

Primljen / Received: 15.2.2016.

Ispravljen / Corrected: 12.6.2017.

Prihvaćen / Accepted: 28.6.2017.

Dostupno online / Available online: 10.2.2018.

Primjena neuronskih mreža za hidrološko modeliranje u krškom području

Autori:




Miljan Kovačević, dipl.ing.građ.

Sveučilište u Prištini, Kosovska Mitrovica
Fakultet tehničkih znanosti
miljan.kovacevic@pr.ac.rs



Izv.prof.dr.sc. **Nenad Ivanišević**, dipl.ing.građ.

Sveučilište u Beogradu
Građevinski fakultet
nesa@grf.bg.ac.rs



Izv.prof.dr.sc. **Tina Dašić**, dipl.ing.građ.

Sveučilište u Beogradu
Građevinski fakultet
mtina@grf.bg.ac.rs



Doc.dr.sc. **Ljubo Marković**, dipl.ing.građ.

Sveučilište u Prištini, Kosovska Mitrovica
Fakultet tehničkih znanosti
ljubo.markovic@pr.ac.rs

Prethodno priopćenje

Miljan Kovačević, Nenad Ivanišević, Tina Dašić, Ljubo Marković

Primjena neuronskih mreža za hidrološko modeliranje u krškom području

U ovom radu je razmatrana mogućnost kratkoročnog predviđanja protoka vode u krškom području. Četiri suvremena algoritma strojnog učenja su korištena za predviđanje protoka jedan dan unaprijed i to: neuronska mreža s višeslojnim perceptronom, neuronska mreža s radijalnom aktivacijskom funkcijom, metoda potpornih vektora za regresiju (SVR), adaptivni neuroneizraziti (fuzzy) sustav zaključivanja (ANFIS). Rezultati pokazuju da ANFIS model nadmašuje ostale algoritme kada se korijeni srednje kvadratne pogreške i srednja apsolutna pogreška upotrijebe kao mjere kvalitete.

Ključne riječi:

umjetna neuronska mreža, SVR, ANFIS, odnos oborine-otjecanje u krškom području

Preliminary report

Miljan Kovačević, Nenad Ivanišević, Tina Dašić, Ljubo Marković

Application of artificial neural networks for hydrological modelling in karst

The possibility of short-term water flow forecasting in a karst region is presented in this paper. Four state-of-the-art machine learning algorithms are used for the one day ahead forecasting: multi-layer perceptron neural network, radial basis function neural network, support vector machines for regression (SVR), and adaptive neuro fuzzy inference system (ANFIS). The results show that the ANFIS model outperforms other algorithms when the root mean square error and mean absolute error are used as quality indicators.

Key words:

artificial neural network, SVR, ANFIS, rainfall-runoff ratio in karst areas

Vorherige Mitteilung

Miljan Kovačević, Nenad Ivanišević, Tina Dašić, Ljubo Marković

Anwendung von neuronalen netzen für die hydrologische modellierung im karstgebiet

In dieser Abhandlung wird die Möglichkeit einer kurzfristigen Vorhersage des Wasserflusses im Karstgebiet betrachtet. Vier moderne maschinelle Lernalgorithmen wurden angewendet, um den Durchfluss einen Tag im Voraus vorherzusagen, und dies: neurales Netz mit mehrschichtigem Perzeptron, neurales Netz mit radialer Aktivierungsfunktion, unterstützende Vektoren. Regressionsmethode (SVR), adaptives Neuro-Fuzzy-Inferenzsystem (ANFIS). Die Ergebnisse zeigen, dass das ANFIS-Modell die übrigen Algorithmen übertrifft, wenn die Wurzel des mittleren quadratischen Fehlers und des mittleren absoluten Fehlers als Qualitätsmaß herangezogen wird.

Schlüsselwörter:

künstliches neuronales Netz, SVR, ANFIS, Verhältnis Niederschlag-Abfluss im Karstgebiet

1. Uvod

Sustavi vodnih resursa su složeni sustavi koje karakterizira kompleksna struktura s međusobnim djelovanjem različitih faktora. Oni su izloženi utjecaju brojnih faktora koji određuju ulaze u sustav, zahtijevane izlaze iz sustava, stanja sustava, ciljeve, modele, itd. Upravljanje sustavom u takvim uvjetima je vrlo kompleksno i teško. Jedan od ključnih parametara u svim zadacima planiranja i upravljanja jest raspoloživost vodnih resursa, koja je obično izražena protokom na mjernoj stanici. Kako bi se smanjila nesigurnost mjerenja ovog parametra, koriste se različiti hidrološki modeli za njegovo predviđanje (predikciju), kao što su stohastički modeli (npr. regresija, neuronske mreže) ili deterministički modeli. Oni se obično temelje na meteorološkim opažanjima i karakteristikama sliva.

Hidrološki modeli se često koriste kod predviđanja protoka rijeka u bliskoj budućnosti. Mogu se podijeliti na kratkoročna, srednjoročna i dugoročna predviđanja [1]. Prema definiciji Svjetske meteorološke organizacije (WMO), kratkoročna predviđanja se odnose na period do dva dana, srednjoročna od dva do deset dana, a dugoročna hidrološka predviđanja odnose se na period dulji od deset dana.

Ogledni primjer koji je opisan u radu odnosi se na krško područje u Bosni i Hercegovini, s brojnim ponorima, izvorima, estavelama, krškim poljima i podzemnim krškim kanalima. Protok u krškom području je složen hidrogeološki fenomen [2, 3]. Površinski tokovi se rijetko javljaju, a podzemna voda je direktno zavisna od podzemnih tokova. Funkcioniranje tih krških tokova je kompleksno i podložno je ekstremnim sezonskim promjenama, uključujući i promjene vodnih tokova. Modeliranje protoka vode u takvim hidrogeološkim uvjetima je vrlo složeno i podložno utjecaju brojnih faktora. Imajući u vidu nepoznavanje veza između tih faktora, primijenjen je model "crne kutije". Analizirana su četiri algoritma strojnog učenja i uspoređeni su njihovi rezultati.

Primjena strojnog učenja na probleme hidrološkog modeliranja predstavlja polje istraživanja koje je u stalnom porastu. Općenito, metode strojnog učenja su pogodne za modeliranje i predviđanje promjene funkcionalnih karakteristika promatranih sustava, jer omogućuju naći rješenje, prepoznati modele ponašanja, klasificirati podatke i predvidjeti buduće događaje [4]. Najčešće, strojno učenje se primjenjuje u hidrologiji za predviđanje protoka i vodostaja u rijekama [5], kad postoje problemi pronosa nanosa [6], modeliranja kvalitete vode [7], identifikacije vodenih površina tijekom poplava [8] kao i u mnogim drugim okolnostima povezanim s vodnim resursima.

