

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencije

Dilek Eren Akyuz

Sveučilište Istanbul - Cerrahpasa, Odjel za građevinarstvo, Istanbul, Turska, dr. sc.
dilek.akyuz@istanbul.edu.tr

H. Kerem Cigizoglu

Tehničko sveučilište Istanbul, Odjel za građevinarstvo, Istanbul, Turska, prof. dr. sc.
cigiz@itu.edu.tr

Sažetak: Ovaj rad obuhvaća predviđanje vodostaja jezera Beysehir, smještenog u središtu Turske, pomoću umjetne inteligencije (AI) poput neuronskih mreža (NN) i neizrazite logike (FL). Studija razmatra detaljno istraživanje utjecaja trajanja dugoročnog predviđanja na predviđanje vodostaja jezera. Analizirana razdoblja predviđanja su bila 1 dan, 30 dana, 60 dana i 90 dana. Parametri jezera poput kratkovalnog zračenja, ukupne brzine dotjecanja u jezero, ukupne brzine otjecanja iz jezera i ranijih vodostaja jezera činili su ulazni sloj AI konfiguracija. Ova studija je jasno pokazala da se uspješnost predviđanja AI metodama smanjuje s povećanjem razdoblja predviđanja. Također se vidi da se najbolji kriteriji za uspješnost predviđanja dobivaju različitim AI metodama za različita razdoblja predviđanja. Vidljivo je da je generalizirana regresijska neuronska mreža (GRNN) pokazala relativno bolje rezultate u usporedbi s druge dvije umjetne neuronske mreže, tj. radijalnom baznom funkcijom (RBF) i metodom prosljeđivanja prema naprijed s povratnim rasprostiranjem pogreške (FFBP), te metodom prilagodljivog sustava neuro-neizrazitog zaključivanja (ANFIS), za duga razdoblja predviđanja, kao što su 60 i 90 dana. Drugu ukupnu najbolju uspješnost postigla je FFBP.

Ključne riječi: predviđanje vodostaja; dugoročno predviđanje; umjetne neuronske mreže; ANFIS

Long range lake water level estimation using artificial intelligence methods

Abstract: This paper covers the estimation of the water levels of Beysehir Lake, located in middle of Turkey, using the artificial intelligence (AI) such as the neural networks (NN) and the fuzzy logic (FL). The study considers the detailed investigation of the effect of the long-term estimate duration on the lake water level estimation. The analysed estimate ranges were 1 day, 30 days, 60 days and 90 days. The lake parameters such as the shortwave radiation, the lake total inflow rate, the lake total outflow rate and the past lake water levels constituted the input layer of the AI configurations. This study clearly showed that the estimate performance of the AI methods decreases with the increasing estimate range. It is also seen that the best estimate performance criteria are obtained by different AI methods for different estimate ranges. It is seen that the Generalized Regression Neural Network (GRNN) showed relatively superior performance compared with the other two artificial neural networks, i.e. the Radial Basis Function (RBF) and the Feed Forward Back Propagation method (FFBP), and the Adaptive Neuro-Fuzzy Inference System (ANFIS) method, for the long estimation ranges such as 60 and 90 days. The second overall best performance was obtained by FFBP.

Key words: Water level forecasting; Long term forecasting; artificial neural networks; ANFIS

1. UVOD

Predviđanje hidrološke varijable jedno je od glavnih pitanja hidrologije za upravljanje i planiranje akumulacije, sliva i zemljišta. Primjena procesnih računalnih programa temeljenih na fizici zahtijeva detaljne prostorne i vremenske podatke o okolišu koji nisu često dostupni. Stoga se za predviđanje hidroloških događaja/ parametara u literaturi često koriste tehnike umjetne inteligencije (AI) poput umjetnih neuronskih mreža (ANN), neizrazite (fuzzy) logike (FL) i genetskog algoritma (GA). Umjetna neuronska mreža (ANN) i neizrazita logika (FL) su nelinearni modeli i mogu se koristiti za određivanje ovog odnosa. ANN i FL se sve više koriste u raznim inženjerskim primjenama. Razlog tome je njihova sposobnost uspješnog rješavanja nelinearnih problema. Ova značajka je jako važan aspekt neuronskog računalstva i lingvističkog računalstva, jer se može koristiti za modeliranje funkcije u slučaju da je na raspolaganju malo podataka ili da je shvaćanje nepotpuno.

Pristup umjetnim neuronskim mrežama se u velikoj mjeri koristi u literaturi o vodnim resursima u području predviđanja i prognoziranja [1-20]. Njihove primjene za prognoziranje i predviđanje nekoliko hidroloških varijabli detaljno su prikazane i razmotrene u radovima [21-25]. Predstavljene su neke studije za poboljšanje uspješnosti njihovog predviđanja.

Iako umjetne neuronske mreže imaju uspješne primjene na mnogim hidrološkim varijablama, točnost predviđanja modela je jako subjektivna i uvelike ovisi o sposobnostima korisnika, njegovom znanju i razumijevanju modela [26]. Međutim, jedna od glavnih kritičkih primjedbi za njihove hidrološke modele je u tome da ne objašnjavaju temeljne fizičke procese u slivu, što dovodi to toga da ih karakteriziraju kao "crna kutija" modele. Posljednjih godina objavljene su studije o fizici sadržanoj u umjetnim neuronskim mrežama. Jain i sur. istraživali su fiziku ugrađenu u njihove korelacijske težine [27]. Sudheer i Jain pokušali su objasniti unutarnje ponašanje modela riječnog toka s umjetnim neuronskim mrežama [28]. Sudheer je proučavao izdvajanje znanja iz obučanih (treniranih) modela riječnog toka s neuronskom mrežom [29].

Broj primjena neizrazite logike u hidrologiji se brzo povećava [2-3, 9, 30-31]. Čini se da će se broj uporaba povećati u znanosti u obliku hibridnih modela.

Istraživanja o predviđanju razine vode ili vodostaja (WL) raznih vodnih tijela u hidrologiji se mijenjaju s razdobljem predviđanja od 1 sata do 30 mjeseci (tablica 1). Razina vode prognozira se u oceanu ili moru [1, 14, 17], akumulaciji ili jezeru [12, 31], rijeci [2-3, 9-10] i podzemnim vodama [4, 8, 11, 16, 20, 32]. Prognozna razdoblja za predviđanje razine podzemne vode su duža u usporedbi s ostalima, jer su podzemne vode prilično spore i uvjeti su gotovo stabilni. Promjene u sustavima podzemnih voda se mogu promatrati na mjesečnoj osnovi. Interval trajanja za prognoziranje vodostaja u uvjetima poplave je kraći jer je sustav dinamičan i njegova svojstva se mijenjaju s minutnim korakom vremena.

