

Primljen / Received: 23.1.2018.  
 Ispravljen / Corrected: 10.5.2018.  
 Prihvaćen / Accepted: 24.6.2018.  
 Dostupno online / Available online: 10.4.2020.

# Predviđanje maksimalnih godišnjih poplavnih protoka primjenom umjetnih neuronskih mreža

## Autori:



Doc.dr.sc. **Tugce Anilan**, dipl.ing.građ.  
 Tehničko sveučilište Karadeniz, Turska  
 Građevinski fakultet  
 koctugce@gmail.com  
 Autor za korespondenciju

Prethodno priopćenje

[Tugce Anilan, Sinan Nacar, Murat Kankal, Omer Yuksek](#)

## Predviđanje maksimalnih godišnjih poplavnih protoka primjenom umjetnih neuronskih mreža

U radu se istražuje primjenjivost pristupa umjetnih neuronskih mreža (ANN) za određivanje maksimalnih godišnjih protoka. Uspoređuju se učinkovitost triju modela neuronskih mreža: višeslojne perceptronske neuronske mreže (MLP\_NN), generalizirane neuronske mreže usmjerene prema naprijed (GFF\_NN) i analiza osnovnih komponenata pomoću neuronskih mreža (PCA\_NN). Predloženi pristupi primjenjeni su na 33 vodomjerne. Utvrđeno je da je optimalna metoda PCA\_NN s tri skrivena sloja prikladnija za određivanje maksimalnih godišnjih protoka od optimalnih modela MLP\_NN i GFF\_NN.

### Ključne riječi:

umjetne neuronske mreže, analiza osnovnih komponenata, maksimalni godišnji protoci

Research paper

[Tugce Anilan, Sinan Nacar, Murat Kankal, Omer Yuksek](#)

## Prediction of maximum annual flood discharges using artificial neural network approaches

The applicability of artificial neural network (ANN) approaches for estimation of maximum annual flows is investigated in the paper. The performance of three neural network models is compared: multi layer perceptron neural networks (MLP\_NN), generalized feed forward neural networks (GFF\_NN), and principal component analysis with neural networks (PCA\_NN). The proposed approaches were applied to 33 stream-gauging stations. It was found that the optimal 3-hidden layered PCA\_NN method was more appropriate than the optimal MLP\_NN and GFF\_NN models for the estimation of maximum annual flows.

### Key words:

artificial neural networks, principal component analysis, maximum annual flows

Vorherige Mitteilung

[Tugce Anilan, Sinan Nacar, Murat Kankal, Omer Yuksek](#)

## Vorhersage der maximalen jährlichen Hochwasserflüsse durch Anwendung künstlicher neuronaler Netze

In der Abhandlung wird die Anwendbarkeit des Ansatzes neuronaler Netze (ANN) zur Bestimmung maximaler jährlicher Durchflüsse untersucht. Verglichen wird die Leistung dreier neuronaler Netzmodelle: mehrlagige perzeptron-neuronale Netze (MLP\_NN), generalisierte vorwärtsgerichtete neuronale Netze (GFF\_NN) und Analyse der Hauptkomponenten mithilfe des neuronalen Netzes (PCA\_NN). Die vorgeschlagenen Ansätze wurden bei 33 Wassermessstationen angewendet. Es wurde festgestellt, dass die optimale PCA\_NN-Methode mit drei verborgenen Schichten zur Bestimmung der maximalen jährlichen Durchflussraten besser geeignet ist, als die optimalen MLP\_NN- und GFF\_NN-Modelle.

### Schlüsselwörter:

künstliche neuronale Netze, Analyse der Hauptkomponenten, maximale jährliche Durchflüsse



Izv.prof.dr.sc. **Murat Kankal**, dipl.ing.građ.  
 Sveučilište Uludag, Turska  
 Građevinski fakultet  
 mkankal06@gmail.com



Prof.dr.sc. **Omer Yuksek**, dipl.ing.građ.  
 Tehničko sveučilište Karadeniz, Turska  
 Građevinski fakultet  
 yuksek@ktu.edu.tr

## 1. Uvod

U Turskoj su poplave jedna od najrazornijim prirodnih nepogoda, a po svojim su posljedicama rangirane odmah iza potresa. U posljednjih stotinjak godina zabilježen je velik broj poplava sa znatnim brojem ljudskih žrtava i velikim materijalnim štetama. Mnoge su naplavne doline gusto naseljene i industrijalizirane. Međutim, u mnogim slučajevima na takvim lokacijama postoje tek oskudni ili čak nikakvi podaci o godišnjim maksimalnim protocima. Mnogi nizovi godišnjih podataka o protoku ne obuhvaćaju dovoljno dugo razdoblje te stoga ne omogućuju točniju procjenu razornih poplava. Zbog toga se za kontrolu poplava i planiranje hidrotehničkih građevina sve više koriste, naročito u Turskoj, regionalni podaci, a na temelju njih se procjenjuje nailazak velikih voda na lokacijama za koje nema odgovarajućih podataka ili su dostupni podaci nedovoljni.

Tijekom godina su razvijeni brojni postupci za određivanje poplavnog protoka. Ti se postupci mogu podijeliti u tri grupe: parametarske metode, regresijske metode i metode koji se temelje na umjetnoj inteligenciji. Značajne nove spoznaje o određivanju poplavnih protoka stečene su na temelju regionalne analize učestalosti prema ideji o ponderiranim momentima vjerojatnosti koje je uveo Greenwood [1] i teoriji momenata L koju je predložio Hosking [2]. Momenți L, određene linearne kombinacije ponderiranih momenata vjerojatnosti, mogu se definirati kao mjere lokacije, opseg i oblika distribucije vjerojatnosti, te čine osnovu opsežne teorije opisivanja, definiranja i procjenjivanja raspodjela. Pristup pomoću momenata L u regionalnoj analizi učestalosti uspješno je primjenjen u većem broju studija u Južnoafričkoj Republici [3], Velikoj Britaniji [4], Indiji [5], Kanadi [6], Kini [7], Egiptu [8], Iranu [9], Maleziji [10], Italiji [11, 12], Keniji [13] i Turskoj [14-16].

Prostorne varijacije u analizi učestalosti blisko su povezane s varijacijama regionalnih meteoroloških i fiziografskih faktora. Stoga se za procjenu statističkih podataka o protoku često koriste regresijski modeli. Razne kvantilne procjene bazirane na regresijskim modelima [17-22] jasno pokazuju da su metode regionalizacije poplava, bazirane na regresijskim modelima, pouzdan način za određivanje poplavnog protoka primjenom varijabli ovisnih o karakteristikama neizučenih lokacija (bez mjerena).

Hidrološki procesi su uglavnom izrazito nelinearni, promjenjivi u vremenu, te prostorno distribuirani. Umjetne neuronske mreže (eng. *Artificial Neural Network* - ANN) se odlikuju fleksibilnom matematičkom strukturu koja omogućuje određivanje kompleksnih nelinearnih odnosa između ulaznih i izlaznih parametara bez prethodnog poznavanja specifičnih fizičkih procesa koji se odvijaju u okviru transformacije [23]. Posljednjih se godina umjetne neuronske mreže (ANN) uspješno koriste za izravno mapiranje složenih nelinearnih odnosa. Dokazano je da ANN pružaju učinkovitu alternativu tradicionalnim metodama za modeliranje kvalitativnih i kvantitativnih varijabli vezanih uz vodne resurse [24-26], te da

se u hidrologiji mogu koristiti za različite namjene. U studiji koju su izradili Shu i Burn [27], takve mreže služe za indeksiranje poplava te za procjenu kvantila poplavnih voda. Analizom primjene na odabranim slivovima u Velikoj Britaniji utvrđeno je da se model ANN ponaša bolje od metoda višestruke linearne regresije. Smatra se također da su modeli ANN vrlo korisni i primjenjivi, i to naročito za rješavanje problema kod kojih se postupci teško mogu definirati pomoću fizikalnih jednadžbi [23]. Aziz i dr. [28] istražili su primjenjivost modela ANN u analizi učestalosti regionalnih poplava (RFFA) te su usporedili rezultate modela RFFA utemeljenih na ANN s regresijskom analizom. Ustanovili su da se model RFFA utemeljen na ANN bolje ponaša od modela kod kojih je korištena regresijska analiza. Seckin i dr. [29] razvili su modele ANN, linearne i nelinearne modele, kao alternativu metodi momenata L radi ocjenjivanja vršnih vrijednosti velikih voda za različita povratna razdoblja. Procjena produktivnosti višeslojnog perceptronskog modela ANN pokazuje da je taj model znatno učinkovitiji od ostalih. Anilan i dr. [16] istražili su provedivost metode ANN bazirane na momentima L u predviđanju velikih voda na temelju niza podataka za Istočni crnomorski sliv (eng. *Eastern Black Sea Basin* - EBSB). Primijenjeni model ANN pokazao se boljim od regresijskih modela, što pokazuje da je ANN prikladniji za određivanje velikih voda na lokacijama bez mjerena.