Umjetne neuronske mreže (ANN), kao što su neuronske mreže s višeslojnim perceptronom (MLP), generalizirane regresijske neuronske mreže (GRNN) i neuronske mreže s radialnom aktivacijskom funkcijom (RBF) ubrajaju se u najčešće primijenjene metode strojnog učenja kod hidrološkog modeliranja [9].

Adaptivni neuroneizraziti sustav zaključivanja (ANFIS) integrira neuronske mreže i principe neizrazite (fuzzy) logike, sa sustavom zaključivanja koji odgovara "ako-onda" (if-then) pravilima koja mogu aproksimirati nelinearne funkcije, pa zbog toga mogu potencijalno istovremeno koristiti prednosti i neuronskih mreža i neizrazite logike. Sanikhani i ostali [10] su modelirali dva različita ANFIS modela - ANFIS s mrežnom podjelom (ANFIS-GP) i ANFIS model koji je koristio klasteriranje (ANFIS-SC) s primjenom genetskih algoritama, za predviđanje fluktuacije jezera Manyas i Tuz u Turskoj jedan, dva i tri mjeseca unaprijed. Rezaeianzadeh i ostali [11] su primijenili ANN, ANFIS i regresijske modele za predviđanje maksimalnog dnevnog protoka na izlazu Khosrow Shirin sliva koji je lociran u Fars provinciji u Iranu. Tien Bui i ostali [12] su predložili neuro-neizraziti sustav zaključivanja s metaheurističkom optimizacijom modela za procjenu opasnosti od poplava. Analizirano je područje s visokom učestalošću pojave tropskih ciklona u okrugu Tuong Duong, u središnjem dijelu Vijetnama. Chang i ostali [13] su analizirali model procjene kvalitete vode koristeći dvije statičke (MLP i ANFIS) i jednu dinamičku umjetnu neuronsku mrežu (NARX) za rijeku Dahan u Tajvanu.

Metoda potpornih vektora (SVM) pripada grupi modela nadziranog učenja koji se mogu koristiti i kod problema klasifikacije i regresije. Osim primjene linearnih modela, SVM se može djelotvorno primijeniti i kod predviđanja nelinearnih zavisnosti pomoću tzv. kernel trika, odnosno preslikavanjem u novi prostor s većim brojem dimenzija pomoću pogodne kernel funkcije, čime se nelinearni problem transformira u linearni. Grenata i ostali [14] su primijenili SVM za modeliranje zavisnosti oborina i otjecanja korištenjem varijante metode SVM za regresiju (Support Vector Regression) za dva sliva locirana u sjevernoj Italiji. Hosseini i Mahjouri [15] su predstavili novi model zavisnosti oborina i otjecanja (SVR-GANN), gdje je SVR model kombiniran s geomorfološki zasnovanim ANN modelom u studiji tri podsliva locirana u polu-sušnom području Irana. Gizaw i Gun [16] su razvili model za analizu regionalne učestalosti poplava (Regional Flood Frequency Analysis-RFFA) koji je zasnovan na SVR metodi, za ocjenjivanje kvantila poplava po područjima za dva razmatrana područja u Kanadi. He i ostali [17] su usporedili ANFIS i SVM modele za predviđanje protoka rijeka u polusušnom planinskom području, na sjeverozapadu Kine. Gong i ostali [18] su koristili ANN, SVM i ANFIS modele za predviđanje razina podzemnih voda blizu jezera Okeechobee na Floridi.

Usporedna analiza nekoliko najsuvremenijih algoritama strojnog učenja za predviđanje zavisnosti oborina i otjecanja izvora rijeke Bune predstavljena je u ovom radu. Analizirane su MLP i RBF neuronske mreže, kao i SVM i ANFIS modeli algoritama za kratkoročno predviđanje protoka rijeke, koristeći oborine i protoke u prethodna dva dana kao ulazne parametre.

2. Metode strojnog učenja za hidrološko modeliranje

2.1. Neuronska mreža s višeslojnim perceptronom

Neuronska mreža s višeslojnim perceptronom je nepovratna neuronska mreža (bez povratne sprege) koja se sastoji od najmanje tri sloja: ulaznog L1, skrivenog L2 i izlaznog L3. Svaki sloj je sastavljen od jedne ili više procesnih jedinica koje se nazivaju neuroni, gdje je svaki neuron jednog sloja povezan sa svakim neuronom sljedećeg sloja, kao što je prikazano slici 1.a. Više slojeva neurona s nelinearnim prijenosnim funkcijama omogućava da mreža nauči nelinearne relacije između ulaznih i izlaznih vektora. Najčešće se koristi sigmoidna aktivacijska funkcija u skrivenom sloju koja je definirana pomoću izraza (1):

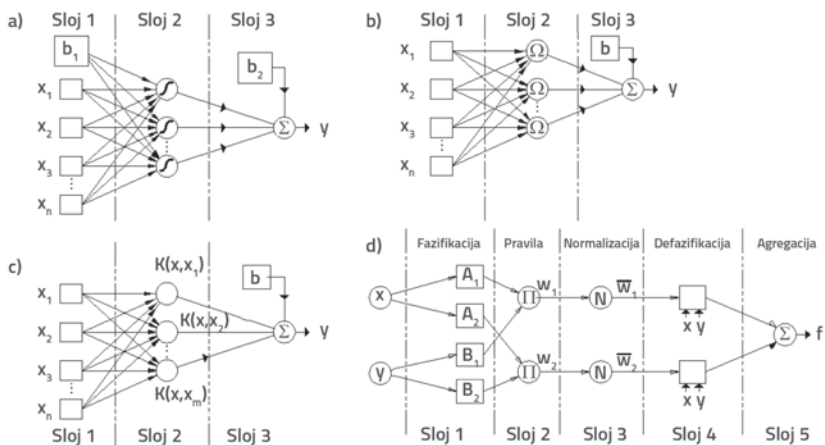
$$\varphi(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

a linearna se aktivacijska funkcija koristi u izlaznom sloju. ANN model s jednim skrivenim slojem čiji neuroni imaju sigmoidnu aktivacijsku funkciju, a neuroni izlaznog sloja imaju linearnu aktivacijsku funkciju, može aproksimirati višedimenzionalnu funkciju za dani skup podataka onda kad postoji dovoljan broj neurona u skrivenom sloju [19].

Broj neurona u skrivenom sloju se određuje eksperimentalno. Može se primjerice odrediti gornja granica, odnosno maksimalan broj neurona skrivenog sloja, i to primijeniti pri modeliranju sustava koji je predstavljen određenim skupom podataka. Preporučuje se prihvaćanje manje vrijednosti broja neurona u skrivenom sloju N_H definiranih izrazima (2) i (3), gdje N_I predstavlja broj ulaza u neuronsku mrežu, a N_S predstavlja broj uzoraka za treniranje [20, 21].

$$N_H \leq 2N_I + 1 \quad (2)$$

$$N_H \leq \frac{N_S}{N_I + 1} \quad (3)$$



Slika 1. Analizirani modeli: a) MLP neuronska mreža, b) RBF neuronska mreža, c) SVR, d) ANFIS

U ovom je radu predložena upotreba MLP modela neuronske mreže s jednim skrivenim slojem koja je trenirana Levenberg-Marquardtovim algoritmom.