U prikazanoj studiji istražuju se vodostaji jezera Beysehir, smještenog u središtu Turske. Jezero je slatkovodno, a okolno područje ima krašku strukturu [33]. Važnost jezera Beysehir za ekonomiju uglavnom proizlazi iz poljoprivrede, ribarstva i ispuštanja otpadnih voda u okolnoj regiji. Male promjene visine velikih površina jezera mogu dovesti do ogromnih promjena površine kopna. Za jezero Beysehir pri smanjenju ili povećanju razine jezera za jedan centimetar prosječni volumen jezera se promijeni za sedam milijuna kubičnih metara.

Cilj predstavljenoga istraživanja je primijeniti metode umjetne inteligencije (AI) za predviđanje dnevnog vodostaja (WL) jezera za duga vremenska razdoblja. Rad je obuhvaćao četiri studije, tj. predviđanje 1 dan unaprijed, predviđanje 30 dana unaprijed, predviđanje 60 dana unaprijed i predviđanje 90 dana unaprijed. Za određivanje najboljeg modela za dugoročno predviđanje koriste se tri vrste umjetnih neuronskih mreža (ANN) i jedan prilagodljivi sustav neuro-neizrazitog zaključivanja (ANFIS).

Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencije

Tablica 1. Pregled literature za predviđanje vodostaja raznih vodnih tijela. (ANFIS: prilagodljivi sustav neuro-neizrazitog zaključivanja, ARIMA: autoregresivni integrirani pomični prosjek, ARMA: autoregresivni pomični prosjek, ARMAX: autoregresivni pomični prosjek s egzogenim ulazom, ARX: autoregresivni s egzogenim podacima, GA: genetski algoritam, NN: neuronske mreže, FFBP: unaprijedna s povratnom propagacijom pogreške, FFBP-LM: unaprijedna s povratnom propagacijom pogreške uz Levenberg-Marquardt, RBF: radijalna bazna funkcija, MLP NN: višeslojna perceptronska neuronska mreža, MLR: Multilinearna regresija).

Referenca	Razina vode za	Korištene metode	Najuspješnija (Naziv metode)	Vrem. raspon	br. ulaza	br. izlaza	Raspon predviđanja
[9]	Rijeku u uvjetima poplave	Fuzzy (2 vrste) i NN	Fuzzy	satno	4, 16	1	1,3,6,9,12 sati
[11]	Podzemne vode	NN (3 vrste)	FFBP "bez jedinstvenog pristupa"	tjedno	3	1	1, 2, 3, 4 tjedna
[3]	Rijeku pri poplavi	NN (1 vrsta), ANFIS, ARMA, ARX	FFBP	satno	2	1	15 min, 2,5,10 sati
[31]	Akumulacija pri tajfunu	ANFIS	ANFIS	satno	17, 18	1	1,2,3 sata
[4]	Podzemne vode	NN (1 vrsta)	FFBP	dnevno	25	12	1 do 71 dana
[32]	Podzemne vode	NN (1 vrsta)	FFBP	dnevno	7	1	30 dana
[8]	Podzemne vode	NN (7 vrsta)	RBF (učenje), FFBP-LM (ispitivanje)	mjesečno	20	1	1, 6, 12, 18 mjeseci
[14]	Ocean	NN (1 vrsta), NN cjelina, klasična harmonijska analiza	FFBP	satno	1, 2, 3	1	4, 13, 25 sati
[12]	Jezero	MLP NN	MLP NN	mjesečno	8,12,14, 16, 20	4	4 mjeseca
[2]	Rijeku pri poplavi	NN, Fuzzy sa GA, ARMA	Fuzzy sa GA	satno	1 do 37	1	6 sati
[17]	More	NN (3 vrste), MLR	FFBP, RBF	dnevno	12	1	1 dan
[20]	Podzemne vode	NN (1 vrsta)	FFBP-LM	mjesečno	12,15,16, 29	5,8,9,22	1 mjesec
[16]	Podzemne vode	NN (1 vrsta)	FFBP-LM	mjesečno	4, 5	1	1 do 30 mjeseci
[1]	More	NN (1 vrsta) i ARIMA	FFBP	mjesečno	13	1	1 mjesec

2. METODE UMJETNE INTELIGENCIJE

Za predviđanje vodostaja jezera Beysehir u ovom istraživanju se koriste tri metode umjetnih neuronskih mreža i neizrazita (fuzzy) metoda zasnovana na adaptivnoj mreži.

2.1 Metode umjetnih neuronskih mreža (ANN)


2.1.1 FFBP

U literaturi o vodnim resursima FFBP je najpopularnija metoda učenja za umjetne neuronske mreže. FFBP se odlikuje prisutnošću jednog ili više skrivenih slojeva, čiji se računski čvorovi

Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetene inteligencije


primjereno nazivaju skriveni neuroni skrivenih jedinica (Slika 1). Funkcija skrivenih neurona je na neki koristan način intervenirati između vanjskog ulaza i mrežnog izlaza. Dodavanjem jednog ili više skrivenih slojeva, mreži se omogućuje izdvajanje statistike višeg reda. Ako je zadan skup ulazno-izlaznih podataka za učenje, najčešće pravilo učenja za višeslojni perceptron je algoritam s povratnim postupkom. Povratni postupak obuhvaća dvije faze; fazu usmjerenu prema naprijed (engl. feed forward) u kojoj se vanjske ulazne informacije na ulaznim čvorovima prenose naprijed kako bi se signal izlazne informacije izračunao na izlaznoj jedinici i povratnu fazu u kojoj se vrše promjene snaga veze na temelju razlika između izračunatih i promatranih informacijskih signala na izlaznim jedinicama. Za proračun izlaza ulaznog i izlaznog sloja mogu se koristiti različite vrste aktivacijskih funkcija. U ovoj studiji koriste se "tangent sigmoid" funkcija i "logsig" funkcija te se uspoređuju odgovarajući rezultati procjene.



Slika 1. FFBP mreža

2.1.2 GRNN

GRNN se sastoji od četiri sloja; ulazni sloj, sloj uzorka, sloj zbrajanja i izlazni sloj [34]. U prvom sloju postoje ulazni parametri i oni su u potpunosti povezani s drugim slojem, tj. slojem uzorka (Slika 2). Svaka jedinica sloja uzorka je povezana s dva neurona u sloju zbrajanja. Optimalna vrijednost širine (s) se često određuje eksperimentalno [7]. Što je to širina veća, to će aproksimacija funkcije biti glatkija. GRNN aproksimira bilo koju proizvoljnu funkciju između ulaznih i izlaznih vektora, crtajući procjenu funkcije izravno iz podataka učenja. Nadalje, konzistentan je; to jest, kako skup za učenja postaje velik, pogreška procjene se približava nuli, uz samo blaga ograničenja na funkciju. GRNN se koristi za predviđanje kontinuiranih varijabli, kao u standardnim tehnikama regresije. Povezan je s mrežom radijalnih baznih funkcija i temelji se na standardnoj statističkoj tehnici zvanj regresija jezgre.