U ovom se radu na temelju niza podataka uspoređuje primjenjivost triju modela ANN za ocjenjivanje velikih voda u području EBSB. Ponašanje svake metode ocijenjeno je pomoću vrijednosti srednje apsolutne pogreške (eng. *mean absolute error* - MAE), srednje kvadratne pogreške (eng. *mean squared error* - MSE), korijena srednje kvadratne pogreške (eng. *root mean square error* - RMSE) i relativne pogreške (eng. *relative error* - RE).

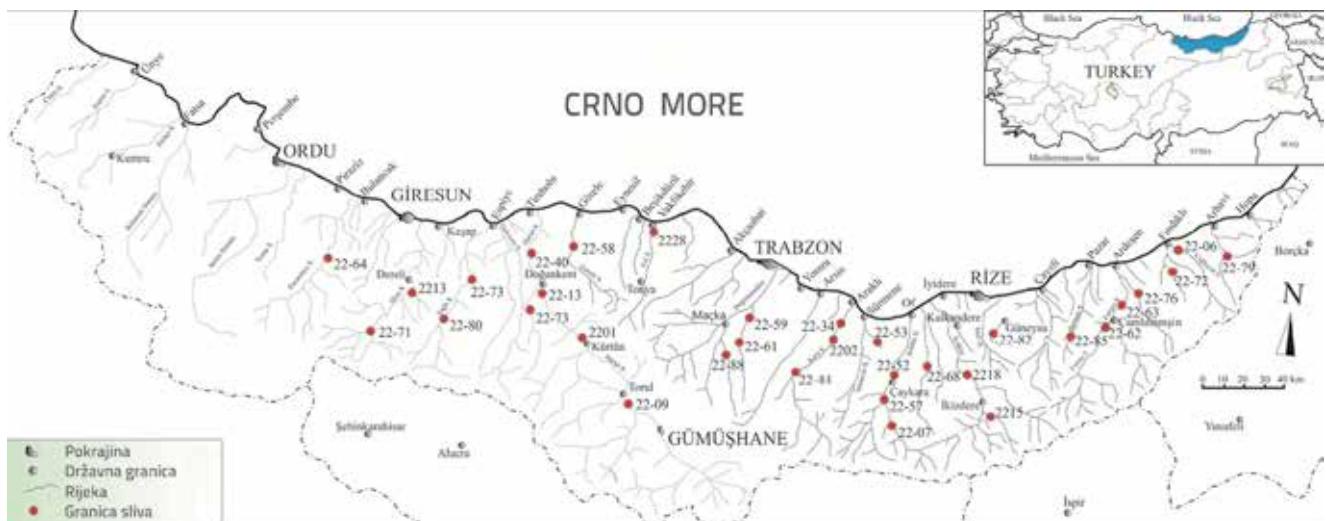
## 2. Analizirano područje i korišteni podaci

Crnomorska obala, na kojoj se bilježe najveće količine oborina, jedino je područje u Turskoj u kojem kiša pada tijekom čitave godine. Istočni crnomorski sliv smješten je na sjeveroistočnoj obali Turske, kao što je to prikazano na slici 1. Sliv je omeđen istočnim crnomorskog planinama na jugu te Crnim morem na sjeveru. Sliv zauzima ukupnu površinu od 24.077 km<sup>2</sup>, s dotokom od 14,9 km<sup>3</sup> vode te s prosječnim dotokom od 19,5 l/s/km<sup>2</sup> [30]. Na slivu EBSB zabilježene su prosječne godišnje oborine od približno 1.100 mm, a taj se iznos povećava čak i do 2.300 mm u blizini pokrajine Rize [31]. U tom se području tlo uglavnom sastoji od nepropusnih ili polupropusnih vulkanskih stijena koje onemogućuju procjeđivanje vode pa tako do otjecanja dolazi površinskim putem [30]. Određivanje velikih voda bitno je za ovaj kraj jer je opasnost od poplave velika zbog hidroloških i topografskih obilježja toga područja. U ovom se radu analiziraju dvije osnovne vrste podataka:

- podaci o protoku (godišnje maksimalne velike vode)
- podaci o karakteristikama sliva (fiziografski, meteorološki i hidrološki podaci).



Slika 1. Prikaz sliva EBSB (Istočni crnomorski sлив)



Slika 2. Lokacije vodomjernih stanica na slivu EBSB (Istočni crnomorski sлив)

Vodomjernim stanicama u Turskoj upravlja Opća uprava za državne hidrotehničke radove (DSI) [32]. U početku su bile odabrane ukupno 53 stanice, a zatim je njihov broj smanjen na 38 zbog neodgovarajućih podataka o protoku i zbog nedovoljno dugog razdoblja mjerjenja. Tako u obzir nisu uzeta vodomjerna razdoblja kraća od deset godina, jer to utječe na točnost predviđanja maksimalnih godišnjih protoka i povratnih razdoblja. Osim toga, iz analize su izuzete i stanice koje su definirane kao heterogene na temelju testova homogenosti i heterogenosti pomoću momenata L. Na kraju su podaci o godišnjim maksimalnim protocima prikupljeni s 33 vodomjerne stанице (SGS) za koje su postojali podaci o mjerjenjima u razdobljima od 10 do 42 godine. Lokacije stanica koje su korištene u ovom istraživanju prikazane su na slici 2.

Regresijska je analiza provedena radi određivanja nezavisnih varijabli koje utječu na veličinu velikih voda. Definirani su razni modeli s nelinearnim regresijskim funkcijama. Na temelju vršnih vrijednosti velikih voda i karakteristika sliva u modelima se dobiva jednadžba kojom se najbolje opisuje odnos između dva niza podataka. Karakteristike korištene u ovom radu uključuju: podatke o površini sliva, nadmorskoj visini, srednjim godišnjim

oborinama, nagibu glavnog vodotoka, gustoći vodotoka, te o povratnom razdoblju. Odabir nezavisnih varijabli korištenih u regresijskim jednadžbama proveden je na temelju prijašnjih studija kako je to prikazano u tablici 1. Na temelju modela s tim varijablama utvrđeno je da su one značajne te da bitno utječu na velike vode, a u svojoj studiji navode Aziza i dr. [28]. I, konačno, u ovom su radu korištene sljedeće nezavisne varijable: površine slivova s vodomjernim stanicama iskazani u četvornim kilometrima (A) te nadmorska visina izražena u m (E); srednje godišnje oborine u mm (R); nagib glavnog vodotoka iskazan u m/km (S); vrijednosti gustoće vodotoka iskazane u km/km<sup>2</sup> (D), te povratna razdoblja izražena u godinama (T).

