hidrološki sustav; prikaz izradila: Ivana Sušanjanj prema Chow i dr. (1988).....</i>	16
SLIKA 7. <i>Shematski prikaz razlike topografskog i utjecajnog sliva tloctno i presjekom A--A; prikaz izradila: Ivana Sušanjanj prema Žugaj (2000).....</i>	18
SLIKA 8. <i>Čimbenici koji utječu na otjecanje sa sliva; prikaz izradila: Ivana Sušanjanj prema Žugaj (2000).....</i>	19
SLIKA 9. <i>Klasifikacija hidroloških modela otjecanja; prikaz izradila: Ivana Sušanjanj prema Singh (1988).....</i>	27
SLIKA 10. <i>Podjela simboličkih matematičkih modela; prikaz izradila: Ivana Sušanjanj prema Singh (1988).....</i>	29
SLIKA 11. <i>Glavni koraci metodologije razvoja hidrološkog modela; prikaz izradila: Ivana Sušanjanj prema Singh (1988).....</i>	30
SLIKA 12. <i>Dijagram toka metodologije za razvoj hidrološkog modela; modificirani prikaz izradila: Ivana Sušanjanj prema Refsgaard (1996).....</i>	31
SLIKA 13. <i>Model umjetnog neurona (<math>x_{1,2,3...m}</math>-ulazni podaci u neuron, <math>w_{1,2,3...m}</math>- vrijednost optimizacijskog parametra, <math>v_k</math>- suma umnožaka ulaznih podataka i optimizacijskog parametra (težinska veza) u <math>k</math>-tom koraku računanja, <math>\phi(v_k)</math> – linearna, ograničena linearna, unipolarna sigmoidalna ili bipolarna sigmoidalna aktivacijska funkcija neurona u <math>k</math>-tom koraku računanja, <math>o_k</math> – odziv neurona u <math>k</math>-tom koraku računanja); prikaz izradila: Ivana Sušanjanj prema Haykin (2009) i Matić (2014).....</i>	33
SLIKA 14. <i>Aktivacijske funkcije umjetnog neurona; a) linearna, b) ograničena linearna, c) unipolarna sigmoidalna, d) bipolarna sigmoidalna (Matić, 2014).....</i>	34
SLIKA 15. <i>Arhitektura umjetne neuronske mreže; prikaz izradila: Ivana Sušanjanj prema Abarhart i sur. (2004).....</i>	35
SLIKA 16. <i>Podjela algoritama za izračunavanje mjere promjene <math>\Delta w</math> za izračun optimizacijskog parametara <math>w_k</math> umjetne neuronske mreže (UNM); prikaz izradila: Ivana Sušanjanj prema Demuth, (2004) i Haykin (2004).....</i>	39
SLIKA 17. <i>Metodologija za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži; modificirani prikaz izradila: Ivana Sušanjanj prema Dawson i Wilby (2001).....</i>	47
SLIKA 18. <i>Metodologija za razvoj hidroloških modela temeljenih na umjetnoj neuronskoj mreži; modificirani prikaz izradila: Ivana Sušanjanj prema Maier i sur. (2010).....</i>	48
SLIKA 19. <i>Situacijski položaj sliva Dubračine; prikaz izradila: Ivana Sušanjanj na topografskoj podlozi.....</i>	50
SLIKA 20. <i>Situacijski prikaz sliva Slanog potoka; prikaz izradila: Ivana Sušanjanj na topografskoj podlozi.....</i>	51
SLIKA 21. <i>Prikaz sliva Slanog potoka; prikaz izradila: Ivana Sušanjanj na ortofotografskoj podlozi.....</i>	52