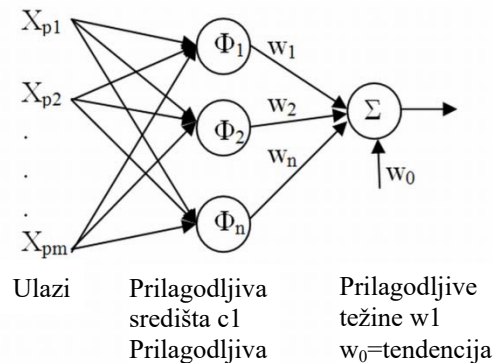
Slika 2. GRNN mreža

Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencije

2.1.3 RBF


RBF mreže su u literaturi o neuronskim mrežama uveli Broomhead i Lowe [35]. Model RBF mreže motiviran je lokalno okrenutim odgovorom uočenim u biološkim neuronima (Slika 3). Teorijska osnova RBF pristupa je na polju interpolacije multivarijantnih funkcija [26]. Rješenje točnog interpolirajućeg RBF mapiranja prolazi kroz svaku podatkovnu točku. U studiji su ispitane različite konstante širine.



Slika 3. RBF mreža

2.2 ANFIS metoda

Neizrazite (Fuzzy) algoritme za složene sustave i procese odlučivanja 1973. godine predstavio je Lotfi Asker Zadeh [36]. ANFIS zasnovan na neizrazitim algoritmima predložio je 1993. godine Jyh-Shing Roger Jang kao dopuštanje neizrazitim sustavima da uče [37]. Ima ulazno-izlazno mapiranje koje je temeljeno i na ljudskom znanju i na naznačenim ulazno-izlaznim parovima podataka, tako da ima sposobnost baviti se nelinearnim i složenim matematičkim problemom (slika 4). ANFIS se u hidrološkim primjenama uglavnom koristi za modeliranje i predviđanje. Neki istraživači su koristili ANFIS za prognoziranje razine vode [2-3, 9, 31]. U ovoj studiji ANFIS se koristi za predviđanje vodostaja jezera nakon dugih vremenskih raspona.



Slika 4. ANFIS mreža

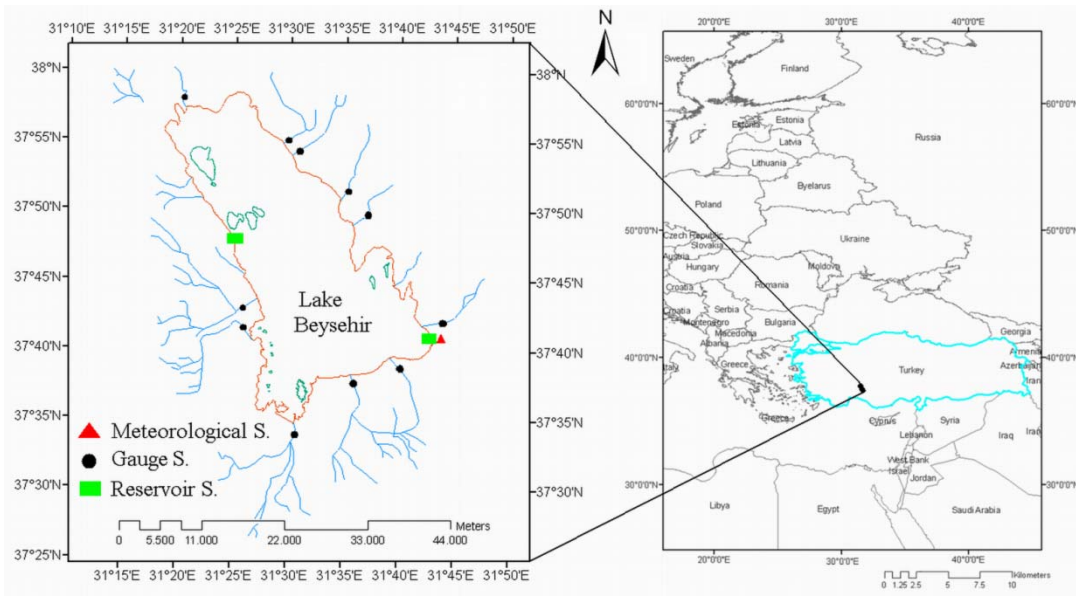
Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencije

3. OPIS PODATAKA

3.1 Područje istraživanja

Jezero Beysehir se nalazi na sjeveru Konya-Beysehira, južno od Isparte-Sarkikaraagaca i u tektonskoj jami između planina Sultan i Anamas, i najveće je slatkovodno jezero u Turskoj. Ima površinu od 700 km². Najdublje mjesto ima približnu dubinu od 11 m, a prosječna dubina je 6 m. Jezero ima važnu ulogu za navodnjavanje i opskrbu pitkom vodom za srednju Anatoliju. Položaj jezera Beysehir prikazan je na Slici 5.

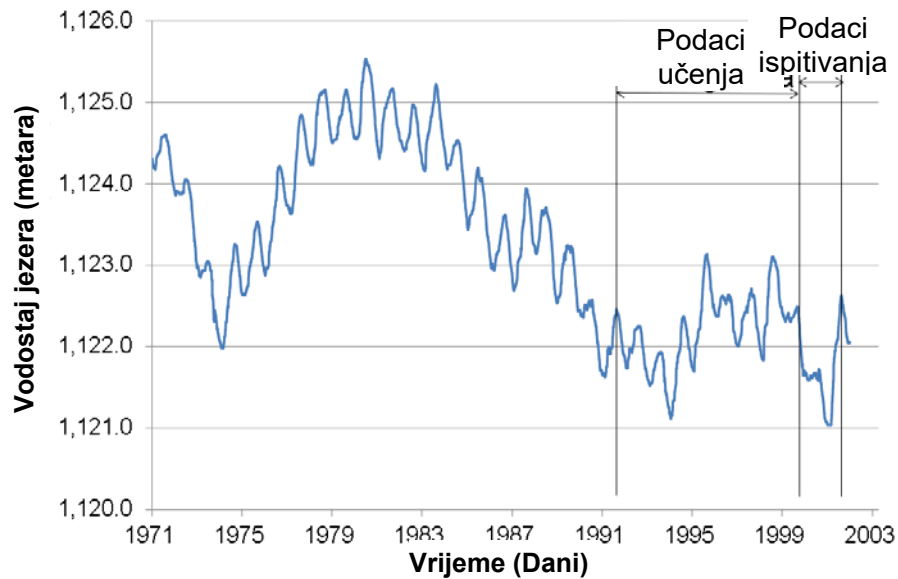


Slika 5. Lokacija jezera Beysehir.