Prosječni obuhvat slivnih područja vodomjernih stanica iznosi 775 km<sup>2</sup>, a raspon varira od 83 do 3.132 km<sup>2</sup>. Prema podacima dobivenima od Uprave za hidrotehničke radove (DSI), raspon nadmorskih visina na kojima se nalaze vodomjerne stanice varira od 17 do 1150 m, pri čemu prosječna vrijednost iznosi 433,24 m. Podaci o srednjim godišnjim količinama oborina (u mm), iskazani za razna standardna razdoblja na meteorološkim stanicama u analiziranoj regiji, dobiveni su od Turske državne meteorološke službe [33]. Podaci o

**Tablica 1. Nezavisne varijable korištene u prijašnjim studijama**

Autori	Usvojene nezavisne varijable
Jingyi i Hall (2004.)	A, R, S, E, dužina osnovnog vodotoka, indeks geoloških obilježja, indeks biljnog pokrova
Shu i Burn (2004.)	A, R, vrsta tla s obzirom na sposobnost procjeđivanja
Leclerc i dr. (2007.)	A, R, zemljopisna širina vodomjernih stanica, zemljopisna dužina vodomjernih stanica, srednja temperatura zraka
Palmen i Weeks (2011.)	A, R, S, I, D, dužina rijeke, područje nanosa, područje s biljnim pokrovom, evapotranspiracija
Malekinezhad i dr. (2011.)	R, dužina osnovnog vodotoka, koeficijent koncentriranosti sliva, srednja godišnja temperatura
Haddad i dr. (2012.)	A, R, I, D, srednja godišnja evapotranspiracija
Aziz i dr. (2013.)	A, R, S, I, evapotranspiracija
Seckin i dr. (2013.)	A, E, zemljopisna širina, zemljopisna dužina, povratno razdoblje
Ovaj rad (2014.)	A, R, S, E, D, povratna razdoblja

\*A - površina sliva, R - srednje godišnje oborine, S - nagib vodotoka, E - nadmorska visina, I - intenzitet oborina, D - gustoća vodotoka

nagibima glavnih vodotoka i gustoćama vodotoka preuzeti su iz Sakaova rada [34]. T vrijednosti za pojedinačne poplavne protoke preuzete su iz Anilanova rada [35] i Anilanova rada sa suradnicima [16]. Dotične su vrijednosti izračunane analizom učestalosti na bazi momenata L za nizove godišnjih vršnih protoka izmjerena na pojedinim vodomjernim stanicama. Vrijednosti T za svaki vršni protok izračunane su pomoću lognormalne distribucije, tj. najprikladnije distribucije za dotičnu regiju. Seckin i dr. [29] navode da je odnos između  $\ln(Q)$  i nezavisnih varijabli značajniji od slučaja kada se Q koristi kao zavisna varijabla. Zato su u ovom radu kao zavisna varijabla korištene vrijednosti  $\ln(Q)$ .

### 3. Pristupi ANN

Umetne neuronske mreže (ANN) fleksibilne su matematičke strukture koje omogućuju određivanje složenih nelinearnih odnosa ili uzoraka između nizova ulaznih i izlaznih parametara, isto kao i procjenu izlaznih vrijednosti na temelju postupaka treninga i učenja. Osnovne razlike između različitih vrsta mreža ANN sastoje se u rasporedu neuroda (arhitektura mreže) i u različitim načinima određivanja težinskih faktora (w) i funkcija za ulaze (x) i neurode (trening) [36].

#### 3.1. Višeslojne perceptronske neuronske mreže (MLP\_NN)

Otkako je uveden algoritam učenja pomoću povratnog prostiranja (BP) greške, višeslojni perceptroni uspješno se koriste za rješavanje raznih problema. Osnovna prednost mreža MLP\_NN sastoje se u jednostavnosti njihove primjene te u sposobnosti aproksimiranja ulazne/izlazne mape [37, 38]. Mreža MLP\_NN sastoje se od jednog ili više skrivenih slojeva, a njihovi računalni čvorovi nazivaju se skrivenim neuronima skrivenih jedinica. Općenito uzevši, skriveni neuroni zaduženi su za kontakte između vanjskog ulaza i izlaza iz mreže. Mreža može ekstrahirati statistiku višeg reda kada se sustavu doda jedan ili više skrivenih slojeva. Ova sposobnost skrivenih

neurona posebno je značajna kada se radi o velikom ulaznom sloju. Mreža MLP\_NN trenira se vođenjem određenog ulaza do odgovarajućeg željenog (ciljanog) izlaza. Težinski faktori se kalibriraju na bazi usporedbe izlaza i željenog izlaza, sve dok izlaz iz mreže ne postane podudaran sa željenim izlazom [39-41].

#### 3.2. Generalizirane naprijed usmjerene neuronske mreže (GFF\_NN)

Generalizirane naprijed usmjerene neuronske mreže (GF\_NN) predstavljaju generalizaciju mreže FF\_NN koja se sastoji od nekoliko skrivenih slojeva generaliziranih neurona, te od izlaznog sloja generaliziranih, sigmoidnih ili linearnih neurona [42]. Kako mreže GF\_NN uključuju velik broj spojeva, ta vrsta mreže može se uglavnom brže trenirati nego što je to slučaj kod negeneraliziranih mreža MLP\_NN [43]. Prilagođavanjem težinskih faktora, neuronska se mreža usmjerava prema optimalnom rješenju baziranom na mjerenu njene učinkovitosti [44].

#### 3.3. Analiza osnovnih komponenata pomoću neuronskih mreža (PCA NN)

Osnovni analitički cilj analize PCA sastoji se u reduciraju dimenzija informacija kompiliranih u nizu podataka, pri čemu se treba sačuvati prvobitna varijabilnost podataka [45]. Analizom PCA transformiraju se prvo bitne varijable u nove nekorelirane varijable (osi) koje nazivamo osnovnim komponentama, a one su zapravo linearne kombinacije prvo bitnih varijabli [46]. Osnovna se komponenta (PC) može izraziti kako je iskazano izrazom (1):

$$Z_{ij} = a_{i1}x_{1j} + a_{i2}x_{2j} + a_{i3}x_{3j} + \dots + a_{im}x_{mj} \quad (1)$$

gdje je Z rezultat komponente, a je težinski udio komponente, x je izmjerena vrijednost varijable, i je broj komponente, j je broj uzorka, a m je ukupan broj varijabli [47].

### 3.4. Algoritmi za trening neuronskih mreža

U ovom se radu koriste dva različita algoritma za trening ANN mreža: algoritam povratnog prostiranja (BP) i konjugirani gradijent (CG). Ti se različiti algoritmi koriste kako bi se ustanovilo kojim od njih se postižu bolji rezultate za potrebe ovog istraživanja [48]. U nastavku se daju osnovne informacije o tim algoritmima.

#### 3.4.1. Algoritam povratnog prostiranja

Algoritam povratnog prostiranja (BP) ne samo da se najčešće koristi u neuronskim mrežama već je to i jedan od najsnažnijih algoritama. Algoritam BP razvili su Rumelhart i dr. (1986.) [49]. Taj se algoritam koristi kako bi se odredili optimalni težinski faktori za generiranje izlaznog vektora koji bi u što većoj mjeri odgovarao željenim izlaznim vrijednostima za izlazni vektor, pri zadanoj razini točnosti. Prema izračunanoj vrijednosti greške u odnosu između izračunane i izmjerene izlazne vrijednosti, algoritam se povratno prostire prema slojevima. Težinski faktori se zatim ažuriraju ovisno o njihovom doprinosu funkciji greške [48, 50]. Detaljniji podaci o ovom algoritmu mogu se naći u radovima Kisi i Uncuoglu (2005.) [48], Nacar i dr. (2017.) [51] i u udžbenicima o umjetnim neuronskim mrežama.