2.2. Neuronska mreža s radijalnom aktivacijskom funkcijom

RBF neuronska mreža se sastoji od ulaznog, skrivenog i izlaznog sloja. Neuroni skrivenog sloja imaju nelinearnu RBF aktivacijsku funkciju (slika 1.b). Za zadani ulaz $x = \{x_1, x_2, \dots, x_n\} \in R$, izlaz iz mreže φ je dan pomoću izraza

$$\varphi(x) = \sum_{i=1}^N \omega_i e^{-\frac{x-c_i^2}{2t}} \quad (4)$$

gdje N predstavlja broj neurona u skrivenom sloju, t je radijus (širina) funkcije s radijalnom osnovom, c_i je centar vektora i -tog neurona, ω_i je težina i -tog neurona.

Mogu se koristiti različite funkcije s radijalnom osnovom, a u ovom radu je korištena Gausova funkcija $K(x,c) = e^{-\frac{\|x-c\|^2}{2t}}$. Obično se primjenjuje euklidska norma ili euklidska udaljenost. Euklidska udaljenost predstavlja najkraću udaljenost od točke u kojoj se izvodi procjenjivanje do središta svakog neurona. Zatim se primjenom funkcije s radijalnom osnovom računa težina za svaki neuron. Parametri ω_i , c_i i t se optimalno određuju tako da postoji najbolje moguće poklapanje između modela i podataka [22].

Za zadani skup od n podataka za trening $\{(x_1, y_1), \dots, (x_n, y_n)\}$ cilj algoritma za učenje je da se dobije skup vrijednosti c_i i težina ω_i ($i = 1, 2, \dots, M$) takav da je $(x_j) \approx y_j$ ($j = 1, 2, \dots, n$).

RBF mreža pozicionira jedan ili više neurona u prostoru koji je definiran ulazima. Funkcija radijalne osnove za neuron je definirana središtem i radijusom. Što je dalje neuron od točke u kojoj se izvodi procjenjivanje, manji je utjecaj koji on ima, pa je odgovarajuća težina ω_i manja. S druge strane, ukoliko je radijus veći, neuroni koji su dalje od promatrane točke imaju veći utjecaj u odnosu na slučaj kada je radijus malen.

2.3. Metoda potpornih vektora za regresiju

Neka je zadan skup podataka za trening $\{(x_1, y_1), \dots, (x_n, y_n)\}$ SIMBOL $R^n \times R$, gdje x_i označava ulazne parametre, a y_i odgovarajuće izlazne parametre. Cilj je SVR metode (slika 1.c) naći funkciju aproksimacije $f(x)$ koja ima odstupanje ε od vrijednosti izlaza y_i za sve podatke na ulazu x_i .

Ova funkcija aproksimacije (4) se može napisati za slučaj linearnog SVR modela pomoću izraza (5):

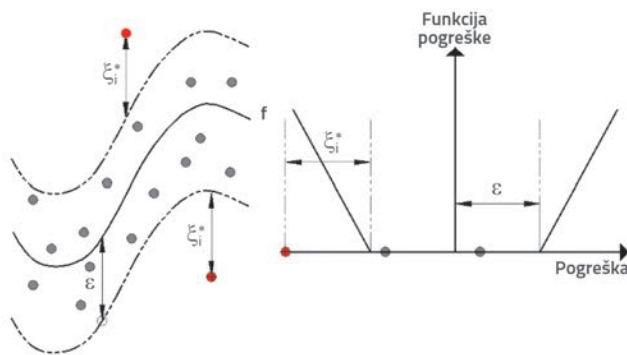
$$f(x) = \langle \omega, x \rangle + b \text{ sa } \omega \in X, b \in \mathfrak{R} \quad (5)$$

gdje $\langle \omega, x \rangle$ predstavlja skalarni produkt. Radi pronalazjenja odgovarajuće aproksimirajuće funkcije f , treba potražiti težinu ω i konstantu C , tako da kriterijska funkcija bude optimalna [5]:

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (6)$$

$$\text{ograničenja} \begin{cases} y_i - \langle \omega, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle \omega, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (7)$$

gdje su ξ_i i ξ_i^* pomoćne varijable, kao što je prikazano na slici 2. Konstanta $C > 0$ je parametar koji određuje veličinu odstupanja većeg od ε koje se može tolerirati. Veća vrijednost C kažnjava veće pogreške (veće ξ_i i ξ_i^*) i na taj način smanjuje pogrešku aproksimacije. Parametre C i ε bira sam korisnik.



Slika 2. Nelinearan SVR s odstupanjem ε

Rješenje za (6) i (7) se može naći uvođenjem Lagrangeove funkcije s dualnim skupom varijabli. Aproksimativna funkcija se tada može napisati pomoću izraza (8):

$$\omega = \sum_{i=1}^n (\alpha_i + \alpha_i^*) x_i \text{ i zato } f(x) = \sum_{i=1}^n (\alpha_i + \alpha_i^*) x_i, x \quad (8)$$

Član b (bias) iznosi

$$b = y_i - \langle \omega, x_i \rangle - \varepsilon \text{ za } 0 < \alpha_i < C \quad (9)$$

$$b = y_i - \langle \omega, x_i \rangle + \varepsilon \text{ za } 0 < \alpha_i^* < C$$

Kada se uzorci za treniranje x_i preslikavaju u prostor više dimezije koristeći preslikavanje $\Phi: x \rightarrow \Phi(x)$, skalarni produkt ima vrijednost $k \langle x_i, x \rangle = \langle \Phi(x_i), \Phi(x) \rangle$. Tada aproksimirajuća funkcija postaje

$$f(x) = \sum_{i=1}^n (\alpha_i + \alpha_i^*) k \langle x_i, x \rangle + b \quad (10)$$

Za linearnu SVR metodu kernel je $k \langle x_i, x \rangle = \langle x_i, x \rangle$, a u nelinearnom slučaju mogu se koristiti različite kernel funkcije, npr. polinomni, sigmoidni ili RBF kernel. RBF i sigmoidni kerneli korišteni u ovom radu definirani su kao [11, 15-18]:

$$k \langle x_i, x \rangle = \exp(-\gamma \|x_i - x\|^2), \gamma > 0 \quad (11)$$

$$k \langle x_i, x \rangle = \tanh(\gamma \langle x_i, x \rangle + r), \gamma > 0 \quad (12)$$

2.4. Adaptivni neuroneizraziti sustav zaključivanja

Adaptivni neuroneizraziti sustav zaključivanja (ANFIS) predstavlja vrstu neuronske mreže (slika 1.d) koja je zasnovana na sustavu zaključivanja Sugeno tipa. Taj sustav zaključivanja odgovara skupu neizrazitih "ako-onda" pravila koja imaju sposobnost aproksimiranja nelinearne funkcije [22].