---

SLIKA 22.	<i>Pregledna geološka karta sliva rijeke Dubračine; Hrvatski geološki institut (2007).....</i>	54
SLIKA 23.	<i>Prikaz sliva Slanog potoka na geološkoj karti Hrvatski geološki institut (2007); prikaz izradila: Ivana Sušan.....</i>	54
SLIKA 24.	<i>Prikaz granica sliva Slanog potoka i granica žarišta erozije na digitalnom elevacijskom modelu; prikaz izradila: Ivana Sušan.....</i>	55
SLIKA 25.	<i>Fotografija žarišta erozije na slivu Slanog potoka; autor fotografije: Ivana Sušan.....</i>	55
SLIKA 26.	<i>Fenomen eflorescencije na području žarišta erozije na slivu Slanog potoka; autor fotografije: Ivana Sušan.....</i>	56
SLIKA 27.	<i>Prikaz srednjih godišnjih oborina (1961.-1990.); prema Hrvatskim vodama VGO Rijeka (2004a).....</i>	58
SLIKA 28.	<i>Prikaz srednjih godišnjih temperatura zraka (1961.-1990.); prema Hrvatskim vodama VGO Rijeka (2004a).....</i>	58
SLIKA 29.	<i>Hod srednjih godišnjih količina oborina za postaju Crikvenica (1892. – 2007.); prema Hrvatskim vodama VGO Rijeka (2004a).....</i>	59
SLIKA 30.	<i>Godišnji hod srednjih mjesečnih temperatura zraka i oborina za postaju Crikvenica (1892. – 2007.); prema Hrvatskim vodama VGO Rijeka (2004a).....</i>	59
SLIKA 31.	<i>Pokrov/korištenje zemljišta Vinodolske doline (Hrvatske vode, 2004b).....</i>	61
SLIKA 32.	<i>Rezultati analize digitalnog elevacijskog modela prostorne raspodjele pada sliva (Ružić i sur., 2011).....</i>	63
SLIKA 33.	<i>Rezultati analize digitalnog elevacijskog modela raspodjele nadmorske visine sliva (Ružić i sur., 2011).....</i>	64
SLIKA 34.	<i>Stanje vodoprivrednih objekata u slivu bujice Slani potok i Mala Dubračina (Andrija Lušičić).....</i>	67
SLIKA 35.	<i>Situacijski prikaz postavljenih instrumenata na području sliva Slani potok; prikaz izradila: Ivana Sušan na ortofotografskoj podlozi.....</i>	72
SLIKA 36.	<i>Tlačna sonda tipa miniDiver (DI502 – 20m) proizvođača Schlumberg Water Services (www.swstechnology.com).....</i>	73
SLIKA 37.	<i>Mjerni profil postavljene tlačne sonde tipa miniDiver (DI502 – 20m); autor fotografije: Ivana Sušan.....</i>	74
SLIKA 38.	<i>Meteorološka postaja Vantage Pro 2 proizvođača Davis Instruments Corporation: unutarnji i vanjski dio instrumenta; (www.cactusnav.com).....</i>	75
SLIKA 39.	<i>Položaj postavljenih automatskih meteoroloških postaja: a) Kamenjak i b) Mjesno groblje Belgrad; autor fotografija: Ivana Sušan.....</i>	76
SLIKA 40.	<i>Situacijski prikaz položaja fotografiranja stanja sliva Slanog potoka; prikaz izradila: Ivana Sušan na ortofotografskoj podlozi.....</i>	77
SLIKA 41.	<i>Zabilježene pojave: a) Muljni tok (29.07.2014.); b) Bujični tok (21.08.2014.) i c) Debritna poplava (21.08.2014.) na nizvodnom dijelu vodotoka Slani potok (Pelićev most); autor fotografija: Ivana Sušan.....</i>	79
SLIKA 42.	<i>Zabilježena oštećenja: a) Oštećenje kolničke trase na Pelićevom mostu (21.08.2014); b) Oštećenje kolnika na lokalnoj cesti Belgrad-Rupe (3.3.2015) i c) Lokalno klizište na rubu žarišta erozije ispod lokalne ceste Belgrad-Kamenjak (3.3.2015); autor fotografija: Ivana Sušan.....</i>	80
SLIKA 43.	<i>Model višeslojnog perceptrona; prikaz izradila: Ivana Sušan prema Abrahart i sur. (2004).....</i>	82