#### 3.4.2. Konjugirani gradijent

Ovaj se postupak razlikuje od greške BP u izračunu gradijenta i naknadnim korekcijama težinskih faktora i pristrane greške [52, 53]. Ovdje se pravac pretraživanja izračunava u svakoj iteraciji treninga  $k$ , a funkcija greške  $f(X)$  minimalizira se usporedno s provođenjem linijskog pretraživanja. Pad gradijenta nije povezan s gradijentom greške kao u prethodno navedenoj metodi povratnog prostiranja već se odvija u smjeru koji je konjugiran s prethodnim korakom. Stoga je promjena gradijenta ortogonalna u odnosu na prethodni korak, ali je prednost u tome što je minimaliziranje funkcije, koje se provodi u svakom koraku, u potpunosti očuvano zato što nema interferencije sljedećih

koraka. Detaljne informacije o tim dobro poznatim algoritmima mogu se naći u radovima Thirumalaiaha i Deoa (1998.) i Kisia (2007.) [54, 55].

### 3.5. Postupak treninga

Ovdje je osnovni cilj razviti model ANN pomoću tri različita modela neuronskih mreža i pomoću dva različita algoritma treninga, kojima se procjenjuje poplavni protok primjenom niza podataka za sliv EBSB. Prilikom definiranja arhitekture mreže ANN, važno je odabrati odgovarajuću njezinu veličinu. Iako mreža ANN može imati i više od jednog skrivenog sloja, teoretski su radovi pokazali da je jedan skriveni sloj dovoljan za aproksimaciju bilo koje složene nelinearne funkcije pomoću mreže ANN [56, 57]. Međutim, u ovom su radu korišteni ne samo modeli s jednim skrivenim slojem već i modeli s dva skrivena sloja. Svaki je sloj potpuno povezan sa sljedećim, ali neuroni u istom sloju nisu međusobno povezani. Prvi i treći sloj sadrži ulazne tj. izlazne podatke. Broj neurona u skrivenim slojevima utvrđen je primjenom jednostavne metode pokušaja i pogreške od tri do devet u svim aplikacijama. Spojevi između ulaznog sloja i središnjeg ili skrivenog sloja sadrže težinske faktoare (pondere), koji se obično određuju treniranjem sustava. Skriveni sloj zbraja ponderirane ulaze i koristi prijenosnu funkciju za dobivanje izlazne vrijednosti. Prijenosna funkcija je odnos između unutarnje aktivacijske razine neurona (koju nazivamo aktivacijskom funkcijom) i izlaznih vrijednosti [36]. U ovom se radu u skrivenim i izlaznim slojevima koriste dvije različite prijenosne funkcije, tj. hiperbolična tangentna funkcija i sigmoidna funkcija. Pouraghhi i dr. [57] koriste tangentne aksonske i sigmoidne aksonske funkcije za predviđanje ulaznog protoka pomoću mreža ANN. Fayed i Abdelbary [58] također navode da je primjena sigmoidne aksonske funkcije djelotvornija za hidrološka predviđanja pomoću mreža ANN. U ovom se radu analiziraju tangentne aksonske funkcije i sigmoidne aksonske funkcije i njihove kombinacije u skrivenim i izlaznim slojevima kako bi se utvrdila njihova učinkovitost. Usvojeno je da razine učenja i momenta algoritma BP iznose 1 tj. 0,7. Dostupni

Tablica 2. Ulazni i izlazni podaci korišteni u analizi

Skup podataka	Statistika	Povratno razdoblje, T [godina]	Površina sliva, A [km <sup>2</sup> ]	Gustoća vodotoka, SD [km/km <sup>2</sup> ]	Nagib vodotoka, S [m/km]	Visina, E [m]	Srednja godišnja količina oborina, R [mm]	Ln Q (protok) [m <sup>3</sup> /s]
Treniranje	Min.	1,013	83,3	192,6	0,022	17	208,556	2,272
	Sred.	5,829	637,102	267,675	0,051	467,673	1166,3	4,303
	Maks.	501,971	3132,8	446,3	0,084	1150	3332,2	6,594
Testiranje	Min.	1,022	258,6	167,2	0,029	90	414,6	2,912
	Sred.	4,619	441,364	241,096	0,043	345,925	774,88	4,234
	Maks.	63,099	576,8	284	0,058	530	1343,8	5,198
Validacija	Min	1,007	162,7	237,7	0,031	78	434,339	3,281
	Sred.	5,134	544,779	266,178	0,049	252,646	1139,9	4,571
	Maks.	83,394	834,9	328,5	0,064	400	2443,488	6,223

skup podataka (909 opažanja) podijeljen je na tri podskupa: trening (668), validacija (108) i testiranje (133). Sve su varijable odabrane nasumice bez obzira na stanice. Ukupno je otprilike 73 % podataka korišteno za trening, 12 % za validaciju i 15 % za testiranje. Minimalne, prosječne i maksimalne vrijednosti skupa podataka prikazane su u tablici 2.

Neuronskim se mrežama obično postižu bolji rezultati ako se koriste standardizirani podaci. Korištenje originalnih podataka kao ulaznih vrijednosti za neuronsku mrežu može uzrokovati problem konvergencije [16]. Svi skupovi podataka zato su transformirani u vrijednosti od 0,1 do 0,9 kako slijedi:

$$\text{Stand. vrijednost} = \left[ \frac{\text{Neobrađena vrijednost} - \text{min. vrijednost}}{\text{Maks. vrijednost} - \text{min. vrijednost}} \right] \times (0,9 - 0,1) + 0,1 \quad (2)$$

Ponašanje modela, razvoj i validacijski koraci ocijenjeni su izračunavanjem statističkih parametara RMSE, RE, MAE i MSE, kako je to prikazano u Izrazima (3) do (6):

$$\text{RMSE} = \left[ \frac{1}{N} \sum_{i=1}^N \left( \ln(Q)_{\text{observed}} - \ln(Q)_{\text{predicted}} \right)^2 \right]^{1/2} \quad (3)$$

$$\text{RE} = \frac{\sum_{i=1}^n \left( \frac{\ln(Q)_{\text{observed}} - \ln(Q)_{\text{predicted}}}{\ln(Q)_{\text{observed}}} \right)}{N} \times 100 \quad (4)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N \left| \ln(Q)_{\text{observed}} - \ln(Q)_{\text{predicted}} \right| \quad (5)$$

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N \left( \ln(Q)_{\text{observed}} - \ln(Q)_{\text{predicted}} \right)^2 \quad (6)$$

## 4. Rezultati i rasprava

Tri metode utemeljene na neuronskim mrežama analizirane su primjenom godišnjih vršnih protoka zabilježenih na 33

vodomjerne stanice (SGS) kako bi se predvidjele velike vode na neizučenim slivnim područjima. Metode MLP\_NN, GFF\_NN i PCA\_NN prilagođene su podacima šest nezavisnih varijabli i LnQ. Kako je objašnjeno u postupku treninga, za sve korištene modele ANN, skupovi podataka podijeljeni su na skupove podataka za trening, validaciju i testiranje. Kao što se može vidjeti u tablici 3., skriveni slojevi s odgovarajućim brojem različitih elemenata za obradu korišteni su za svaku od tri vrste metoda ANN, a pritom su upotrijebljene sigmoidne aksonске i hiperbolične tangentne aksonске prijenosne funkcije. Algoritmi učenja BP i CG analizirani su određivanjem vrijednosti MSE, RMSE, MAE i RE za validacijski skup podataka i za skup podataka za testiranje. Svaka od tri metode za različite elemente obrade (PE) upozorila je na znatne promjene vrijednosti grešaka u algoritmima učenja (trening). Modeli s CG algoritmom u svakoj su metodi uglavnom imali niže vrijednosti greške u odnosu na modele s algoritmom BP, kao što je to prikazano u tablicama 3. i 4. Najniža vrijednost RMSE za validacijski skup podataka iznosila je 0,21, što je određeno primjenom metode PCA\_NN i algoritmom CG uz korištenje modela s tri skrivena sloja. Osim toga, najniža vrijednost RMSE za skup podataka za testiranje iznosila je 0,30, što je također određeno pomoću metode PCA\_NN i algoritmom CG. Vrsta prijenosne funkcije također bitno utječe na učinkovitost modela ANN. Rezultati analize pokazuju da se sigmoidna aksonска prijenosna funkcija ponaša bolje od tangentne aksonске funkcije. Greške izračunane za skup validacijskih podataka modela postavljenih sa sigmoidnom aksonskom prijenosnom funkcijom niže su od vrijednosti hiperbolične tangentne aksonске prijenosne funkcije, i to u svakoj od tri metode. Vrijednosti greške modela postavljenih sa sigmoidnom aksonskom prijenosnom funkcijom za skup podataka za testiranje također su niže nego kod modela s tangentnom hiperboličnom aksonskom prijenosnom funkcijom u metodama GFF\_NN i PCA\_NN, kako je to prikazano u tablici 4.