Jezero i okolno područje su pod zaštitom pošto predstavljaju Nacionalni park, Zaštićeno područje akumulacije za piće i navodnjavanje; u skupini "A" kopnenih voda s međunarodnim značajem i imaju povijesni i kulturni značaj. Jezero ima posebnu važnost među svim ostalim jezerima zbog biljnog i životinjskog svijeta i izvanredne prirode. Jezero Beysehir je privlačno jezero u Turskoj s otocima različitih veličina, pješčanom plažom, krškim špiljama i florom. Međutim, jezero se suočava s mnogim problemima poput smanjenja vodostaja jezera, pogrešne politike korištenja voda, nekontroliranog ribolova, urbanizacije i prekomjerne upotrebe jezera. Ono ima društveno-ekonomski značaj za ribarstvo, navodnjavanje, ptičji svijet.

Klimatske i hidrološke dnevne podatke (1991.-2001.) korištene u ovom istraživanju osigurali su Državna meteorološka služba Turske (DMI) i Državni vodovod Turske (DSI). Parametri jezera koji se razmatraju u ovom istraživanju su kratkovalno zračenje, ukupno otjecanje, ukupni dotok i vodostaj. Prosječni dnevni podaci su podaci za jezero Beysehir u središnjem dijelu Turske (Slika 5), a vrijednosti razine jezera za vremensko razdoblje od 1971. do 2001. godine su prikazane su na Slici 6.

Značajne pritoke koje se ulijevaju u jezero su; Celtek, Ozan, Cavus, Ebulvefa, Eflatun, Karadiken, Ustunler, Soguksu, Kurucuova, Hizar (Slika 5). Jedini odljev je kanal Beysehir. Osim toga, voda se crpi za navodnjavanje u regijama Yenisarbademli, Kireli i Sarkikaraagac. Dnevno ukupno dotjecanje i otjecanje su zbroj količina dotjecanja svih dolaznih rijeka u danu, odnosno zbroj svih otjecanja u danu.



Slika 6. Apsolutne visine jezera Beysehir iznad razine mora

Uobičajeno razdoblje podataka za sve parametre jezera obuhvaća vremensko razdoblje koje započinje od 1. rujna 1991. pa do 2. srpnja 2001. godine (Slika 6). Podaci u ovom vremenskom razdoblju su podijeljeni na dva vremenska razdoblja kao učenje i ispitivanje. Podaci ispitivanja obuhvaćaju posljednjih 20% svih dnevnih vrijednosti (Tablica 2).

Tablica 2. Odabir dva neovisna podskupa

Vrsta podataka	Broj podataka	Raspon datuma
Učenje	2850	01.10.1991-20.07.1999.
Ispitivanje	713	21.07.1999.-02.07.2001.
Svi podaci	3563	01.10.1991.-02.07.2001.

3.2 Statistički podaci za parametre jezera

Za učenje, ispitivanje i cijelo razdoblje podataka izračunati su osnovni deskriptivni statistički podaci kao što su maksimum (X_{max}), minimum (X_{min}), srednja vrijednost (X_{mean}), standardno odstupanje (s_x) i asimetričnost (c_{sx}) (Tablica 3).

Iako je raspon odstupanja asimetrije za sva vremenska razdoblja za vodostaj jezera (0,06-0,14) blizu nule, odgovarajući raspon ukupnih dotjecanja je suprotan (2,66-5,07, tablica 3). Slično vodostaju jezera, i kratkovalna varijacija pokazuje raspon odstupanja asimetričnosti (-0,06-0,004) prilično blizu nule. S druge strane, ukupna asimetrija otjecanja se kreće između 0,30 i 0,97 (Tablica 3). Može se zaključiti da kratkovalno zračenje i vodostaj pokazuju simetričnu raspodjelu granične vjerojatnosti (normalna raspodjela), dok ukupno dotjecanje i ukupno otjecanje odstupaju od normalne raspodjele s pozitivnom asimetrijom. Izuzev ukupnog dotjecanja, maksimalne vrijednosti ispitivanja i učenja su blizu jedna drugoj (Tablica 3).


Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetene inteligencije

Tablica 3. Osnovni statistički podaci svih serija parametara jezera za učenje, ispitivanje i cijelo vremensko razdoblje

Naziv podatka	Vrsta podataka	X_{max}	X_{min}	X_{mean}	S_x	C_{sx}
Ukupno dotoci	Svi podaci	177,21	1,21	12,38	13,51	2,91
	Učenje	177,21	1,21	13,69	14,39	2,66
	Ispitivanje	96,34	1,85	7,13	7,10	5,07
Kratkovalno zračenje	Svi podaci	8186,7	237,1	4291,7	2039,1	-0,06
	Učenje	8186,7	237,1	4279,6	2050,6	-0,08
	Ispitivanje	8135,3	378,3	4339,9	1993,0	0,004
Ukupno otjecanja	Svi podaci	38,00	0,00	9,18	9,10	0,50
	Učenje	30,00	0,00	8,97	8,81	0,30
	Ispitivanje	38,00	0,00	10,02	10,13	0,97
Vodostaj	Svi podaci	1123,1	1121,1	1122,1	0,43	0,14
	Učenje	1123,1	1121,1	1122,2	0,44	0,11
	Ispitivanje	1122,9	1121,5	1122,1	0,38	0,06

Autokorelacije za vodostaj su date na Slici 7. Raspon varijacije autokorelacije je 0,58-1 za prvih 100 vremenskih pomaka, tj. 100 dana. Uzajamne korelacije između parametara jezera pokazuju da vodostaj (WL_t) ima najnižu korelaciju s otjecanjem ($r=0,01$, Tablica 4). Korelacije vodostaj - kratkovalno zračenje i vodostaj - ukupno otjecanje su jednake 0,30 (Tablica 4). U Tablici 4 dane su i autokorelacije za vremenske serije vodostaja. Prema tome, vrijednosti autokorelacije lag_1 (između WL_t i WL_{t+1}), autokorelacije lag_30 (između WL_t i WL_{t+30}), autokorelacije lag_60 (između WL_t i WL_{t+60}) i autokorelacije lag_90 (između WL_t i WL_{t+90}) su određene kao 1,00, 0,94, 0,81, odnosno 0,64 (Tablica 4).



Slika 7. Autokorelacije za vodostaj

Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetene inteligencije

Tablica 4. Uzajamne korelacije na skupu podataka

Parametar	WL _t (m)	WL _{t+1} (m)	WL _{t+30} (m)	WL _{t+60} (m)	WL _{t+90} (m)
Kratkovalna (cal/cm ² -day)	0,30	0,29	0,08	-0,14	-0,32
Ukupna dotjecanja (m ³ /s)	0,30	0,31	0,45	0,47	0,40
Ukupna otjecanja (m ³ /s)	0,01	0,01	0,01	0,01	0,00
WL _t (m)	1,00	1,00	0,94	0,81	0,64
WL _{t+1} (m)		1,00	0,95	0,81	0,65
WL _{t+30} (m)			1,00	0,94	0,81
WL _{t+60} (m)				1,00	0,94
WL _{t+90} (m)					1,00

4. REZULTATI

U studiji su korištene 3 različite ANN metode, FFBP, GRNN, RBF s algoritmom učenja Levenberg-Marquardt [25] i ANFIS metoda [37] za svaki odabrani slučaj dugoročnog predviđanja. Stoga je za svaku metodu provedeno učenje i ispitivanje za četiri različita razdoblja predviđanja vodostaja, tj. 1 dan, 30 dana, 60 dana i 90 dana. Ukupno je provedeno 16 različitih simulacija. Kako postoje 4 različita pojedinačna slučaja izlaza (WL_{t+1}, WL_{t+30}, WL_{t+60}, WL_{t+90}), struktura ulaza se uvijek sastoji od ukupnog dotjecanja, ukupnog otjecanja, kratkovalnog zračenja i WL_t. Parametri modela su pregledno prikazani u tablici 5. Rezultati istraživanja predviđanja za četiri različita vremenska razdoblja ukratko su prikazani su u sljedećem odjeljku.