Slika 2.d prikazuje ANFIS sustav s dva ulazna parametra, jednim izlaznim parametrom i dva pravila koja su definirana kao:

$$\text{Pravilo 1: ako je } x = A_1 \text{ i } y = B_1, \text{ onda je } f_1 = p_1 x + q_1 y + r_1 \quad (13)$$

$$\text{Pravilo 2: ako je } x = A_2 \text{ i } y = B_2, \text{ onda je } f_2 = p_2 x + q_2 y + r_2 \quad (14)$$

gdje su A_i i B_i neizraziti skupovi, f_i je izlaz određen odgovarajućim neizrazitim pravilom, p_i , q_i i r_i su linearni parametri u "onda" (then) dijelu neizrazitog modela Sugeno tipa.

Ulazne varijable se fazificiraju u prvom skrivenom sloju. Procesom fazificiranja se transformiraju vrijednosti ulaza u neizrazite funkcije pripadnosti. U ovom radu je korištena Gausova funkcija dana izrazom (15).

$$\mu_{A_i}(x) = e^{-\frac{(x-c)^2}{2\delta^2}} \quad (15)$$

gdje su $\mu_{A_i(x)}$ i $\mu_{B_i(y)}$ funkcije pripadnosti, dok su redom δ i c širina i centar funkcije. Pravila se formiraju u drugom sloju. Za svako od navedenih pravila, njegovu jačinu (w_i) definiramo na sljedeći način:

$$w_i = \mu_{A_i(x)} \cdot \mu_{B_i(y)}, i = 1, 2 \quad (16)$$

U sljedećem koraku izvodi se normalizacija jačine pravila i vrijednosti w_i se računaju u sloju 3 pomoću izraza (17):

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}; i = 1, 2 \quad (17)$$

Defazifikacija se obavlja u sloju 4 pomoću izraza:

$$\bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (18)$$

Konačne vrijednosti se računaju u sloju 5 pomoću:

$$\text{Izlazne veličine} = \sum_i \bar{w}_i \cdot f_i; i = 1, 2 \quad (19)$$

2.5. Ocjena kvalitete modela i kriteriji kvalitete

Kvaliteta modela u radu je ocijenjena primjenom različitih statističkih kriterija. Kao statistički kriterij korišten je korijen srednje kvadratne pogreške (RMSE), srednja apsolutna pogreška (MAE), koeficijent determinacije (R^2) i Nash-Sutcliffeov koeficijent efikasnosti (CE).

RMSE je mjera razlike između vrijednosti koju predviđa model o_k i stvarno izmjerene vrijednosti protoka rijeke d_k (20). Predstavlja mjeru točnosti modela.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (d_k - o_k)^2} \quad (20)$$

MAE je također mjera točnosti modela i koristi se za predstavljanje srednje apsolutne pogreške modela prema izrazu (21):

$$MAE = \frac{1}{N} \sum_{k=1}^N |d_k - o_k| \quad (21)$$

Koeficijent determinacije R^2 je definiran jednadžbom (22):

$$R^2 = \left[\sum_{k=1}^N (d_k - \bar{d})(o_k - \bar{o}) \right]^2 \cdot \left[\sum_{k=1}^N (d_k - \bar{d})^2 \sum_{k=1}^N (o_k - \bar{o})^2 \right]^{-1} \quad (22)$$

gdje o_k predstavlja srednju vrijednost predviđanja dobivenu odgovarajućim modelom, a d_k predstavlja srednju izmjerenu vrijednost.

Nash-Sutcliffeov koeficijent efikasnosti modela CE se uobičajeno koristi za ocjenu moći predviđanja hidrološkog modela. Definiran je kao:

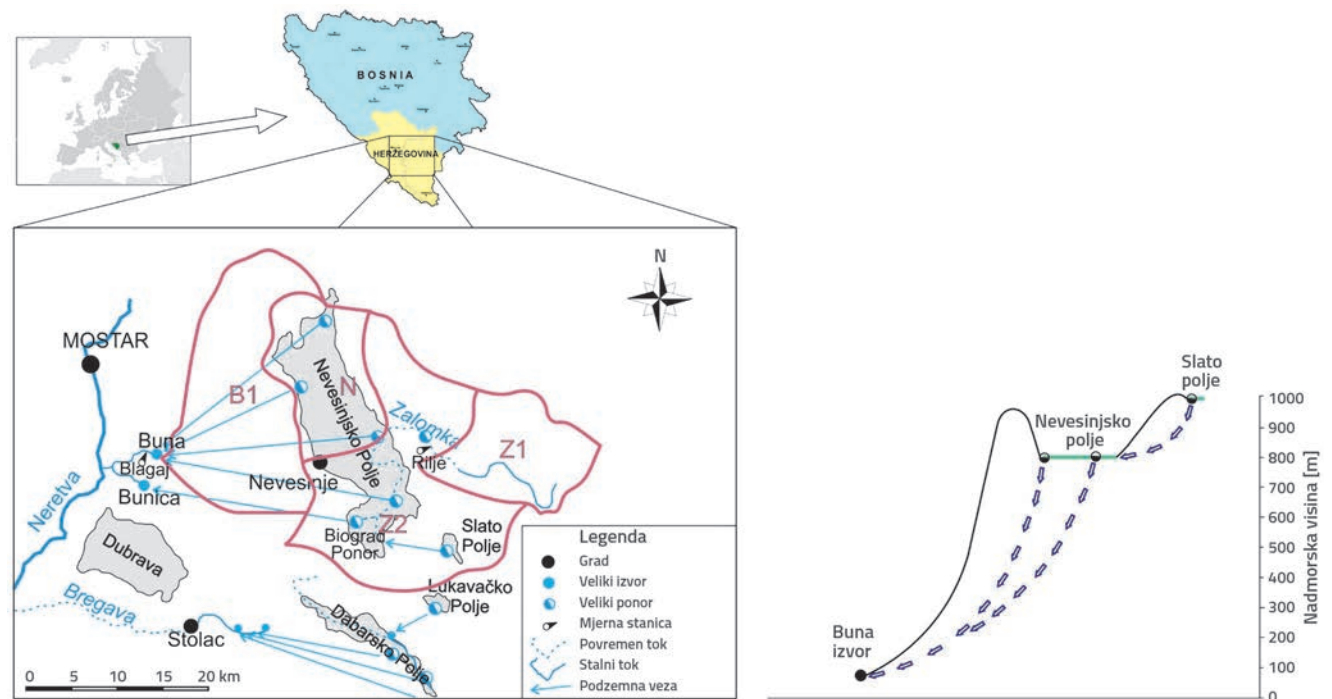
$$CE = 1 - \frac{\sum_{k=1}^N (d_k - o_k)^2}{\sum_{k=1}^N (d_k - \bar{d})^2} \quad (23)$$

CE ima opseg od $-\infty$ do 1, tako da CE = 1 odgovara savršenom poklapanju između izmjerene i modelirane vrijednosti. Legates i McCabe [23] sugeriraju da je potrebno koristiti najmanje jednu relativnu (npr. CE ili R^2) i najmanje jednu apsolutnu (npr. RMSE ili MAE) mjeru pogreške pri ocjenjivanju modela.