**Tablica 3. Vrijednosti greške u metodama MLP\_NN, GFF\_NN i PCA\_NN za različite elemente obrade, prijenosne funkcije i algoritme učenja za skup podataka za validaciju**

Model	Greška	3PE				6PE				9PE			
		THYP		SIG		THYP		SIG		THYP		SIG	
		BP	CG	BP	CG	BP	CG	BP	CG	BP	CG	BP	CG
MLP_NN	RMSE	0,29	0,28	0,39	0,26	0,34	0,42	0,39	0,31	0,39	0,30	0,39	0,30
GFF_NN		0,36	0,29	0,42	0,30	0,49	0,35	0,41	0,31	0,38	0,36	0,41	0,31
PCA_NN		0,28	0,28	0,39	<b>0,21</b>	0,29	0,34	0,44	0,30	0,39	0,36	0,39	0,30
MLP_NN	MSE	0,08	0,08	0,15	0,07	0,11	0,18	0,15	0,09	0,15	0,09	0,16	0,09
GFF_NN		0,13	0,08	0,17	0,09	0,24	0,12	0,17	0,09	0,15	0,13	0,17	0,10
PCA_NN		0,08	0,08	0,15	<b>0,04</b>	0,09	0,12	0,19	0,09	0,16	0,13	0,16	0,09
MLP_NN	MAE	0,23	0,21	0,30	0,21	0,28	0,33	0,30	0,24	0,31	0,21	0,30	0,24
GFF_NN		0,30	0,23	0,32	0,21	0,39	0,28	0,31	0,25	0,30	0,27	0,31	0,25
PCA_NN		0,22	0,23	0,30	<b>0,17</b>	0,23	0,28	0,34	0,24	0,32	0,29	0,30	0,22
MLP_NN	RE	5,55	5,06	7,24	5,09	6,72	8,17	7,22	5,91	7,38	5,15	7,26	5,73
GFF_NN		7,16	5,66	7,56	5,17	9,85	6,67	7,55	6,08	7,08	6,72	7,56	6,00
PCA_NN		5,31	5,45	7,17	<b>4,05</b>	5,65	6,75	8,25	5,74	7,54	7,00	7,27	5,54

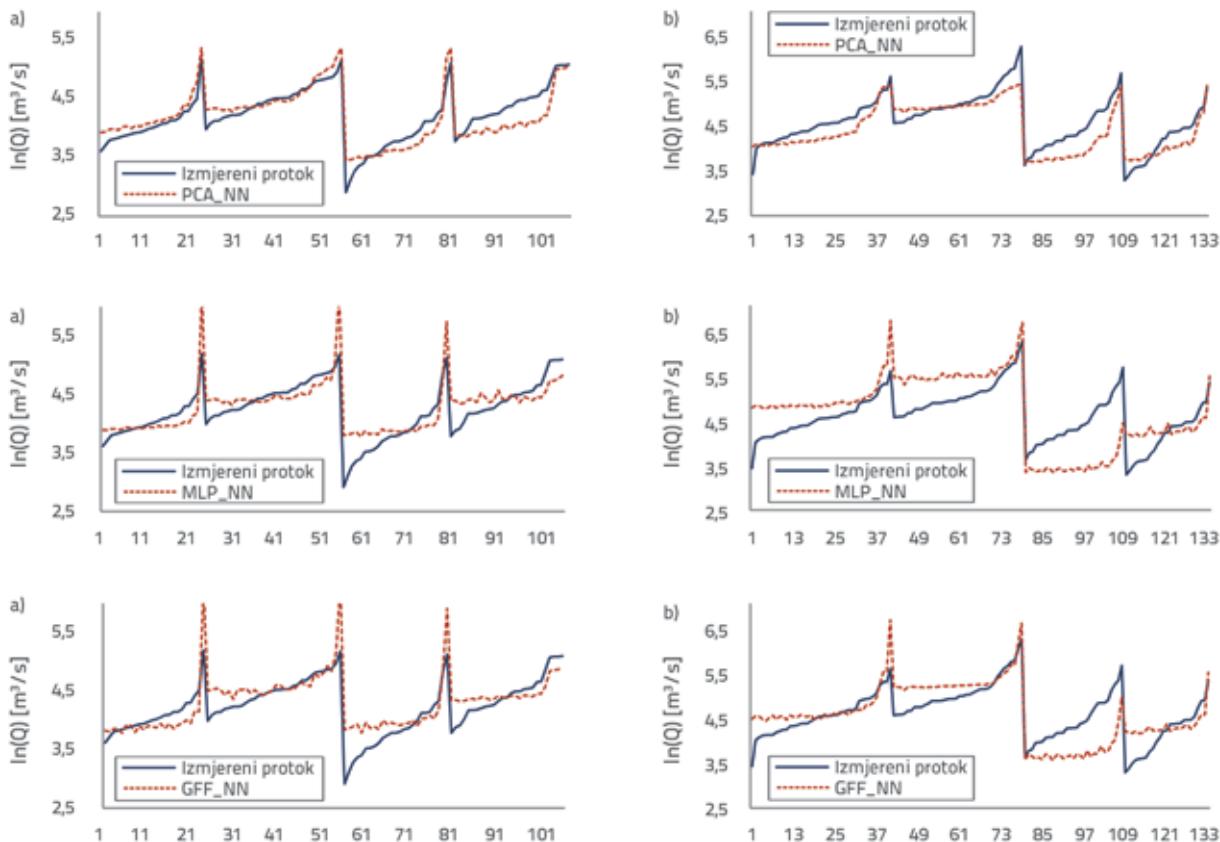
Tablica 4. Vrijednosti greške u metodama MLP\_NN, GFF\_NN i PCA\_NN za različite elemente obrade, prijenosne funkcije i algoritme učenja za skup podataka za testiranje

Model	Greška	3PE				6PE				9PE			
		THYP		SIG		THYP		SIG		THYP		SIG	
		BP	CG	BP	CG	BP	CG	BP	CG	BP	CG	BP	CG
MLP_NN	RMSE	0,59	0,35	0,51	0,47	0,57	0,47	0,50	0,49	0,47	0,39	0,50	0,46
GFF_NN		0,52	0,64	0,52	0,46	0,55	0,46	0,46	0,45	0,69	0,41	0,52	0,44
PCA_NN		0,74	0,59	0,50	<b>0,30</b>	0,61	0,57	1,43	0,56	0,52	0,47	0,52	0,48
MLP_NN	MSE	0,35	0,12	0,26	0,22	0,32	0,22	0,25	0,24	0,22	0,15	0,25	0,22
GFF_NN		0,27	0,41	0,27	0,21	0,31	0,21	0,21	0,20	0,48	0,17	0,27	0,19
PCA_NN		0,55	0,34	0,25	<b>0,09</b>	0,37	0,32	2,04	0,31	0,27	0,22	0,28	0,23
MLP_NN	MAE	0,48	0,30	0,38	0,38	0,46	0,35	0,38	0,36	0,36	0,32	0,38	0,36
GFF_NN		0,39	0,52	0,39	0,35	0,44	0,35	0,35	0,35	0,56	0,33	0,39	0,33
PCA_NN		0,63	0,46	0,38	<b>0,25</b>	0,52	0,44	1,35	0,41	0,39	0,36	0,39	0,36
MLP_NN	RE	10,85	6,61	8,38	8,20	10,26	7,68	8,34	8,12	7,92	6,91	8,29	7,98
GFF_NN		8,58	11,70	8,37	7,95	9,52	7,70	7,70	7,79	11,70	7,22	8,35	7,36
PCA_NN		14,17	10,25	8,32	<b>5,46</b>	11,31	9,87	28,73	8,84	8,50	7,89	8,37	8,29