---



---

SLIKA 44.	<i>Promjena LM algoritma s obzirom na promjenu kombinacijskog koeficijenta <math>\mu</math>; prikaz izradila: Ivana Sušan prema Matić (2014).....</i>	89
SLIKA 45.	<i>Koraci postupka primjene LM algoritma u treniranju mreže višeslojnog perceptrona.....</i>	91
SLIKA 46.	<i>Podjela numeričkih mjera kvalitete modela; prikaz izradila: Ivana Sušan prema Abraham i sur. (2004); Matić, (2014); Govindaraju i Ramachandra Rao (2000)....</i>	92
SLIKA 47.	<i>Prikaz mjerenja kumulativne količine oborina za meteorološku postaju Belgrad.....</i>	103
SLIKA 48.	<i>Prikaz mjerenja količine oborina u dvominutnom koraku vremena za meteorološku postaju Belgrad.....</i>	103
SLIKA 49.	<i>Prikaz mjerenja intenziteta oborina u dvominutnom koraku vremena za meteorološku postaju Belgrad.....</i>	104
SLIKA 50.	<i>Prikaz mjerenja temperature zraka u dvominutnom koraku vremena za meteorološku postaju Belgrad.....</i>	104
SLIKA 51.	<i>Prikaz mjerenja vlažnosti zraka u dvominutnom koraku vremena za meteorološku postaju Belgrad.....</i>	105
SLIKA 52.	<i>Prikaz mjerenja tlaka zraka u dvominutnom koraku vremena za meteorološku postaju Belgrad.....</i>	106
SLIKA 53.	<i>Prikaz mjerenja sunčane radijacije (insolacija) u dvominutnom koraku vremena za meteorološku postaju Belgrad.....</i>	106
SLIKA 54.	<i>Prikaz mjerenja razine vode u dvominutnom koraku vremena za meteorološku postaju Belgrad.....</i>	108
SLIKA 55.	<i>Shematski prikaz arhitekture modela umjetne neuronske mreže (<math>X_{1,2,3...m}</math>-ulazni podaci u neuron, <math>w_{1,2,3...m}</math> - vrijednost optimizacijskog parametra, <math>v_k</math>- suma umnožaka ulaznih podataka i optimizacijskog parametra u k-tom koraku računanja, <math>o_k</math> – odaziv neurona u k-tom koraku računanja, <math>d_k</math> –mjereni podaci).....</i>	109
SLIKA 56.	<i>Arhitektura modela; a) Model M15 predviđanja 30 minuta, b) Model M30 predviđanja 60 minuta, c) Model M60 predviđanja 120 minuta (<math>X_{1,2,3...m}</math> -ulazni podaci u neuron, <math>w_{1,2,3...m}</math> - vrijednost optimizacijskog parametra, <math>v_k</math>- suma umnožaka ulaznih podataka i optimizacijskog parametra u k-tom koraku računanja, <math>o_k</math> – odaziv neurona u k-tom koraku računanja, <math>d_k</math> –mjereni podaci).....</i>	110
SLIKA 57.	<i>Prikaz podjele ulaznih varijabli za model M15 (Količina oborine, Intenzitet oborine i Temperatura zraka) na skupove za treniranje, validaciju i evalvaciju modela.....</i>	112
SLIKA 58.	<i>Prikaz podjele ulaznih varijabli za model M15 (Tlak zraka, Vlažnost zraka i Solarna radijacija) na skupove za treniranje, validaciju i evalvaciju modela.....</i>	113
SLIKA 59.	<i>Prikaz podjele izlazne varijable za model M15 (Razina vode u vodotoku) na skupove za treniranje, validaciju i evalvaciju modela.....</i>	114
SLIKA 60.	<i>Prikaz odziva modela M15 u procesu treniranja u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	115
SLIKA 61.	<i>Prikaz analize linearne regresije mjerenih podataka razine vode te odziva modela M15.....</i>	116
SLIKA 62.	<i>Prikaz procesa optimalnog treniranja modela M15 kroz broj iteracija u ovisnosti o sumi kvadratne pogreške (SSE) i validaciji.....</i>	116
SLIKA 63.	<i>Prikaz odziva modela M30 u procesu treniranja u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	117

---

---

SLIKA 64.	<i>Prikaz analize linearne regresije mjerenih podataka razine vode te odziva modela M30.....</i>	118
SLIKA 65.	<i>Prikaz procesa optimalnog treniranja modela M30 kroz broj iteracija u ovisnosti o sumi kvadratne pogreške (SSE) i validaciji.....</i>	118
SLIKA 66.	<i>Prikaz odziva modela M60 u procesu treniranja u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	119
SLIKA 67.	<i>Prikaz analize linearne regresije mjerenih podataka razine vode te odziva modela M60.....</i>	120
SLIKA 68.	<i>Prikaz procesa optimalnog treniranja modela M60 kroz broj iteracija u ovisnosti o sumi kvadratne pogreške (SSE) i validaciji.....</i>	120
SLIKA 69.	<i>Prikaz odziva modela M15 u procesu validacije u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	121
SLIKA 70.	<i>Prikaz odziva modela M30 u procesu validacije u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	122
SLIKA 71.	<i>Prikaz odziva modela M60 u procesu validacije u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	122
SLIKA 72.	<i>Prikaz odziva modela M15 u procesu evalvacije u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	124
SLIKA 73.	<i>Prikaz odziva modela M30 u procesu evalvacije u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	125
SLIKA 74.	<i>Prikaz odziva modela M60 u procesu evalvacije u usporedbi s mjerenim podacima i prikazom pogreške.....</i>	126
SLIKA 75.	<i>Prikaz raspodjele mjerenih podataka u postotne razrede.....</i>	128
SLIKA 76.	<i>Dijagram toka metodologije za implementaciju hidrološkog modela otjecanja na malim slivovima temeljenog na umjetnoj neuronskoj mreži.....</i>	135
SLIKA 77.	<i>Dijagram toka implementacije umjetne neuronske mreže.....</i>	143