3. Ogledni primjer vrela rijeke Bune

Prethodno opisane metode primijenjene su za modeliranje otecanja u krškom području vrela rijeke Bune u istočnoj Hercegovini (slika 3.). Razmatrani ogledni primjer prostorno pripada dinarskom krškom području, sastavljenom uglavno od topljivih karbonatnih stijena [2]. Karakterizira ga postojanje površinskih i podzemnih krških fenomena, kao što su ponori, izvori, estavele, podzemni krški kanali i kaskadna krška polja, koji se prostiru na nadmorskim visinama od razine mora do približno 900 m.

U krškim poljima postoje aktivni površinski tokovi samo za vrijeme kišnih perioda godine. Oni utječu u ponore, obično duž



Slika 3. Pregled krških polja i njihovih podzemnih veza

južnih oboda polja. Pražnjenja su obično duž južnog oboda nižeg polja. Rijeka Buna (slika 3.) jedan je od rijetkih stalnih površinskih tokova u istočnoj Hercegovini. Ulijeva se u rijeku Neretvu nizvodno od grada Mostara. Hidrološka slivna površina izvora Bune uključuje znatno širu površinu u usporedbi s njenom orografskom slivnom površinom. Slivna površina vrela Bune uključuje šire područje sliva rijeke Zalomke, veliki dio Nevesinjskog polja, slivnu površinu Lukovačkog i Slatu polja, kao i slivnu površinu između Nevesinjskog polja i dijela masiva planine Velež. Najznačajniji dio sliva vrela Bune je planinsko područje između Nevesinjskog polja i vrela.

Vrelo Bune predstavlja jedno od najpoznatijih u dinarskom kršu. Formirano je na kontaktu krednih vapnenaca i eocenskog fliša, na visini od 36 m iznad nivoa mora. Mjerna stanica Blagaj se nalazi neposredno nizvodno od vrela. Srednje godišnje pražnjenje je $Q_{sr} = 23,7 \text{ m}^3/\text{s}$, dok je minimalno i maksimalno pražnjenje $Q_{min} = 2,95 \text{ m}^3/\text{s}$ i $Q_{max} = 380 \text{ m}^3/\text{s}$ [2]. Slivna površina vrela Bune je podijeljena u nekoliko podslivova (slika 3.). Područje označeno s B1 predstavlja neposrednu orografsku slivnu površinu. To je planinsko područje (padine planine Velež) i voda iz tog područja dotječe neposredno u vrelo Bune. Voda iz područja koje je označeno s N ponire duž rijeke Zalomke i prazni se na vrelu rijeke Bune. Dio vode iz područja Z1 i Z2 ponire duž rijeke Zalomke i prazni se na vrelu Bune. Ovaj dio sliva uključen je u proračun preko protoka na mjernoj stanici Rilje na rijeci Zalomki.

Metode za modeliranje pražnjenja vrela Bune zasnovane su na principu "crne kutije". Analizirani su ulazni i izlazni parametri da bi se dobili operatori preslikavanja. Ulazni parametri su prosječna dnevna vrijednost oborina na slivu i protok rijeke na hidrološkim mjernim stanicama Rilje i Blagaj u prethodnim danima. Istraživanjima na terenu, kada su bojenjem vode na ponorima dobiveni podaci o vremenu pojave boje na vrelu, utvrđeno je da su za to potrebna dva dana (zbog krške prirode terena) [2]. Budući da postoji odgođeno djelovanje ulaznih u odnosu na izlaznu veličinu, provedena je posebna analiza koja je pokazala da produljenje razmatranog perioda za više od dva dana ne utječe na poboljšanje točnosti modela.

Ulazni vektori su formirani korištenjem oborina i protoka u prethodna dva dana:

$$Q_i^{BL} = f \left\{ P_{i-2}^{B1}, P_{i-1}^{B1}, P_{i-2}^N, P_{i-1}^N, Q_{i-2}^r, Q_{i-1}^r, Q_{i-2}^{BL}, Q_{i-1}^{BL} \right\} \quad (24)$$

gdje je:


P_i^{B1} - dnevna vrijednost oborina i -tog dana za područje B1,
 P_i^N - dnevna vrijednost oborina i -tog dana za područje N,
 Q_i^r - dnevni protok i -tog dana na stanici Rilje,
 Q_i^{BL} - dnevni protok i -tog dana na stanici Blagaj (1 dan unaprijed).

Ukupan broj raspoloživih podataka je 4747. Za treniranje mreže korišteno je 70 % prikupljenih podataka, 15 % podataka pripada skupu za validaciju, a 15 % podataka se koristi za testiranje

modela. Podaci za treniranje mreže obuhvaćaju razdoblje od 3. rujna 1971. do 7. listopada 1980. Podaci za validaciju odnose se na razdoblje od 8. listopada 1980 do 19. rujna 1982., a podaci za testiranje mreže obuhvaćaju period od 20. rujna 1982. do 31. kolovoza 1984. Vrijednosti protoka koje pripadaju periodu treniranja, odnosno osposobljavanja mreže, mogu iznositi minimalno $2,8 \text{ m}^3/\text{s}$ do maksimalno $115,35 \text{ m}^3/\text{s}$, dok vrijednosti za skup podataka za validaciju iznose od $3,1 \text{ m}^3/\text{s}$ do $108,00 \text{ m}^3/\text{s}$, a vrijednosti za skup podataka za testiranje iznose od $2,95 \text{ m}^3/\text{s}$ do $94,9 \text{ m}^3/\text{s}$. Isti podaci za treniranje, validaciju i testiranje primjenjivani su za sve modele.

4. Rezultati i rasprava

U radu su prikazani rezultati za predviđanje oborina i otjecanja primjenom četiri metode strojnog učenja: MLP i RBF neuronskih mreža, SVR i ANFIS modela. Isti skup ulaznih atributa je korišten za sve modele, odnosno istih 8 ulaznih varijabli koje definiraju oborine i otjecanja u prethodna dva dana.