Tablica 5. Parametri ANN i ANFIS modela koji su dali najbolje rezultate ispitivanja

Razdoblje predviđanja (dana)	METODE			
	FFBP	GRNN	RBF	ANFIS
1	FFBP(4,4,1), 1000 iteracija, tansig-logsig	4,s=0.8,1	RBF(4,s=0.67,1), 100 neurona,	br. MF-a 7, gaussmf
30	FFBP(4,4,1), 1000 iteracija, tansig-logsig	4,s=0.10,1	RBF(4,s=0.28,1), 100 neurona,	br. MF-a 7, gaussmf
60	FFBP(4,4,1), 1000 iteracija, tansig-logsig	4,s=0.10,1	RBF(4,s=0.22,1), 100 neurona,	br. MF-a 7, gaussmf
90	FFBP(4,4,1), 1000 iteracija, tansig-logsig	4,s=0.10,1	RBF(4,s=0.20,1), 100 neurona,	br. MF-a 7, gaussmf

Sve tri ANN metode, FFBP, GRNN i RBF, te ANFIS metoda se obučavaju s ulaznim slojem koji ima 4 ulaza, tj. ukupni dotok, istjecanje, kratkovalno zračenje i vodostaj, sve izmjereno u trenutku "t". Jedinstveni izlaz predstavljao je vodostaj u trenutku "t+1", "t+30", "t+60" ili "t+90". Vremenska razdoblja učenja i ispitivanja ANN modela prikazana su u Tablici 2. Povezani parametri ANN i ANFIS modela i konfiguracije modela koji su dali najbolje rezultate ispitivanja dani su u Tablici 5. Prema ovoj tablici FFBP (4,4,1) predstavlja FFBP konfiguraciju s ulaznim slojem od 4 neurona, skrivenim slojem koji ima 4 neurona i izlaznim slojem s jedinstvenim čvorom (Tablica 5, drugi stupac). Broj iteracijskih učenja za FFBP je 1000. Najbolje aktivacijske funkcije ustanovljeno je da su tangencijalni sigmoid između ulaznog sloja i skrivenog sloja i logaritamski sigmoid između skrivenog sloja i izlaznog sloja.

Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencije

Kriteriji za procjenu uspješnosti faze ispitivanja, kao što su srednja kvadratna pogreška (RMSE) i koeficijent determinacije (R^2), dobiveni za razdoblje ispitivanja, navedeni su u tablicama 6 i 7 za svaku AI metodu.

RMSE kriterij za procjenu uspješnosti formuliran je na sljedeći način:

$$RMSE = \sqrt{\left(\sum_{i=1}^N (Y_{i,observed} - Y_{i,predicted})^2 / N\right)} \quad (1)$$

Drugi kriterij za procjenu rezultata, tj. koeficijent determinacije (R^2), izračunava se kao što je prikazano u nastavku:

$$R^2 = 1 - \left(\sum_{i=1}^N (Y_{i,observed} - Y_{i,predicted})^2\right) / \left(\sum_{i=1}^N (Y_{i,observed} - Y_{mean})^2\right) \quad (2)$$

4.1 Predviđanje 1 dan unaprijed (WL_{t+1})

GRNN i RBF imali su vrijednosti širine jednake 0,8, odnosno 0,67 (Tablica 5, treći red). Vrijednosti RMSE i R^2 za predviđanje WL_{t+1} za jedan dan unaprijed dane su u Tablicama 6 i 7 ispod zaglavlja „t+1“. Najmanja RMSE je dobivena s ANFIS-om (0,007, 0,006) za podatke učenja, ispitivanja i cjelokupne podatke (Tablica 6). Osim GRNN, sve ostale tri metode dale su vrijednosti RMSE ili jednake ili manje od 0,010. Najbolje vrijednosti RMSE prikazane su podebljanim slovima i podvučene (Tablica 6).

Tablica 6. Usporedba RMSE za sve vrste modela


Metoda	Podaci	Razdoblje predviđanja (dana)			
		t+1	t+30	t+60	t+90
GRNN	Svi podaci	0,039	<u>0,082</u>	<u>0,123</u>	<u>0,15</u>
	Učenje	0,018	<u>0,059</u>	<u>0,069</u>	<u>0,087</u>
	Ispitivanje	0,079	0,139	0,238	0,286
FFBP	Svi podaci	0,009	0,087	0,151	0,22
	Učenje	0,009	0,089	0,151	0,201
	Ispitivanje	0,008	<u>0,081</u>	<u>0,154</u>	0,285
RBF	Svi podaci	0,009	0,083	0,148	0,19
	Učenje	0,008	0,077	0,122	0,16
	Ispitivanje	0,01	0,104	0,225	0,279
ANFIS	Svi podaci	<u>0,007</u>	0,099	0,186	0,246
	Učenje	<u>0,007</u>	0,101	0,189	0,245
	Ispitivanje	<u>0,006</u>	0,093	0,173	<u>0,249</u>
Najmanja RMSE	Svi podaci	<u>0,007</u> (ANFIS)	<u>0,082</u> (GRNN)	<u>0,123</u> (GRNN)	<u>0,15</u> (GRNN)
	Učenje	<u>0,007</u> (ANFIS)	<u>0,059</u> (GRNN)	<u>0,069</u> (GRNN)	<u>0,087</u> (GRNN)
	Ispitivanje	<u>0,006</u> (ANFIS)	<u>0,081</u> (FFBP)	<u>0,154</u> (FFBP)	<u>0,249</u> (ANFIS)

Sve vrijednosti R^2 dobivene pomoću 4 metode jednake su 1,00, što pokazuje prilično veliku uspješnost za učenje, ispitivanje i cjelokupnu seriju za razdoblje predviđanja od 1 dan (Tablica 7). Grafikoni vodostaja u vidu hidrograma vodostaja i dijagrama raspršenja prikazani su na Slikama 8 i 9 za sve metode umjetne inteligencije. Izuzev GRNN-a, predviđanja modela i opažene vrijednosti su gotovo neraspoznatljive (Slike 8 i 9). Međutim, za GRNN se mogu primijetiti odstupanja od opaženih vrijednosti (Slika 8b i 9b).


Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencijeTablica 7. R^2 svih vrsta modela

Metode	Podaci	Razdoblje predviđanja (dana)			
		t+1	t+30	t+60	t+90
GRNN	Svi podaci	1,000	0,992	<u>0,966</u>	<u>0,926</u>
	Učenje	1,000	0,998	<u>0,982</u>	<u>0,976</u>
	Ispitivanje	1,000	0,960	0,895	0,746
FFBP	Svi podaci	1,000	<u>1,000</u>	0,961	0,887
	Učenje	1,000	<u>1,000</u>	0,961	0,886
	Ispitivanje	1,000	<u>1,000</u>	<u>0,964</u>	<u>0,895</u>
RBF	Svi podaci	1,000	0,964	0,887	0,823
	Učenje	1,000	0,970	0,925	0,871
	Ispitivanje	0,999	0,931	0,726	0,651
ANFIS	Svi podaci	1,000	0,948	0,824	0,703
	Učenje	1,000	0,949	0,821	0,697
	Ispitivanje	1,000	0,944	0,837	0,723
Najveći R^2	Svi podaci	<u>1,000 (sve metode)</u>	<u>1,000(FFBP)</u>	<u>0,966(GRNN)</u>	<u>0,926(GRNN)</u>
	Učenje	<u>1,000(sve metode)</u>	<u>1,000(FFBP)</u>	<u>0,982(GRNN)</u>	<u>0,976(GRNN)</u>
	Ispitivanje	<u>1,000(GRNN, FFBP, ANFIS)</u>	<u>1,000(FFBP)</u>	<u>0,964(FFBP)</u>	<u>0,895(FFBP)</u>



Slika 8. Dijagram raspršenja za podatke ispitivanja u slučaju predviđanja za jedan dan unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS



Slika 9. Hidrogram vodostaja za podatke ispitivanja u slučaju predviđanja za jedan dan unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS


4.2 Predviđanje 30 dana unaprijed (WL_{t+30})

Sljedeći korak istraživanja bio je proširenje razdoblja predviđanja s 1 dana na 30 dana (1 mjesec). Rezultati predviđanja ponovno su definirani s obzirom na RMSE i R^2 (Tablice 6 i 7), a hidrogrami vodostaja i dijagrami raspršenja su prikazani na slikama 10 i 11. ANN i ANFIS


Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencije

konfiguracije s najboljim rezultatima prikazane su u Tablici 5. FFBP metoda je dala najbolju uspješnost za RMSE za seriju ispitivanja (Tablica 6). GRNN metoda imala je najmanju RMSE za cijelu seriju i seriju učenja. FFBP je opet imao najbolji rezultat u pogledu R^2 (Tablica 7). Vrijednosti R^2 se kreću između 0,931 i 1 000, što ukazuje na to da sve metode imaju veliku uspješnost za predviđanje 30 dana unaprijed (Tablica 7). Grafikoni vodostaja u vidu hidrograma vodostaja i dijagrama raspršenja pokazuju da su predviđanja razine jezera za fazu ispitivanja prilično blizu opaženim vrijednostima s prihvatljivim odstupanjima od linije trenda (Slika 10 i Slika 11).




Slika 10. Dijagram raspršenja za podatke ispitivanja u slučaju predviđanja za 30 dana unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS



Slika 11. Hidrogram vodostaja za podatke ispitivanja u slučaju predviđanja za 30 dana unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS

4.3 Predviđanje 60 dana unaprijed (WL_{t+60})

U ovom dijelu rada predviđanja razdoblje predviđanja je produženo na 60 dana (2 mjeseca). Vidi se da je u studiji predviđanja GRNN metoda dominirala s najboljim rezultatima RMSE i R^2 za podatke o učenju i cijelu seriju (Tablice 6 i 7). FFBP metoda je imala drugi po redu rezultat.




Slika 12. Dijagram raspršenja za podatke ispitivanja u slučaju predviđanja za 60 dana unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS

Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetne inteligencije


Vrijednosti RMSE i R^2 za predviđanja WL_{t+60} za 60 dana unaprijed dane su u Tablicama 6 i 7 ispod zaglavlja „t+60“. Najmanja RMSE je dobivena s GRNN (0,123), a RBF ima drugi po redu rezultat (0,148) za cijelu seriju (tablica 6). Najveća vrijednost R^2 je dobivena s GRNN (0,966) uz FFBP koji opet ima drugi po redu rezultat (0,961) ako se uzme u obzir cijela serija (Tablica 7). Hidrogrami vodostaja i dijagrami raspršenja pokazuju da predviđanja odstupaju od uočenih vrijednosti, no ostaju unutar prihvatljivog raspona pogreške (Slike 12 i 13).




Slika 13. Hidrogram vodostaja za podatke ispitivanja u slučaju predviđanja za 60 dana unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS

4.4 Predviđanje 90 dana unaprijed (WL_{t+90})

Konačni dio analize predviđanja sastojao se od predviđanja za 90 dana (3 mjeseca) unaprijed. Vrijednosti RMSE i R^2 za predviđanje WL_{t+90} za 90 dana unaprijed dane su u Tablicama 6 i 7 ispod zaglavlja „t+90“. Najmanja RMSE je dobivena s GRNN (0,150), a RBF ima drugi po redu rezultat (0,190) za cijelu seriju (Tablica 6). GRNN je ponovo imao najveći R^2 (0,926), a nakon njega FFBP (0,887) za sve podatke (Tablica 7). Rezultat ANFIS metode je bio relativno slabiji u usporedbi s ostale tri ANN metode u pogledu ova dva kriterija za procjenu uspješnosti, osim slučaja ispitivanja (Tablice 6 i 7). ANFIS pokazuje manja odstupanja za fazu ispitivanja (Slike 14 i 15).



Slika 14. Dijagram raspršenja za podatke ispitivanja u slučaju predviđanja za 90 dana unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS



Slika 15. Hidrogram vodostaja za podatke ispitivanja u slučaju predviđanja za 90 dana unaprijed za (a) FFBP, (b) GRNN, (c) RBF i (d) ANFIS

5. ZAKLJUČCI

Za sva razdoblja predviđanja rezultati modela za RMSE su dani u Tablici 6. Sve AI metode dale su zadovoljavajuće rezultate predviđanja za prognoziranje vodostaja jezera za razdoblja predviđanja u rasponu između 1 dan i 90 dana. Vidljivo je da je GRNN metoda imala najbolje vrijednosti za kriterije procjene uspješnosti za razdoblja predviđanja veća od 1 dana. Može se zaključiti da pri povećanju razdoblja predviđanja rezultati predviđanja GRNN metodom imaju prevagu nad ostalim AI metodama. GRNN pristup ne zahtijeva iterativni postupak učenja, za razliku od FFBP-a i ANFIS-a. On aproksimira bilo koju proizvoljnu funkciju između ulaznih i izlaznih vektora, crtajući procjenu funkcije izravno iz podataka učenja [34]. Iako se i u ranijim studijama [38-39] pokazalo da GRNN daje bolje rezultate od FFBP-a, u ovoj studiji je po prvi put istraživana uspješnost ove metode u dugoročnom predviđanju neke hidrološke varijable, tj. vodostaja jezera.