---

## POPIS KRATICA

KRATICA	ZNAČENJE (Hrvatski jezik)	IZVORNI ILI MEĐUNARODNI NAZIV
$cm^2$	Četvorni centimetar	Square centimeter
°C	Stupanj Celzijusa	Degrees Fahrenheit
ARMA	Modeli autoregresivnog pomičnog prosjeka	Autoregressive Integrated Moving Average
BFGS	Broyden–Fletcher–Goldfarb–Shanno	Broyden–Fletcher–Goldfarb–Shanno
BP	Algoritam Propagacije Pogreške Unatrag	Error Backpropagation
CE	Koeficijent učinkovitosti	Coefficient of Efficiency
$CE_b$	Modificirani Koeficijent Učinkovitosti	Modified Coefficient of Efficiency
CG	Konjugirani Gradijent	Conjugate Gradient
cm	Centimetar	Centimeter
DEM	Digitalni Elevacijski Model	Digital Elevation Model
EU	Europska Unija	European Union
GIS	Geografsko Informacijskom Sustav	Geographic Information System
GN	Gauss- Newton	Gauss- Newton
GRNN	Opće Regresijske Neuronske Mreže	Generalized Regression Neural Networks
HBV	/	Hydrologiska Byråns Vattenbalansavdelning
JICA	Japanska Međunarodna Agencija za Suradnju	Japan International Cooperation Agency
LM	Levenberg-Marquardt	Levenberg-Marquardt
<i>m n.m.</i>	Metara nad morem	Meters above sea level
M15	Model koraka predviđanja $\Delta t=30$ minuta	/
M30	Model koraka predviđanja $\Delta t =60$ minuta	/
M60	Model koraka predviđanja $\Delta t =120$ minuta	/
MAE	Srednja apsolutna pogreška	Mean Absolute Error
Max.	Maksimum	Maximum
Min.	Minimum	Minimum
MLP	Višeslojni Perceptron	Multilayer Perceptron
mm	Milimetar	Millimeters
mm/h	Milimetar na sat	Millimeters per hour
mmHg	Milimetar živina stupca	Millimeter of Mercury
MS4E	Srednja pogreška četvrtog reda	Mean Higher-order error
MSE	Srednja kvadratna pogreška	Mean Squared Error
MSRE	Srednja kvadratna relativna pogreška	Mean Squared Relative Error
PBIAS	Postotno odstupanje	Percentage to BIAS

---

<i>PI</i>	<i>Indeks dosljednosti</i>	<i>Persistence index</i>
<i>RBF</i>	<i>Mreža Radijalne Baze</i>	<i>Radial Basis Function</i>
<i>RMSE</i>	<i>Korijen srednje kvadratne pogreške</i>	<i>Root Mean Squared Error</i>
<i>RSR</i>	<i>Omjer Srednje kvadratne pogreške i standardne devijacije</i>	<i>Root Mean Squared Error to Standard deviation</i>
<i>SHE</i>	<i>Europski Hidrološki Sustav</i>	<i>The Système Hydologique Européen</i>
<i>SOM</i>	<i>Samo-organizirajuća Mapa</i>	<i>Self-Organising Map</i>
<i>SSE</i>	<i>Suma kvadratne pogreške</i>	<i>Sum Squared Error</i>
<i>SVM</i>	<i>Vektorsko Upravljanje Strojivima</i>	<i>Support Vector Machines</i>
<i>TNN</i>	<i>Vremenske Neuronske Mreže</i>	<i>Temporal Neural Networks</i>
<i>UN/ISDR</i>	<i>Strategija Ujedinjenih Nacija za Smanjenje Rizika od Katastrofa</i>	<i>United Nations International Strategy for Disaster Reduction</i>
<i>UNM</i>	<i>Umjetna Neuronska Mreža</i>	<i>Artificial Neural Network (ANN)</i>
<i>VGO</i>	<i>Vodno Gospodarski Odjel</i>	<i>/</i>
<i>W/m<sup>2</sup></i>	<i>Watta po četvornom metru</i>	<i>Watt per square meter</i>
<i>WEKA</i>	<i>/</i>	<i>Waikato Environment for Knowledge Analysis</i>
<i>WMO</i>	<i>Svjetska Meteorološka Organizacija</i>	<i>World Meteorological Organization</i>