Slika 4. Usporedni pregled statističkih pokazatelja za različite arhitekture MLP neuronskih mreža: a) korijen srednje kvadratne pogreške (RMSE) i srednja apsolutna pogreška (MAE); b) koeficijent determinacije (R^2) i Nash-Sutcliffeov koeficijent efikasnosti (CE)

Za ocjenu kvalitete modela korišteni su korijen srednje kvadratne pogreške (RMSE), srednja apsolutna pogreška (MAE), koeficijent determinacije (R^2) i Nash-Sutcliffeov koeficijent efikasnosti (CE). Za testiranje je korišten skup podataka koji nije bio uključen u proces treniranja. Isti skup podataka za testiranje je korišten za sve algoritme.

Za MLP model neuronske mreže broj neurona ulaznog sloja je određen brojem ulaznih varijabli, odnosno sastoji se od 8 neurona, dok je u izlaznom sloju samo jedan neuron. Broj

neurona u skrivenom sloju se određuje eksperimentalno. Gornja granica, odnosno maksimalni broj neurona skrivenog sloja koji se može koristiti za modeliranje je 17, određen na osnovi izraza (2) i (3). Da bi se odredio optimalan broj neurona, provedeno je višestruko osposobljavanje mreže za različite brojeve neurona skrivenog sloja između 1 i 17, kao što je prikazano na slici 4. Može se vidjeti da je optimalan broj neurona skrivenog sloja 8, što je potvrđeno pomoću tri kriterija kvalitete modela, RMSE, MAE i R^2 (slika 4.).

RBF neuronska mreža sadrži isti broj neurona u ulaznom i izlaznom sloju kao MLP neuronska mreža, dok se optimalan broj neurona u skrivenom sloju određuje eksperimentalno u rasponu od 1 do 100 neurona, kao što je prikazano na slici 5. Uzeta je veća vrijednost za gornju granicu broja neurona u odnosu na MLP zbog toga što funkcija s radijalnom osnovom ima značajan odgovor samo kada se ulazi nalaze u uskom području ulaznog prostora [24].



Slika 5. Performanse RBF modela s različitim brojem neurona u skrivenom sloju i različitim vrijednostima radijusa

U radu se koristi Gausova aktivacijska funkcija, pri čemu parametar radijus kontrolira širinu Gausove funkcije, što znači da određuje veličinu ulaznog prostora na koju će RBF neuron reagirati. Ispitane su vrijednosti radijusa od 0,1 do 3 s korakom 0,1 kako bi se našla najbolja vrijednost radijusa koja daje najmanju vrijednost MSE. Može se uočiti da je optimalan broj neurona u skrivenom sloju 13 s vrijednošću radijusa 0.6 (zeleno na slici 5.).

Analizirana je upotreba SVR modela s linearnim, RBF i sigmoidnim kernelom. Normalizacija, kojom su svi ulazni podaci transformirani u raspon [0,1] napravljena je prije osposobljavanja i testiranja modela. Optimalni model je određen algoritmom potpune pretrage [25] za sve kernele ($C = 0.038650$ i $\varepsilon = 0.019523$ za linearni kernel; $C = 0.105115$; $\varepsilon = 0.005524$; $\gamma = 0.297305$ za RBF kernel; $C = 0.197405$; $\varepsilon = 0.0191385$; $\gamma = 0.178585$ za sigmoidni kernel). LIBSVM biblioteka je korištena za implementaciju SVR [26].

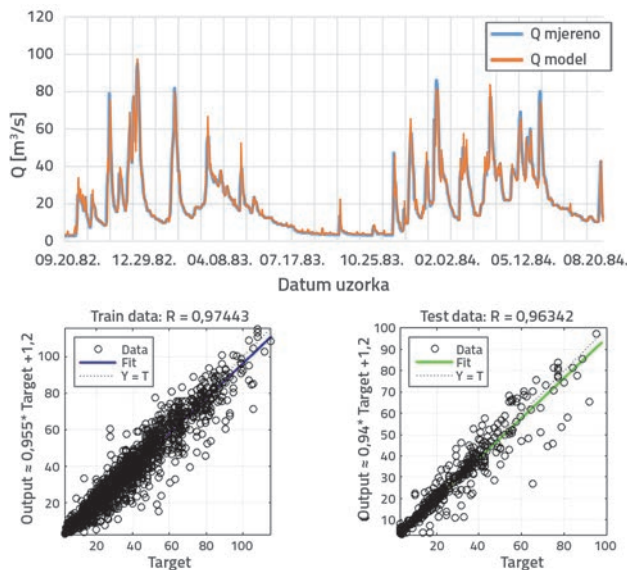
Za određivanje parametara ANFIS modela primjenjen je hibridni postupak osposobljavanja. Gradijentna metoda je primijenjena za podešavanje parametara premise pravila ("ako" dio pravila), a metoda najmanjih kvadrata za pronalaženje linearnih parametara u posljedičnom dijelu pravila ("onda" dio pravila). Ulazni sloj ima osam varijabli, a izlazni samo jednu. Ulazne varijable su linearno normalizirane u opsegu [0,1] prije korištenja ANFIS modela. Broj neizrazitih funkcija pripadnosti za svaku ulaznu varijablu je postavljen na 2. Usvojene su Gausove funkcije pripadnosti za ulaze. Radi osposobljavanja neizrazitih sustava zaključivanja (FIS), najprije treba definirati samu strukturu. U ovom istraživanju FIS struktura je generalizirana metodom "subtractive clustering" [10, 27], koja služi za određivanje područja prostora atributa s velikom gustoćom podataka. Točka s najvećim brojem susjeda se odabire za centar klastera. Podaci u okviru unaprijed definiranog neizrazitog radijusa se zatim uklanjaju (oduzimaju iz čitavog skupa), a algoritam pretražuje nove točke s najvećim brojem susjeda. Postupak se ponavlja dok svi podaci ne budu istraženi. U ovom su istraživanju korištena dva klastera. Ispitane su vrijednosti neizrazitog radijusa od 0,15 do 0,50 s korakom 0,01. Vrijednost 0,22 je usvojena kao optimalna koristeći kao kriterij RMSE. Broj trening epoha je podešen na 100.

Performanse svih modela korištenjem kriterija RMSE, MAE, R^2 i CE prikazane su u tablici 1. Označen je najbolji model u svakom stupcu. Kada RMSE i MAE koristimo kao kriterij kvalitete ANFIS model ima najbolje performanse. Prema kriterijima R^2 i CE, svi modeli su prilično slični, ali je SVR model s linearnim kernelom neznatno bolji od ostalih modela kada se koristi R^2 , dok RBF neuronska mreža predstavlja najbolji model kada se koristi CE kao kriterij. U oba slučaja ANFIS je drugi najbolji model. Zbog svega navedenog, na osnovi sva četiri kriterija, možemo izabrati ANFIS kao najpovoljniji model za kratkoročno predviđanje

Tablica 1. Performanse za MLP i RBF neuronske mreže, SVR i ANFIS model

Model	Kriterij			
	RMSE	MAE	R^2	CE
MLP	4,870	2,399	0,920	0,930
RBF	4,993	2,544	0,927	0,947
SVR-RBF kernel	4,715	2,272	0,925	0,928
SVR-linearni kernel	4,819	2,507	0,946	0,921
SVR-sigmoidni kernel	4,815	2,459	0,922	0,921
ANFIS	4,615	2,255	0,928	0,937

protoka rijeke jedan dan unaprijed, zasnovanom na podacima o oborinama i protoku u prethodna dva dana. Sve daljnje analize su rađene primjenom ovog modela. Usporedba mjerenih vrijednosti i vrijednosti dobivenih primjenom ANFIS modela, kao i dijagram raspršenosti za podatke za osposobljavanje i testiranje prikazani su na slici 6.