ANFIS metoda je imala relativno slabije rezultate u odnosu na ostale tri ANN metode u pogledu ova dva kriterija za procjenu uspješnosti za razdoblje predviđanja (Tablice 6 i 7). ANFIS pokazuje manja odstupanja od opaženih vrijednosti za razdoblje predviđanja od 90 dana i za fazu ispitivanja (Slike 14 i 15). Na podacima ispitivanja, čini se da je FFBP bolji u odnosu na ostale tri AI metode (Tablice 6 i 7). Za podatke ispitivanja, ANFIS daje linearni porast RMSE s povećanjem razdoblja predviđanja. Nasuprot tome, ostale metode pokazuju različite trendove na RMSE liniji između uzastopnih razdoblja predviđanja. Razlog relativno slabijeg rezultata GRNN-a na podacima ispitivanja mogao bi biti veliki koeficijent asimetrije podataka ispitivanja za dotjecanje i otjecanje (Tablica 3). Asimetrija tečenja za ispitivanje primjetno je veća od vrijednosti za učenje (Tablica 3). Parametar širine GRNN-a je potpuno ovisan o asimetriji razmatrane vremenske serije [34]. Budući da se i za učenje i za ispitivanje koristi ista širina, rezultat GRNN-a za učenje je bio prilično dobar, ali za ispitivanje uspješnost predviđanja se relativno smanjila zbog gotovo udvostručenih vrijednosti asimetrije tečenja (Tablica 3).

Točno dugoročno predviđanje vodostaja jezera je prilično važno kako za aktivnosti za ekologiju, tako i za projekte kojima se bave ljudi, ovisno o vodostajima i bilanci voda na jezeru. Uz pomoć bliskih predviđanja za dugoročna razdoblja koja obuhvaćaju nekoliko mjeseci mogu se donijeti odluke o budućnosti projekata vodnih resursa, ranije osiguravajući dovoljno vremena za zahvaćeno lokalno stanovništvo uključeno ili pogođeno tim projektima.

Vodostaj jezera predstavlja dubinu jezera, a time i zapreminu jezera. Dakle, ako se vodostaj poveća, paralelno će se povećavati i količina vode. Količina vode ima dominantnu ulogu za stabilnost jezera. Za jezera s velikom površinom, promjena vodostaja jezera čak i od 1 cm može uzrokovati veliku promjenu zapremine vode jezera. Jezero s niskim vodostajem osjetljivije je na vanjske utjecaje u usporedbi sa slučajem velike zapremine vode. Količina topline za povećanje temperature dubokog jezera veća je od količine topline za plitko jezero. Stoga količina energije i trajanje promjene temperature potrebne za zagrijavanje ili hlađenje jezera ovise o vodostaju jezera. To će izravno utjecati na mikroorganizme, kemijske procese i način raslojavanja/ cirkulacije. Potom će ovi parametri utjecati na organizme (kao što su ribe, fitoplankton). Na primjer, ako će pomiješanost biti visoka, tada će se raslojavanje smanjiti. Dakle, broj mikroorganizama se povećava a zatim smanjuje na kvaliteti vode. U suprotnoj situaciji, tj. u slučaju velikog raslojavanja, u sloju hipolimniona (dna jezera) nalaze se hranjivi sastojci, ali ne i kisik, u sloju epilimniona (vrha jezera) nalazi se kisik, ali ne i hranjive tvari. Dakle, kako se broj mikroorganizama smanjuje, kvaliteta vode se poboljšava [40].

Ukratko, nekoliko ekoloških aktivnosti unutar jezera se izravno ili neizravno odnose na dubinu vode. To pokazuje kako je dugoročno predviđanje vodostaja jezera značajno za planove upravljanja jezerom, s obzirom da na biološke i kemijske procese bilo pozitivno bilo negativno utječe količina vode jezera. U normalnim uvjetima razina vode jezera ima ciklus i

ovaj ciklus ima drukčiju strukturu ako se ispituju različiti vremenski intervali. Na satnoj osnovi, tijekom sunčanog dana u jezeru u kojem je dominantno isparavanje, razina vode je visoka ujutro, a niska u večernjim satima. Međutim, za kišne dane razina vode je niska prije kiše, a visoka nakon kiše. Na mjesečnoj osnovi, vodostaj je visok u kišnim razdobljima (zima/proljeće), a nizak u sušnom razdoblju (ljetno). Ako je vremenski interval godina, vodostaj je visok u kišnoj godini i suprotno u sušnoj godini. Kratkoročni ciklusi se mogu bolje razumjeti. No, pošto su opažene vrijednosti ograničene i broj utjecajnih parametara velik, karakter vodostaja je složeniji i postoji mnogo mogućnosti varijacija je za dugoročne cikluse. Međutim, ovo istraživanje je potvrdilo uspješno korištenje metoda umjetne inteligencije (AI) u tu svrhu.

Uspješnost dugoročnog predviđanja pomoću AI metoda trebala bi se ispitati i za ostale hidrometeorološke varijable kao što su riječni protok, oborine, suspendirani nanos, temperatura itd. Budući da većina ovih varijabli ima niže autokorelacije u usporedbi s vodostajem jezera, bilo bi prilično izazovno za ove varijable analizirati rezultate predviđanja AI metodama.