---

## POPIS SIMBOLA

SIMBOL	ZNAČENJE
$(w_k)_n$	Vrijednost $n$ -te komponente vektora optimizacijskog parametra u $k$ -tom koraku računanja
$(x_k)_n$	Vrijednost $n$ -te komponente vektora ulaznih podataka u neuron u $k$ -tom koraku računanja
$(\nabla^2 E(w))^{-1}$	Parcijalna derivacija drugog reda pogreške po podesivim parametrima mreže
$(\varphi^j(v_k^j))'$	Vrijednost derivacije aktivacijske funkcije $j$ -tog neurona za vrijednost $v_k^j$
$\frac{\partial^2 E}{\partial w_n^2}$	Parcijalna derivacija drugog reda pogreške po podesivim parametrima mreže
$\frac{\partial E_k}{\partial w_k}$	Parcijalna derivacija pogreške po podesivim parametrima u $k$ -tom koraku računanja
$\frac{\partial E_k^j}{\partial w_k^j}$	Parcijalna derivacija pogreške $j$ -tog neurona po podesivim parametrima u $k$ -tom koraku računanja
$J^T$	Transponirana Jakobijeva matrica
$\bar{d}$	Srednja vrijednost željenog odziva mreže
$d_b$	Indeks kompatibilnosti
$d_k$	Srednja vrijednost željenog odziva mreže
$d_{k-1}$	Željeni odziv mreže u $k - 1$ koraku računanja
$d_k^j$	Željeni odziv $j$ -tog neurona mreže višeslojnog perceptrona u $k$ -tom koraku računanja
$e_k$	Pogreška mreže višeslojnog perceptrona u $k$ -tom koraku računanja
$e_k^j$	Pogreška $j$ -tog neurona mreže višeslojnog perceptrona u $k$ -tom koraku računanja
$\bar{o}$	Srednja vrijednost odziva neurona mreže
$o_k$	Odziv neurona u $k$ -tom koraku računanja
$o_k^j$	Odziv $j$ -tog neurona mreže višeslojnog perceptrona u $k$ -tom koraku računanja
$r^2$	Koeficijent određenosti
$v_k$	Suma umnožaka ulaznih podataka $x_k$ i težinskih koeficijenata $w_k$ u $k$ -tom koraku računanja
$v_k^j$	Suma umnožaka ulaznih podataka $x_k$ i težinskih koeficijenata $w_k$ u $k$ -tom koraku računanja u $j$ -ti neuron
$w_k$	Optimizacijski parametar u $k$ -tom koraku računanja
$w_{k+1}$	Optimizacijski parametar u $k+1$ koraku računanja
$x_k$	Vrijednost ulaznih podataka u neuron u $k$ -tom koraku računanja
$\bar{x}$	Srednja vrijednost
$\delta_k^j$	Lokalni gradijent za $j$ -ti neuron mreže višeslojnog perceptrona u $k$ -tom koraku računanja