Utjecaj variranja broja skrivenih slojeva analiziran je kako bi se postigla što veća učinkovitost korištenih modela ANN. Ispitani su modeli s jednim i dva skrivena sloja. Rezultati analize prikazani u tablicama 3. i 4. pokazuju da se najbolje ponaša model ANN s

jednim skrivenim slojem. Učinkovitost modela mreže smanjuje se usporedno s povećanjem broja skrivenih neurona.

Najbolji je model dobiven pomoću algoritma učenja s konjugiranim gradijentom i sa sigmoidnom aksonskom

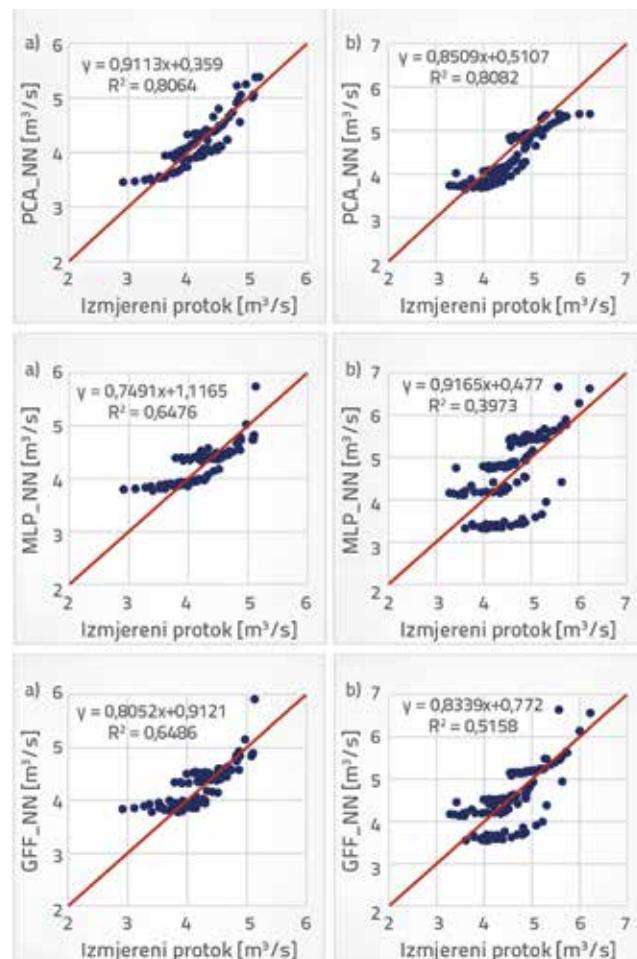


Slika 3. Izmjereni protok i izračunane velike vode za modele PCA\_NN, MLP\_NN i GFF\_NN za skupove podataka za: a) validaciju; b) testiranje

prijenosnom funkcijom s jednim skrivenim slojem neurona, stopom učenja 1, i s modelom PCA\_NN konstantnog momenta 0,7 (najniža vrijednost MSE: 0,04, RMSE: 0,21, MAE: 0,17, RE: 4,05 za skup podataka za validaciju, tj. najniža vrijednost MSE: 0,09, RMSE: 0,30, MAE: 0,25, RE: 5,46 za skup podataka za testiranje). Na slici 3., prikazani su rezultati analize skupova podataka za testiranje i validaciju primjenom modela MLP\_NN, GFF\_NN i PCA\_NN. Na slici 4., prikazan je točkasti dijagram izmjerениh i izračunanih velikih voda primjenom modela MLP\_NN, GFF\_NN i PCA\_NN za skupove podataka za validaciju i testiranje. Jasno je da optimalni model ima najniže vrijednosti greške, kako je prije objašnjeno. Poplavni protoci za razna povratna razdoblja mogu se izračunani pomoću ovog optimalnog modela PCA\_NN za sliv EBSB.

Vrijednosti RMSE za modele PCA\_NN s različitim brojem osnovnih komponenata (PC) prikazane su u tablicama 5. i 6. Točnost modela nije se povećala s povećanjem broja skrivenih slojeva. Vrijednosti greške modela za skupove podataka za testiranje i validaciju smanjile su se s povećanjem broja PC, kao što se to može vidjeti u tablicama 5. i 6. Najniža vrijednost greške dobivena je u modelu u kojem je korišteno šest PC.

Slika 4.  
Usporedba izmjerenih i izračunanih rezultata za modele PCA\_NN, MLP\_NN i GFF\_NN za skupove podataka za:  
a) validaciju; b) testiranje



Tablica 5. Vrijednosti RMSE modela PCA\_NN s različitim vrijednostima PC za skup podataka za testiranje

Osnovna komponenta	3PE				6PE				9PE			
	Tanj. akson.		Sigm. akson.		Tanj. akson.		Sigm. akson.		Tanj. akson.		Sigm. akson.	
	BP	CG										
2 PC	0,45	0,46	0,46	0,46	0,44	0,40	0,46	0,45	0,44	0,44	0,45	0,45
3 PC	0,44	0,45	0,46	0,46	0,47	0,45	0,45	0,45	0,44	0,42	0,45	0,45
4 PC	0,42	0,40	0,44	0,37	0,41	0,34	0,44	0,37	0,42	0,42	0,43	0,38
5 PC	0,36	0,36	0,45	0,39	0,39	0,39	0,43	0,39	0,39	0,38	0,43	0,40
6 PC	0,28	0,28	0,39	0,21	0,29	0,34	0,44	0,30	0,39	0,36	0,39	0,30

Tablica 6. Vrijednosti RMSE modela PCA\_NN s različitim vrijednostima PC za skup podataka za validaciju

Osnovna komponenta	3PE				6PE				9PE			
	Tanj. akson.		Sigm. akson.		Tanj. akson.		Sigm. akson.		Tanj. akson.		Sigm. akson.	
	BP	CG										
2 PC	0,64	0,62	0,64	0,65	0,61	0,56	0,65	0,67	0,60	0,60	0,64	0,64
3 PC	0,54	0,62	0,65	0,66	0,57	0,62	0,64	0,62	0,57	0,52	0,65	0,63
4 PC	0,51	0,61	0,54	0,60	0,58	0,61	0,53	0,64	0,56	0,53	0,53	0,56
5 PC	0,65	0,73	0,57	0,54	0,52	0,71	0,54	0,54	0,57	0,63	0,53	0,55
6 PC	0,74	0,59	0,50	0,30	0,61	0,57	1,43	0,56	0,52	0,47	0,52	0,48

## 5. Zaključak

U području hidrologije i hidrotehnike smatra se određivanje velikih voda značajnim pitanjem. Regionalni podaci danas se sve više koriste tijekom kontrole poplava i planiranja hidrotehničkih građevina, naročito u Turskoj, za određivanje velikih voda na lokacijama s malo ili bez izmijerenih podataka.