LITERATURA

1. Vaziri, M.: Predicting Caspian Sea surface water level by ANN and ARIMA models, *J Wtrwy, Port, Coast, Oc. Engineering*, 1997, 123(4), 158–162.
2. See, L., Openshaw, S.: Applying soft computing approaches to river level forecasting, *Hydrological Sciences*, 1999, 44(5), 763-778.
3. Bazartseren, B., Hildebrandt, G., Holz, K.-P.: Short-term water level prediction using neural networks and neuro-fuzzy approach, *Neurocomputing*, 2003, 55, 439-450.
4. Coppola, E. A. Jr, Szidarovszky, F., Poulton, M., Charles, E.: Artificial neural network approach for predicting transient water levels in multi-layered groundwater system under variable state, pumping and climate conditions, *Journal of Hydrologic Engineering*, 2003, 8(6), 348-360.
5. Cigizoglu, H. K.: Estimation, forecasting and extrapolation of river flows by artificial neural networks, *Hydrol. Sci. J.*, 2003, 48(3), 349–362.
6. Iqbal, M., Naeem, U. A., Habib-ur-Rehman, A. A., Ghani, U., Farid, T.: Relating groundwater levels with meteorological parameters using ANN technique, *Measurement*, 166, 2020, <https://doi.org/10.1016/j.measurement.2020.108163>.
7. Cigizoglu, H. K., Alp, M.: Rainfall-Runoff Modelling Using Three Neural Network Methods, *Int. Conf. Artificial Intelligence and Soft Computing- ICAISC 2004, Lecture Notes in Artificial Intelligence*, 2004, 3070; 166-171.
8. Daliakopoulos, I. N., Coulibaly, P., Tsanis, I. K.: Groundwater level forecasting using artificial neural networks, *Journal of Hydrology*, 2005, 309, 229-240.
9. Alvisi, S., Mascellani, G., Franchini, M., Bardossy, A.: Water level forecasting through fuzzy logic and artificial neural network approaches, *Hydrology and Earth System Sciences*, 2006, 10(1), 1-17.
10. Bustami, R. A., Bessaih, N., Muhammad, M. S.: Artificial neural network for daily water level estimation, *Engineering e-Transaction*, (ISSN 1823-6379), 2006, 1(1), 7-12. (<http://ejum.fsktm.um.edu.my>).
11. Asefa, T., Wanakule, N., Adams, A.: Field-scale application of three types of neural networks to predict ground-water levels, *JAWRA*, 2007, 43(5), 1245-1256.
12. Ondimu, S., Murase, H.: Reservoir level forecasting using neural networks: Lake Naivasha, *Biosystems Engineering*, 2007, 96 (1), 135-138.
13. Sing, P., Deo, M. C.: Suitability of different neural networks in daily flow forecasting. *Applied Soft Computing*, 2007, 7, 968-978.

14. Han, G., Shi, Y.: Development of an Atlantic Canadian coastal water level neural network model, *Journal of Atmospheric and Oceanic Technology*, 2008, 25, 2117-2132.
15. Zeynoddin, M., Bonakdari, H., Ebtehaj, I., Azari, A., Gharabaghi, B.: A generalized linear stochastic model for lake level prediction, *Science of The Total Environment*, 2020, 723, 138015, <https://doi.org/10.1016/j.scitotenv.2020.138015>.-4129.
16. Tsanis, I. K., Coulibaly, P., Daliakopoulos, I. N.: Improving groundwater level forecasting with a feedforward neural network and linearly regressed projected precipitation, *Journal of Hydroinformatics*, 2008, 10(4), 317-330.
17. Sertel, E., Cigizoglu, H. K., Sanli, D. U.: Estimating daily mean sea level heights using artificial neural networks, *Journal of Coastal Research*, 2008, 24(3), 727-734.
18. Khaledian, M. R., Isazadeh, M., Biazar, S. M. et al.: Simulating Caspian Sea surface water level by artificial neural network and support vector machine models, *Acta Geophys.*, 2020, 68, 553-563. <https://doi.org/10.1007/s11600-020-00419-y>.
19. Partal, T., Cigizoglu, H. K.: Prediction of daily precipitation using wavelet-neural networks, *Hydrological Sciences Journal*, 2009, 54(2), 234-246.
20. Sreekanth, P. D., Geethanjali, N., Sreedevi, P. D., Ahmed, S., Kumar, N. R., Jayanthi, P. D. K.: Forecasting groundwater level using artificial neural networks, *Current Science*, 2009, 96(7), 933-939.
21. Zhang, G., Patuwo, B. E., Hu, M. Y.: Forecasting with artificial neural networks: The state of art, *International Journal of Forecasting*, 1998, 14, 35-62.
22. Maier, H. R., Dandy, G. C.: Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental Modelling and Software*, 2000, 15, 101-124.
23. Dawson, C. W., Wilby, R. L.: Hydrological modelling using artificial neural networks. *Progress in Physical Geography*, 2001, 25(1), 80-108.
24. Jain, A., Kumar A. M.: Hybrid neural network models for hydrologic time series forecasting, *Applied Soft Computing*, 2007, 7, 585-592.
25. Mirzaee, H.: Long-term prediction of chaotic time series with multi-step prediction horizons by a neural network with Levenberg-Marquardt learning, *Chaos, Solitons and Fractals*, 2009, 41, 1975-1979.
26. Cigizoglu, H. K.: Estimation and forecasting of daily suspended sediment data by multi-layer perceptrons, *Adv. Water Res.*, 2004, 27, 185-195.
27. Jain, A., Sudheer, K. P., Srinivasulu, S.: Identification of physical processes inherent in artificial neural network rainfall runoff models, *Hydrological Processes*, 2004, 18(3), 571-581.
28. Sudheer, K. P., Jain, A.: Explaining the internal behaviour of artificial neural network river flow models, *Hydrological Processes*, 2004, 18 (4), 833-844.
29. Sudheer, K. P.: Knowledge extraction from trained neural network river flow models, *Journal of Hydrologic Engineering*, 2005, 10 (4), 264-269.
30. Nayak, P. C., Sudheer, K. P., Rangan, D. M., Ramasastri, K. S.: A neuro-fuzzy computing technique for modelling hydrological time series, *Journal of Hydrology*, 2004, 291, 52-66.
31. Chang, F. J., Chang, Y. T.: Adaptive neuro-fuzzy inference system for prediction of water level in reservoir, *Advances in Water Resources*, 2006, 29, 1-10.
32. Coppola, E. A. Jr., Rana, A. J., Poulton, M. M., Szidarovszky, F., Uhl, V. W.: A neural network model for predicting aquifer water level elevations, *Ground Water*, 2005, 43(2), 231-241.
33. Dincer, T.: The use of oxygen 18 and deuterium concentrations in the water balance of lakes. *Water Resources Research*, 1968, 4(6), 1289-1306.
34. Specht, D. F.: A general regression neural network, *IEEE Transactions on Neural Networks*, 1991, 2(6): 568-576.
35. Broomhead, D., Lowe D.: Multivariable functional interpolation and adaptive networks, *Complex System*, 1988, 2, 321-355.

Akyuz, D. E., Cigizoglu, H. K.

Dugoročno predviđanje vodostaja jezera metodama umjetene inteligencije

36. Zadeh, L. A.: Outline of a new approach to analysis of complex systems and decision processes, IEEE Trans. Syst., Man, Cybern., 1973, 3, 28-44.
37. Jang, J.-S. R.: ANFIS: Adaptive-Network-based Fuzzy Inference Systems, IEEE Trans. on Systems, Man and Cybernetics, 1993, 23(3), 665-685.
38. Cigizoglu, H. K.: Generalized Regression Neural Network in Monthly Flow Forecasting, Civil Engineering and Environmental Systems, 2005, 22 (2), 71-84.
39. Cigizoglu, H. K.: Application of the Generalized Regression Neural Networks to Intermittent Flow Forecasting and Estimation, ASCE Journal of Hydrologic Engineering, 2005, 10(4), 336-341.
40. Odum, E. P., Barrett, G. W.: Fundamentals of Ecology, Thomson Brooks/Cole: Belmont, 2004, 624.