$\frac{\partial e_1}{\partial w_1}$	Derivacija vektora pogreške po podesivim parametrima mreže
$\frac{\partial E}{\partial w}$	Parcijalna derivacija pogreške po podesivim parametrima mreže
$\Delta w_k$	Mjera promjene u k-tom koraku računanja
$\Delta w_{k-1}$	Mjera promjene u k-1 koraku računanja
$\Delta w_k^j$	Mjera promjene j-tog neuronu k-tom koraku računanja
$\Delta w$	Mjera promjene
MSRE	Srednja kvadratna relativna pogreška
PBIAS	Postotno odstupanje
RSR	Omjer Srednje kvadratne pogreške i standardne devijacije
H	Hessian matrica zakrivljenosti površine prostora pogreške
I	Jedinična matrica
J	Jacobijeva matrica derivacije vektora pogreške po podesivim parametrima mreže
e	Vektor pogreške
A	Površina sliva
CE	Koeficijent učinkovitosti
D	Gustoća drenske mreže
E(e)	Suma kvadrata funkcije pogreške
K	Koeficijent koncentriranosti
L	Duljina glavnog vodotoka
MAE	Srednja apsolutna pogreška
MS4E	Srednja pogreška četvrtog reda
MSE	Srednja kvadratna pogreška
O	Opseg sliva
PI	Indeks dosljednosti
RMSE	Korijen srednje kvadratne pogreške
SSE	Suma kvadratne pogreške
U	Udaljenost od težišta sliva do protjecajnog mjernog profila
d	Indeks podudarnosti
n	Broj mjerenih podataka
$\nabla E(w)$	Parcijalna derivacija pogreške po podesivim parametrima mreže
$\alpha$	Moment za smanjenje ili povećanje mjere promjene $\Delta w$ [-1,1]
$\eta$	Bezdimenzionalna veličina koja definira intenzitet promjene parametra (brzina učenja)
$\mu$	Kombinacijski koeficijent Levenberg-Marquardt algoritma
$\sigma$	Standardna devijacija
$\varphi(v_k)$	Aktivacijska funkcija neurona

## ŽIVOTOPIS

Ivana Sušan rođena je u Rijeci 15.2.1985. godine te od tada živi u gradu Kastvu. Osnovnoškolsko obrazovanje završava u Kastvu 1999. godine, a srednjoškolsko obrazovanje ostvaruje u Rijeci gdje pohađala Prvu Riječku Hrvatsku Gimnaziju te potom 2003. godine upisuje Građevinski fakultet Sveučilišta u Rijeci. Sveučilišni dodiplomski studij hidrotehničkog usmjerenja završava 2009. godine izradom diplomskog rada iz kolegija Hidraulika naslova „Model rušenja nasute brane“ pod mentorstvom prof.dr.sc. Gorana Gjetvaja.

Za vrijeme pohađanja studija prima državnu stipendiju za uspješne studente te potom i stipendiju Hrvatskih voda. Na zadnjoj godini studija od svibnja 2008. do lipnja 2009. godine honorano radi u projektnoj grupi Hrvatskih voda VGO Rijeka kao suradnik na projektima.

Po završetku studija 2009. godine se zapošljava na Građevinskom fakultetu Sveučilišta u Rijeci u svojstvu asistenta a potom u travnju 2011. godine upisuje poslijediplomski sveučilišni studij građevinarstva smjera hidrotehnike priobalnih područja te postaje znanstveni novak u suradničkom zvanju asistenta na bilateralnom hrvatsko-japanskom znanstvenom projektu: *„Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje nepogoda kod odrona zemlje i poplava u Hrvatskoj“* (voditelj projekta: prof.dr.sc. Nevenka Ožanić). Kao asistent održavala je vježbe iz kolegija s područja hidrotehnike a koji su: Gospodarenje vodama, Vodoopskrba i kondicioniranje, Gospodarenje otpadom, Hidrotehničke građevine, Hidrologija, Regulacije i melioracije i Inženjerska hidrologija na preddiplomskom i diplomskom sveučilišnom studiju te kolegije Instalacije i Vodogradnje na preddiplomskom stručnom studiju.

U sklopu istraživanja za potrebe izrade disertacije provela je sveukupno 5 mjeseci, u nekoliko navrata u 2011 i 2012 godini, na Sveučilištu u Kyotu (Japan), u Institutu za istraživanje sprečavanja katastrofa (*eng. Disaster Prevention Research Institute, Kyoto University*).

Kao istraživač sudjeluje na znanstveno istraživačkim projektima kao što su: Bilateralni hrvatsko-japanski znanstveni projekt: *„Identifikacija rizika i planiranje korištenja zemljišta za ublažavanje nepogoda kod odrona zemlje i poplava u Hrvatskoj“*, potom na projektu: *„Hidrologija osjetljivih vodnih resursa“* te na projektu: *„Networking for Drinking Water Supply in the Adriatic Region (DRINKADRIA)“*.



## POPIS OBJAVLJENIH RADOVA

### Izvorni znanstveni radovi u CC časopisima

Sušanj, I., Ožanić, N., i Marović, I. (2016). *Methodology for developing hydrological models based on an artificial neural network to establish an early warning system in small catchments*, *Advances in Meteorology*, 2016, 0-14.