Ispitano je više nezavisnih varijabli koje se odnose na slivna područja te na meteorološke i hidrološke karakteristike, te je definirano šest najprikladnijih varijabli. To su varijable koje se odnose na površinu sliva, nagib glavnog vodotoka, nadmorsku visinu, gustoću vodotoka, srednju godišnju količinu oborina te povratna razdoblja. Ti su parametri korišteni za razvoj modela pomoći tri različita pristupa ANN. Modeli MLP\_NN, GFF\_NN i PCA\_NN primijenjeni su u analizi prethodno zabilježenih godišnjih maksimalnih protoka na slivu EBSB u Turskoj. Usporedbom tih triju metoda, utvrđeno je da se najbolji rezultati dobivaju pomoći modela PCA\_NN. Osim toga, vrijednosti greške u modelima s algoritmom CG bile su niže u usporedbi s algoritmom BP. Od dviju prijenosnih funkcija korištenih u modelima, na smanjenje greške utjecala je sigmoidna aksonskna prijenosna funkcija. Za skupove podataka za validaciju i testiranje, najbolji rezultati dobiveni su metodom PCA\_NN s tri skrivena sloja gdje je trening proveden

algoritmom CG pomoći sigmoidne aksonskne prijenosne funkcije. Najniža vrijednost greške dobivena je u modelu u kojem je korišteno šest osnovnih komponenata. Rezultati upućuju na provedivost i primjenljivost tih modela. Na temelju istraživanja provedenih u ovom radu može se zaključiti da najbolji model za predviđanje velikih voda sadrži sljedeće parametre:

- sigmoidnu aksonsku prijenosnu funkciju,
- jedan skriveni sloj s tri PE
- vrijednost epohe: 10.000
- vrijednosti momenta i stope učenja: 0,7 tj. 1.

Optimalni se model može koristiti za procjenu kvantila poplava na slivu EBSB, a rezultati se mogu dodatno prilagoditi za primjenu na druge turske slivove sa sličnim hidrološkim i fizikalnim karakteristikama. Ovaj će rad omogućiti nadležnim institucijama da pri projektiranju hidrotehničkih građevina primijene vrijedne spoznaje o vršnim poplavnim vrijednostima na slivu, i to za različita povratna razdoblja. Drugim riječima, rezultati ovog istraživanja mogu pomoći u smanjenju rizika od rušenja hidrotehničkih građevina te u ublažavanju pogubnih posljedica poplava na analiziranom slivu. Rezultati ovog istraživanja također se mogu primijeniti za razvoj postupaka za određivanje poplavnih događaja na drugim slivovima.

## LITERATURA

- [1] Greenwood, J.A.: Probability Weighted Moments: Definition and Relation to Parameters of Several Distributions Expressible in Inverse Form, *Water Resources Research*, 15 (1979) 5, pp. 1049-1054.
- [2] Hosking, J.R.M.: L-moments: Analysis and Estimation of Distributions Using Linear Combinations of Order Statistics, *Journal of the Royal Statistical Society Series B*, 52 (1990), pp. 105-124.
- [3] Kjeldsen, T.R., Smithers, J.C., Schulze, R.E.: Regional Flood Frequency Analysis in the Kwazulu-Natal Province, South Africa, Using the Index-Flood Method, *Journal of Hydrology*, 255 (2002) 1, pp. 194-211.
- [4] Fowler, H.J., Kilsby, C.G.: A Regional Frequency Analysis of United Kingdom Extreme Rainfall from 1961 to 2000, *International Journal of Climatology*, 23 (2003) 11, pp. 1313-1334.
- [5] Kumar, R., Chatterjee, C., Kumar, S., Lohani, A.K., Singh, R.D.: Development of Regional Flood Frequency Relationships Using L-Moments for Middle Ganga Plains Subzone of India, *Water Resources Management*, 17 (2003) 4, pp. 243-257.
- [6] Yue, S., Chun, Y.W.: Possible Regional Probability Distribution Type of Canadian Annual Streamflow by L-Moments, *Water Resources Management*, 18 (2004) 5, pp. 425-438.
- [7] Chen, Y.D., Huang, G., Shao, Q., Xu, C-Y.: Regional Analysis of Low Flow Using L-Moments for Dongjiang Basin, South China, *Hydrological Sciences Journal*, 51 (2006) 6, pp. 1051-1064.
- [8] Atiem, I.A., Harmancioğlu, N.: Assessment of Regional Floods Using L-Moments Approach: The Case of the River Nile, *Water Resources Management*, 20 (2006) 5, pp. 723-747.
- [9] Rahnama, M.B., Ramin, R.: Halil-River Basin Regional Flood Frequency Analysis Based on L-Moment Approach, *International Journal of Agricultural Research*, 2 (2007), pp. 261-267.
- [10] Zin, W.Z.W., Aziz Jemain, A., Kamarulzaman, I.: The Best Fitting Distribution of Annual Maximum Rainfall in Peninsular Malaysia Based on Methods of L-Moment and LQ-Moment, *Theoretical and applied climatology*, 96 (2009) 3-4, pp. 337-344.
- [11] Noto, L.V.: Goffredo La Loggia, Use of L-Moments Approach for Regional Flood Frequency Analysis in Sicily, *Italy Water resources management*, 23 (2009) 11, pp. 2207-2229.
- [12] Cannarozzo, M., Noto, L.V., Viola, F., Loggia, G.: Annual Runoff Regional Frequency Analysis in Sicily, *Physics and Chemistry of the Earth, Parts A/B/C*, 34 (2009) 10, pp. 679-687.
- [13] Nobert, J., Mugo, M., Gadain, H.: Estimation of Design Floods in Ungauged Catchments Using a Regional Index Flood Method, *Physics and Chemistry of the Earth*, 2014, <http://dx.doi.org/10.1016/j.pce.2014.02.001>.
- [14] Seckin, N., Haktanır, T., Yurtal, R.: Flood Frequency Analysis of Turkey Using L-Moments Method, *Hydrological Processes*, 25 (2011), pp. 3499-3505.
- [15] Aydogan, D., Kankal, M., Onsoy, H.: Regional Flood Frequency Analysis for Coruh Basin of Turkey with L-moments approach, *Journal of Flood Risk Management*, 9 (2014) 1, pp. 69-86.
- [16] Anilan, T., Satılmış, U., Kankal, M., Yuksek, O.: Application of Artificial Neural Networks and Regression Analysis to L-Moments Based Regional Frequency Analysis in the Eastern Black Sea Basin, Turkey, *KSCE Journal of Civil Engineering*, 20 (2015) 5, pp. 2082-2092.
- [17] Leclerc, M., Taha, B.M.J.: Ouarda, Non-Stationary Regional Flood Frequency Analysis at Ungauged Sites *Journal of hydrology*, 343 (2007) 3, pp. 254-265.
- [18] Haddad, K., Weinmann, P.E., Kuczera, G., Ball, J.: Streamflow Data Preparation for Regional Flood Frequency Analysis: Lessons from Southeast Australia, *Australian Journal of Water Resources*, 14 (2010) 1, pp. 17-32.