Slika 6. a) Usporedba mjerenih vrijednosti i vrijednosti dobivenih primjenom ANFIS modela, b) Regresijski dijagrami za podatke o treniranju i testiranju kod ANFIS modela

Svi prethodno testirani modeli su koristili svih osam ulaznih varijabli (dnevne vrijednosti oborina i dnevne vrijednosti protoka), ne vodeći računa o utjecaju pojedinačnih varijabli na točnost modela. U daljnjim analizama je primijenjena selekcija varijabli. Izvedeno je modeliranje primjenom samo najrelevantnijih varijabli, a izostavljene su irelevantne i redundantne varijable koje ne pridonose točnosti modela, ili je čak mogu smanjiti. Ovo ne samo da smanjuje složenost modela, već i ubrzava proces osposobljavanja modela. Algoritam potpune pretrage [28, 29] korišten je za ovaj zadatak. Za zadani skup od $N=8$ ulaznih varijabli, označenih kao $P_{i-2}^{B1}, P_{i-1}^{B1}, P_{i-2}^N, P_{i-1}^N, Q_{i-2}^r, Q_{i-1}^r, Q_{i-2}^{BL}, Q_{i-1}^{BL}$ postoji $2^N - 1 = 255$ mogućih kombinacija varijabli, pa je generirano 255 različitih ANFIS. Primijenjen je postupak deseterostruke unakrsne validacije i određena je vrijednost MSE za svaki model. Optimalni podskup ulaznih varijabli je onaj koji daje model s najmanjom vrijednošću MSE.

Tablica 2. Modeli s podskupovima ulaznih varijabli

Model	Ulazna varijabla								Kriterij			
	P_{i-2}^{B1}	P_{i-1}^{B1}	P_{i-2}^N	P_{i-1}^N	Q_{i-2}^r	Q_{i-1}^r	Q_{i-2}^{BL}	Q_{i-1}^{BL}	RMSE	MAE	R ²	CE
1,	1	1	0	1	1	1	1	1	4,633	2,421	0,942	0,953
2,	1	1	0	1	0	1	0	1	4,693	2,520	0,940	0,952
3,	1	1	1	1	1	1	1	1	4,615	2,255	0,928	0,937

Dodatno je određena učestalost pojavljivanja svake od ulaznih varijabli u svim generiranim modelima i na osnovi toga su detektirane najrelevantnije varijable. Rezultat ove analize je prikazan na slici 7. i pokazuje da je varijabla 8 (Q_{i-1}^{BL}) prisutna u svim modelima, dok varijable 1, 2, 4 i 6 ($P_{i-2}^{B1}, P_{i-1}^{B1}, P_{i-1}^N, Q_{i-1}^r$) imaju približno 20-30 % nižu učestalost pojavljivanja, a varijable 5 i 7 (Q_{i-2}^r, Q_{i-2}^{BL}) imaju učestalost pojavljivanja manju od 50 %. Najmanje značajna je varijabla 3 (P_{i-2}^N).



Slika 7. Učestalost pojavljivanja ulaznih varijabli u modelima

Budući da su varijable 3, 5 i 7 ($P_{i-2}^N, Q_{i-2}^r, Q_{i-2}^{BL}$) znatno manje značajne u usporedbi s drugima, analizirani su modeli kod kojih je izostavljena samo varijabla 3 (model 1 u tablici 2.) i sve tri varijable (model 2 u tablici 2.). Binarna vrijednost (1 ili 0) označava da li je određena varijabla uključena u model ili nije. Usporedba performansi tih modela s modelom koji koristi svih osam ulaznih varijabli (model 3 u tablici 2.) pokazuje da korištenje podskupa od samo 5 ulaznih varijabli daje slične rezultate kada služi kao kriterij kvalitete RMSE, ili čak bolje rezultate kada služi kao kriterij kvalitete R² i CE.

5. Zaključak

U ovom radu izvedena je usporedna analiza većeg broja najmodernijih algoritama strojnog učenja za zadatak kratkoročnog predviđanja protoka rijeke u krškom području. Analizirani su različiti oblici neuronskih mreža, kao što su MLP i RBF, ANFIS model koji inkorporira neuronske mreže s principima neizravne logike, kao i više SVR modela. Za kriterije kvalitete

primijenjene su različite relativne (CE ili R^2) i apsolutne ($RMSE$ ili MAE) mjere kvaliteta.

Rezultati predviđanja protoka za rijeku Bunu u Bosni i Hercegovini za jedan dan unaprijed, na osnovi podataka o oborinama i protoku u prehodna dva dana, pokazuju da ANFIS model nadmašuje ostale modele. Analiza je pokazala da kombinacija neizrazite logike i neuronskih mreža nadilazi teškoće i ograničenja neuronskih mreža, omogućujući bolji prediktivni model.

Napravljena je i analiza utjecaja i važnost ulaznih varijabli na performanse modela. Podaci za oborine i protoke su prikupljeni na različitim lokacijama (dvije lokacije za oborine i dvije za

protoke). U svim prethodno analiziranim modelima korišteno je svih 8 ulaznih varijabli. Međutim, nemaju sve varijable isto značenje s aspekta točnosti modela i pokazano je da primjena podskupa od samo 5 ulaznih varijabli, odnosno izuzimanje 3 manje relevantne varijable, može čak omogućiti bolje rezultate. U isto vrijeme model je pojednostavljen i sam proces osposobljavanja je ubrzan.

Daljnja istraživanja trebala bi uključiti dodatne faktore koji mogu utjecati na točnost predviđanja, kao što je razina podzemnih voda, geološki sastav sliva, morfologija i vegetacija, što bi moglo pridonijeti univerzalnosti predstavljenog modela.