### Uredničke knjige

Karleuša, B. i Sušanjanj, I., (Urednici), (2016). *International Symposium: Cross-border drinking water management-Proceedings*, Rijeka, Republika Hrvatska: Sveučilište u Rijeci, Građevinski fakultet.

Marović, I. i Sušanjanj, I., (Urednici), (2014). *Zbornik sažetaka / Drugi skup mladih istraživača iz područja građevinarstva i srodnih tehničkih znanosti "Zajednički temelji"*, Rijeka, Republika Hrvatska: Sveučilište u Rijeci, Građevinski fakultet, Udruga hrvatskih građevinskih fakulteta.

### Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

Ožanić, N., Sušanjanj, I., Ružić, I., Žic, E. i Dragičević, N. (2012). *Monitoring and analyses for the working group II (WG2) in Rijeka area in Croatian-Japanese project*, Rijeka, Republika Hrvatska: Ožanić, N., Arbanas, Ž., Mihalić, S. i Marui, H. (Urednici): *Book of proceedings: Second workshop of the monitoring and analyses for disaster mitigation of landslides, debris flow and floods*, 85-91.

Santin, G., Uzelac, B., Sokol, M. i Sušanjanj, I. (2009). *Precipitation water drainage on the site of the planned University campus in Rijeka-Issues and Solution*, Rijeka, Republika Hrvatska: Rubinić, J. i Zmaić, B. (Urednici): *Zbornik radova: Konferencija s međunarodnim sudjelovanjem-Suvremene metode odvodnje oborinskih voda urbanih sredina na obalnim područjima*, 224-233.

Sušanj, I., Dragičević, N., Karleuša, B. i Ožanić, N. (2013). *Gis based monitoring database for dubračina river catchment area as a tool for mitigation and prevention of flash flood and erosion*, Bratislava, Slovakia: Šoltész, A., Baraková, D., Orfánus, M. i Holubec, M. (Urednici): *Book of proceedings: Thirteenth International Symposium on water management and hydraulic engineering*, 637-652.

Sušanj, I., Ožanić, N. i Yamashiki, Y. (2014). *Analysis of flash flood occurred at Slani potok chachement, Croatia*, Zagreb, Republika Hrvatska: Arbanas Mihalić, S. i Arbanas, Ž. (Urednici): *Proceedings: Landslide and flood hazard assessment, 1st Regional Symposium on Landslides in the Adriatic-Balkan Region, 3rd Workshop of the Japanese-Croatian Project" Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia"*, 107-110.

Žic, E., Marović, I., Ožanić, N. i Sušanjanj, I. (2010). *The throughput of the drainage-retaining channel Botonega in Istria, Croatia*, Krtiny, Češka Republika: Hanák, T., Aigel, P., i Dyntarová, K. (Urednici): *Book of proceedings: International Scientific Conference" People, Buildings and Environment 2010"*, 455-461.

Žic, E., Sušanjanj, I., Ružić, I., Ožanić, N. i Yamashiki, Y. (2014). *Hydrologic data analysis for the Grohovo landslide area*, Zagreb, Republika Hrvatska: Arbanas Mihalić, S. i Arbanas, Ž. (Urednici): *Proceedings: Landslide and flood hazard assessment, 1st Regional Symposium on Landslides in the Adriatic-Balkan Region, 3rd Workshop of the Japanese-Croatian Project" Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia"*, 97-107.

## Drugi radovi u zbornicima skupova s recenzijom

- Ožanić, N., Arbanas, Ž., Mihalić, S., Sušanjanj, I., Žic, E., Ružić, I. i Dragičević, N. (2012). *Croatian-Japanese project on floods and landslides: research activities and application of results*, Vukovar, Republika Hrvatska: Biondić, D. i Holjević, D. (Urednici): Zbornik radova: Zaštita od poplava u Hrvatskoj, Okrugli stol, 171-188.
- Ožanić, N., Dragičević, N., Sušanjanj, I., Žic, E., Ružić, I., Krvavica, N. i Karleuša, B. (2015). *Research results on the Croatian-Japanese project-floods and mudflow*, Opatija, Republika Hrvatska: Karleuša, B. i Pavlič, K. (Urednici): Zbornik radova: 9. Dani ovlaštenih inženjera građevinarstva, Vodnogospodarski projekti I EU fondovi, 45-69.
- Ožanić, N., Žic, E., Sušanjanj, I., Travaš, V., Ružić, I., Dragičević, N. i Krvavica, N. (2015). *Scientific equipment and research possibilities at the Faculty of Civil Engineering of the University of Rijeka*, Opatija, Republika Hrvatska: Biondić, D., Holjević, D. i Vizner, M. (Urednici): Zbornik radova 6. Hrvatske konferencije o vodama s međunarodnim sudjelovanjem-HRVATSKE VODE NA INVESTICIJSKOM VALU (6th Croatian Water Conference with International participation-CROATIAN WATERS ON THE INVESTMENT WAVES), 1425-1443.