- [19] Palmen, L.B., Weeks, W.D.: Regional Flood Frequency for Queensland Using The Quantile Regression Technique, *Australian Journal of Water Resources*, 15 (2011) 1, pp. 47-56.
- [20] Malekinezhad, H., Nactnebel, H.D., Klik, A.: Comparing the Index Flood and Multiple Regression Methods Using L-Moments, *Physics and Chemistry of the Earth*, 36 (2011), pp. 54-60.
- [21] Haddad, K., Rahman, A.: Regional Flood Frequency Analysis in Eastern Australia: Bayesian GLS Regression-Based Methods within Fixed Region and ROI Framework – Quantile Regression and Parameter Regression Technique, *Journal of Hydrology*, 430-431 (2012), pp. 142-161.
- [22] Zaman, M.A., Rahman, A., Haddad, K.: Regional Flood Frequency Analysis in Arid Regions: a Case Study for Australia, *Journal of Hydrology*, 475 (2012), pp. 74-83.
- [23] Jingyi, Z., Hall, M.J.: Regional Flood Frequency Analysis for the Gan-Ming River Basin in China, *Journal of Hydrology*, 296 (2004), pp. 98-117.
- [24] Karunanithi, N., Grenney, W.J., Whitley, D., Bovee, K.: Neural Networks for River Flow Prediction, *Journal of Computing in Civil Engineering*, 82 (1994), pp. 201-220.
- [25] Maier, H.R., Dandy, G.C.: Use of Artificial Neural Networks for Prediction of Water Quality Parameters, *Water Resources, Research*, 324 (1996), pp. 1013-1022.
- [26] Shamseldin, A.Y.: Application of Neural Network Technique to Rainfall-Runoff Modelling, *Journal of Hydrology*, 1993 (1997) 4, pp. 272-294.
- [27] Shu, C., Burn, D.H.: Homogeneous Pooling Group Delineation for Flood Frequency Analysis Using a Fuzzy Expert System with Genetic Enhancement, *Journal of Hydrology*, 291 (2004), pp. 132-149.
- [28] Aziz, K., Rahman, A., Fang, G., Shrestha, S.: Application of Artificial Neural Networks in Regional Flood Frequency Analysis: a Case Study for Australia", *Stochastic Environmental Research and Risk Assessment*, 28 (2013) 3, pp. 541-554.
- [29] Seckin, N., Cobaner, M., Yurtal, R., Haktanir, T.: Comparison of ANN Methods with L-Moments for Estimating Flood Flow at Ungauged Sites: The Case of East Mediterranean River Basin, Turkey, *Water Resources Management*, 27 (2013), pp. 2103-2124.
- [30] Uzlu, E., Akpinar, A., Kömürcü, M.İ.: Restructuring of Turkey's Electricity Market and the Share of Hydropower Energy: The Case of Eastern Black Sea Basin, *Renewable Energy*, 36 (2011), pp. 676-688.
- [31] Yuksek, O., Kankal, M., Ucuncu, O.: Assessment of Big Floods in the Eastern Black Sea Basin of Turkey, *Environmental Monitoring and Assessment*, 185 (2013), pp. 797-814.
- [32] DSİ, Annual flood reports, Ankara, Turkey: General Directorate of State Hydraulic Works, 1970–2005.
- [33] DMİ, Analysis of Turkey's Maximum Precipitation Values and their Return Periods, Ankara, Turkey: Turkish State Meteorological Service, 2001.
- [34] Saka, F.: Sentetik Debi Sürekliklik Eğrilerinin Matematiksel Yöntemlerle Belirlenmesi ve Doğu Karadeniz Örneği, Ph.D. Thesis, Karadeniz Technical University Trabzon, Turkey, 2012.
- [35] Anilan, T.: Application Of Artificial Intelligence Methods To L-Moments Based Regional Frequency Analysis In The Eastern Black Sea Basin, PhD Thesis, Karadeniz Technical University, Turkey, 2014.
- [36] Caudill, M., Butler, C.: Understanding neural networks: volume 1: basic networks, Massachusetts Institute of Technology, Cambridge, MA, 1992.
- [37] Hornik, K., Maxwell, S., Halbert, W.: Multilayer Feedforward Networks are Universal Approximators, *Neural networks*, 2 (1989) 5, pp. 359-366.
- [38] Kumarand, R., Yadav, G.S.: Forecasting of Rain Fall in Varanasi District, Uttar Pradesh Using Artificial Neural Network, *Journal of Environmental Science*, 2 (2013) 3, pp. 721-729.
- [39] Hagan, M.T., Menhaj, M.B.: Training Feedforward Networks with the Marquardt Algorithm", *IEEE Trans. Neural Networks*, 5 (1994) 6, pp. 989-993.
- [40] El-Bakyr, M.Y.: Feed Forward Neural Networks Modeling for K-P Interactions, *Chaos, Solutions and Fractals*, 18 (2003) 5, pp. 995-1000.
- [41] Kisi, O., Cigizoglu, H.K.: Comparison of Different ANN Techniques in River Flow Prediction, *Civil Engineering and Environmental Systems*, 24 (2007) 3, pp. 211-231.
- [42] Arulampalam, G., Abdesselam, B.: A Generalized Feedforward Neural Network Architecture for Classification and Regression, *Neural Networks*, 16 (2003) 5, pp. 561-568.
- [43] Asensio-Cuesta, S., Diego-Mas, J.A., Alcaide-Marzal, J.: Applying Generalized Feedforward Neural Networks to Classifying Industrial Jobs in Terms of Risk of Low Back Disorders, *International Journal of Industrial Ergonomics*, 40 (2010) 6, pp. 629-635.
- [44] JadHAV, S.M., Nalbalwar, S.L., Ghatal, A.A.: Generalized Feedforward Neural Network Based Cardiac Arrhythmia Classification from Ecg Signal Data, In Advanced Information Management and Service (IMS), 2010 6<sup>th</sup> International Conference on (pp. 351-356). IEEE, 2010.
- [45] Pineda-Martínez, L.F., Carbalal, N., Medina-Roldán, E.: Regionalization and Classification of Bioclimatic Zones in the Central-Northeastern Region Of México using Principal Component Analysis (PCA), *Atmósfera*, 20 (2007) 2, pp. 133-145.
- [46] Sarbu, C., Pop, H.F.: Principal Component Analysis Versus Fuzzy Principal Component Analysis: a Case Study: the Quality of Danube Water (1985-1996), *Talanta*, 65 (2005) 5, pp. 1215-1220.
- [47] Shrestha, S., Babel, M.S., Gupta, A.D., Kazama, F.: Evaluation of Annualized Agricultural Nonpoint Source Model for a Watershed in the Siwalik Hills of Nepal, *Environmental Modelling & Software*, 21 (2006) 7, pp. 961-975.
- [48] Kisi, O., Uncuoglu E.: Comparison of the three backpropagation training algorithms for two case studies, *Indian Journal of Engineering and Materials Sciences*, 12 (2005) 5, pp. 434-42.
- [49] Rumelhart, D.E., Hinton, G.E., Williams, R.J.: Learning representations by back-propagating errors, *Nature*, 323 (1986), pp. 533-536.
- [50] Kisi, O., Ozkan, C., Akay, B.: Modeling discharge-sediment relationship using neural networks with artificial bee colony algorithm, *Journal of Hydrology*, 428 (2012), pp. 94-103.
- [51] Nacar, S., Hinis, M.A., Kankal, M.: Forecasting daily streamflow discharges using various neural network models and training algorithms, *KSCE Journal of Civil Engineering*, pp. 1-10, 2017.
- [52] Wasserman, P.D.: Advanced methods in neural computing. New York: Wiley, pp. 147-176, 1993.
- [53] Adeli, H., Hung, S.L.: Machine Learning: Neural Networks, Genetic Algorithms and Fuzzy Systems, New York, Wiley, 1994.
- [54] Thirumalaiah, K., Deo, M.C.: River stage forecasting using artificial neural networks, *Journal of Hydrologic Engineering*, 3 (1998) 1, pp. 26-32.
- [55] Kisi, O.: Streamflow forecasting using different artificial neural network algorithms, *Journal of Hydrologic Engineering*, 12 (2007) 5, pp. 532-539.
- [56] Cybenko, G.: Approximation by superpositions of a sigmoidal function", *Mathematics of Control, Signals and Systems*, 2 (1989) 4, pp. 303-314.
- [57] Pourhaghhi, A., Ali, A.M.A., Radmanesh, F., Podeh, H.T., Solgi, A.: Predicting the Input Flow into the Dez Dam Reservoir using the Optimized Neural Network by Genetic Algorithm, *International Journal of Engineering*, 2 (2013) 6, pp. 231-236.
- [58] Fayed, A.L., Hatem, E.A.: Prediction of the Ultimate Pullout Capacity of Shallow Foundations Utilizing ANNs, *Ain Shams Journal of Civil Engineering*, 1 (2010), pp. 275-293.