LITERATURA

- [1] Peng, G., Leslie, L. M., Shao, Y.: Environmental Modelling and Prediction, Eds. Springer-Verlag, pp. 215-273, 2002.
- [2] Milanović, P.: Karst Istočne Hercegovine i dubrovačkog priobalja, Beograd, 2006.
- [3] Makropoulos, C., Koutsoyiannis, D., Stanić, M., Djordjević, S., Prodanović, D., Dašić, T., Prohaska, S., Maksimović, Č., Wheeler, H.: A multi-model approach to the simulation of large scale karst flows, *Journal of Hydrology*, 348 (2008) 3-4, pp. 412-424, <https://doi.org/10.1016/j.jhydrol.2007.10.011>
- [4] Lazarevska, M., Knežević, M., Cvetkovska, M., Ivanišević, N., Samardzioska, T., Trombeva-Gavriloska, A.: Prognošički model za određivanje požarne otpornosti AB stupova, *GRAĐEVINAR*, 64 (2012) 7, pp. 565-571.
- [5] Yaseen, Z.M., El-shafie, A., Jaafar, O., Afan, H.A., Sayl, K.M.: Artificial intelligence based models for stream-flow forecasting: 2000-2015, *Journal of Hydrology*, 530 (2015), pp. 829-844, <https://doi.org/10.1016/j.jhydrol.2015.10.038>
- [6] Afan, H.A., El-shafie, A., Mohtar, W.H.M.W., Yaseen, Z.M.: Past, present and prospect of an Artificial Intelligence (AI) based model for sediment transport prediction, *Journal of Hydrology*, 541 B (2016), pp. 902-913.
- [7] Raghavendra, S.N., Deka, P.S.: Support vector machine applications in the field of hydrology: A review, *Applied Soft Computing*, 19 (2014), pp. 372-386, <https://doi.org/10.1016/j.asoc.2014.02.002>
- [8] Ireland, G., Volpi, M.P., Petropoulos, P.G.: Examining the Capability of Supervised Machine Learning Classifiers in Extracting Flooded Areas from Landsat TM Imagery: A Case Study from a Mediterranean Flood, *Remote Sensing*, 7 (2015) 3, pp. 3372-3399.
- [9] Kostic, S., Stojkovic, M., Prohaska, S.: Hydrological flow rate estimation using artificial neural networks: Model development and potential applications, *Applied Mathematics and Computation*, 291 (2016), pp. 373-385, <https://doi.org/10.1016/j.amc.2016.07.014>
- [10] Sanikhani, H., Kisi, O., Kiafar, H., Ghavidel, S.Z.Z.: Comparison of Different Data-Driven Approaches for Modeling Lake Level Fluctuations: The Case of Manyas and Tuz Lakes (Turkey), *Water Resources Management*, 29 (2015) 5, pp. 1557-1574.
- [11] Rezaei-zadeh, M., Tabari, H., Yazdi, A.A., Isik, S., Kalin, L.: Flood flow forecasting using ANN, ANFIS and regression models, *Neural Computing and Applications*, 25 (2014) 1, pp. 25-37.
- [12] Bui, D.T., Pradhan, B., Nampak, H., Bui, Q.T., Tran, Q.A., Nguyene, Q.P.: Hybrid artificial intelligence approach based on neural fuzzy inference model and metaheuristic optimization for flood susceptibility modeling in a high-frequency tropical cyclone area using GIS, *Journal of Hydrology*, 540 (2016), pp. 317-330, <https://doi.org/10.1016/j.jhydrol.2016.06.027>
- [13] Chang, F.J., Tsai, Y.H., Chen, P.A., Coynel, G.: Modeling water quality in an urban river using hydrological factors - Data driven approaches, *Journal of Environmental Management*, 151 (2015), pp. 87-96, <https://doi.org/10.1016/j.jenvman.2014.12.014>
- [14] Granata, F., Gargano, R., de Marinis, G.: Support Vector Regression for Rainfall-Runoff Modeling in Urban Drainage: A Comparison with the EPA's Storm Water Management Model. *Water*, 8 (2016) 3.
- [15] Hosseini, S.M., Mahjour, N.: Integrating Support Vector Regression and a geomorphologic Artificial Neural Network for daily rainfall-runoff modeling, *Journal Applied Soft Computing*, 38 (2016) C, pp. 329-345.
- [16] Gizaw, M.S., Gan, T.Y.: Regional Flood Frequency Analysis using Support Vector Regression under historical and future climate, *Journal of Hydrology*, 538 (2016), pp. 387-398, <https://doi.org/10.1016/j.jhydrol.2016.04.041>
- [17] He, Z., Wen, X., Liu, H., Du, Jun.: A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region, *Journal of Hydrology*, 509 (2014), pp. 379-386, <https://doi.org/10.1016/j.jhydrol.2013.11.054>
- [18] Gong, Y., Zhang, Y., Lan, S., Wang, H.: Comparative Study of Artificial Neural Networks, Support Vector Machines and Adaptive Neuro Fuzzy Inference System for Forecasting Groundwater Levels near Lake Okeechobee, Florida, *Water Resources Management*, 30 (2016) 1, pp. 375-391.
- [19] Beale, M.H., Hagan, M.T., Demuth, H.B.: *Neural Network Toolbox™ User's Guide*, The MathWorks, Inc, 2010.
- [20] Matić, P.: Predviđanje dotoka rijeke Cetine u akumulaciju Peruća pomoću umjetne neuronske mreže, Kvalifikacijski doktorski rad, Fakultet elektrotehnike strojarstva i brodogradnje u Splitu, Sveučilište u Splitu, 2012.
- [21] Kingston, G.B.: Bayesian Artificial Neural Networks in Water Resources Engineering, doctoral dissertation, School of Civil and Environmental Engineering, Faculty of Engineering, Computer and Mathematical Science, University of Adelaide, Australia, 2006.

- [22] Araghinejad, S.: Data-Driven Modeling: Using MATLAB® in Water Resources and Environmental Engineering, Water Science and Technology Library, 67 (2014), pp. 139-193, <https://doi.org/10.1007/978-94-007-7506-0>
- [23] Legates, D.R., McCabe, G.J. Jr.: Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation, Water Resources Research, 35 (1999) 1, pp. 233-241.
- [24] Safari, M.J.S., Aksoya, H., Mohammadi, M.: Artificial neural network and regression models for flow velocity at sediment incipient deposition, Journal of Hydrology, 541,B (2016), pp.1420-1429.
- [25] Chang, C.C., Lin, C.J., LIBSVM: a library for support vector machines. ACM Transactions on Intelligent Systems and Technology, 2:27:1-27:27, 2011.
- [26] <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- [27] Sumathi, S., Paneerselvam, S.: Computational Intelligence Paradigms: Theory & Applications using MATLAB, CRC Press, pp. 351-393, 2010.
- [28] Theodoridis, S., Koutroumbas, K.: An introduction to Pattern Recognition: A MATLAB® Approach, Academic Press, pp. 122-135, 2009.
- [29] Theodoridis, S., Koutroumbas, K.: Pattern Recognition, Academic Press, pp. 261-318, 2009, <https://doi.org/10.1016/B978-1-59749-272-0.50007-4>