## Sažeci u zbornicima skupova

- Ožanić, N., Sušanjanj, I., Ružić, I., Žic, E. i Dragičević, N. (2011). *Monitoring and analyses for the Working Group II (WG2) in Rijeka area in Croatian-Japanese project*, Rijeka, Republika Hrvatska: Ožanić, N., Arbanas, Ž., Mihalić, S. i Marui, H. (Urednici): Book of abstracts: Second workshop of the monitoring and analyses for disaster mitigation of landslides, debris flow and floods, 26.
- Ožanić, N., Sušanjanj, I., Žic, E., Krvavica, N., Ružić, I., Dragičević, N., Volf, G. i Karleuša, B. (2013). *Disaster Mitigation of Floods and Debris Flow at Rijeka Region through Croatian-Japanese Collaboration*. Split, Republika Hrvatska: Vlastelica, G., Andrić, I. i Salvezani, D. (Urednici): Book of abstracts: 4<sup>th</sup> project workshop: Japanese-Croatian Project on risk identification and land-use planning for disaster mitigation of landslides and floods in Croatia, 43-45.
- Sušanj, I. (2015). *Levenberg-Marquardt algoritam za treniranje umjetnih neuronskih mreža*, Mostar, Bosna i Hercegovina: Lovrić, I., i Vrdoljak, A. (Urednici): Zbornik sažetaka: Treći skup mladih istraživača iz područja građevinarstva i srodnih tehničkih znanosti – Zajednički temelji, 53-55.
- Sušanj, I. (2016). *Umjetne neuronske mreže: Izazov hidrotehnike?*, Osijek, Republika Hrvatska: Dokšanović, T., Galić, M. (Urednici): Zbornik radova: Zajednički temelji 2016, Četvrti skup mladih istraživača iz područja građevinarstva i srodnih tehničkih znanosti, 56-57.
- Sušanj, I., Dragičević, N., Karleuša, B. i Ožanić, N. (2013). *Izrada GIS baze podataka za sliv rijeke dubračine radi utvrđivanja stanja sliva te umanjenja i sprečavanja pojave bujica, poplava, erozije i lokalnih klizišta*, Split, Republika Hrvatska: Divić, V., Trgolić, B. i Gotovac, H. (Urednici): Zbornik sažetaka: Prvi skup mladih istraživača iz područja građevinarstva, arhitekture, geodezije i elektrotehnike: ZAJEDNIČKI TEMELJI, 47-48.
- Sušanj, I. i Ožanić, N. (2014). *Predviđanje razina podzemne vode upotrebom umjetne neuronske mreže (UNM) na primjeru sliva Slanog potoka*, Rijeka, Republika Hrvatska: Marović, I., Sušanjanj, I., (Urednici): Zbornik sažetaka: Drugi skup mladih istraživača iz područja građevinarstva i srodnih tehničkih znanosti "Zajednički temelji", 52-54.
- Sušanj, I., Yamashiki, Y., Ožanić, N. (2012). *Croatian-Japanese project: "Risk identification and land-use planning for disaster mitigation of landslides and floods in Croatia"*, Kyoto, Japan: Nakashima, M. (Urednik): Book of abstracts: 3rd Symposium of Disaster Risk Management (DRM) for Human Security Engineering in Asian Megacities, 7.
- Yamashiki, Y., Kurokawa, S., Žic, E., Takahashi, T., Rozainy, M. R., Sušanjanj, I. i Fujiki, S. (2013). *Development of Hydro-Debris 2D and 3D applicable for stony debris flow*, Zagreb, Republika Hrvatska: Arbanas Mihalić, S. i Arbanas, Ž. (Urednici): Book of abstracts: Landslide and flood hazard assessment, 1st Regional Symposium on Landslides in the Adriatic-Balkan Region, 3rd Workshop of the Japanese-Croatian Project "Risk Identification and Land-Use Planning for Disaster Mitigation of Landslides and Floods in Croatia".