

Primljeno / Received: 17.07.2017.

Prihvaćeno / Accepted: 30.10.2017.

UDK 528.482

Pregledni naučni rad / Review article

# PREDIKCIJA POMJERANJA BLOKOVA BRANE PRIMJENOM VJEŠTAČKIH NEURONSKIH MREŽA

## DAM BLOCKS MOVEMENT PREDICTION USING ARTIFICIAL NEURAL NETWORKS

*Adis Hamzić, Zikrija Avdagić*

### SAŽETAK

Brane su veoma važni objekti za proizvodnju energije, navodnjavanje, zaštitu od poplava i turizam. Međutim, pored svih koristi koje pružaju, brane predstavljaju i veliku opasnost za područja nizvodno jer uvijek postoji određeni rizik od pucanja brane. Zbog ovoga rizika veoma je važno da se redovno vrši monitoring brana, a za te potrebe se koriste različite fizikalne i geodetske metode. Geodetske metode za monitoring koriste mrežu tačaka pri čemu se sa osnovne mreže tačaka opažaju objektne tačke koje su strateški raspoređene na samom objektu. Kvalitetnom predikcijom ponašanja objekta bilo bi moguće pravovremeno djelovanje na sprečavanju daljnog oštećenja objekta i spašavanju ljudskih života u slučaju veće opasnosti. U ovome radu su kao alat za predikciju pomjeranja brane korištene vještačke neuronske mreže (VNM). VNM su jako popularan alat za predikciju, a razlozi za to su brzo učenje iz primjera i dobra sposobnost generalizacije po čemu se razlikuju od mnogih tradicionalnih statističkih metoda.

**Ključne riječi:** brana, monitoring, neuronske mreže, predikcija

### ABSTRACT

The dams are very important objects for production of electric energy, irrigation, flood management and tourism. However, besides all benefits the dams provide, they also represent great danger for areas downstream because there is always risk of dam failure. To prevent dam failure it is important to perform regular dam monitoring and for that purpose geodetic and physical methods are used. Geodetic methods use special network of points for object monitoring where reference points are used for monitoring of object points which are strategically distributed on the object. By quality prediction of object behaviour it would be possible to prevent further damage on the object and additionally to save human lives in cases of great danger. In this paper artificial neural networks (ANNs) are used for dam movement prediction. ANNs are very popular tool for prediction since they are known for their quick learning ability and good generalization ability which gives them advantage compared to traditional statistical methods.

**Keywords:** dam, monitoring, neural networks, prediction.

## 1 UVOD

Brane, mostovi, visoke zgrade te drugi izgrađeni i prirodni objekti su podložni pomjeranjima zbog uticaja različitih faktora kojima su izloženi. Ti faktori mogu imati različit intenzitet i smjer i ne djeluju uвijek onako kako je očekivano. Zbog toga je bitno da se vrši redovan monitoring ponašanja ovih objekata kako bi se utvrdilo zdravlje objekta i sprječila eventualna oštećenja na objektu. Monitoring i analiza pomjeranja je predmet geodetske i građevinske struke. Važno je napomenuti da su pomjeranja objekata očekivana i normalna pojava, a deformacije nastaju u slučaju ekstremnih pomjeranja, neravnomjernih pomjeranja različitih dijelova objekta i u slučaju kada se pojedini dijelovi objekata pomjeraju u različitim pravcima ili smjerovima. Za mjerjenje pomaka i deformacija se koriste različiti instrumenti i metode koje možemo svrstati u dvije grupe: geodetske i fizikalne.

Geodetske metode za monitoring koriste mrežu tačaka pri čemu se tačke dijele na tačke osnovne kontrolne mreže i objektne tačke. Tačke osnovne mreže služe za osmatranje (sa njih se osmatra objekat) dok su objektne tačke strateški raspoređene na samome objektu tako da se na osnovu njihovog opažanja može stvoriti precizna slika ponašanja objekta. Pri osmatranju brana najčešće korištene geodetske metode su: tahimetrija (mjerjenje dužina, horizontalnih i vertikalnih uglova), geometrijski i hidrostatski nivelman (mjerjenje visinskih razlika), opažanje pomoću globalnog sistema za pozicioniranje (eng. *Global Positioning System – GPS*) i aliniranje (ispitivanje koliko su se tačke na objektu pomjerile u odnosu na pravac koji je zadan dvjema stabilnim tačkama). Geodetske metode daju globalnu sliku ponašanja objekta ali i terena u okolini objekta, međutim preciznost je lošija u odnosu na fizikalne metode osmatranja. Prednost je što se obavi veliki broj mjerena (prekobrojnost) koja se statistički obrađuju i na taj način se dobije pouzdanost te se mogu odstraniti grube greške i ocijeniti kvalitet mjerena. S druge strane, fizikalne metode osmatranja daju podatke o lokalizovanim pomjeranjima s tim da se kontrola kvaliteta mjerena može ustanoviti samo poređenjem sa drugim nezavisnim mjeranjima. Prednost instrumenata koji se koriste za fizikalna osmatranja (deformetri, viskovi, klinometri, i dr.) je to što ih je lako prilagoditi za automatska kontinuirana opažanja. Podaci pomjeranja objekta korišteni u ovome radu su dobijeni isključivo primjenom geodetskih metoda osmatranja.

Ukoliko se monitoring objekta vrši redovno, što je uobičajeno, vremenom se skupi velika količina podataka pomjeranja objekta. Korištenjem ovih podataka može se mnogo naučiti o ponašanju objekta, a zatim je moguće vršiti i predikcije budućeg ponašanja. Za predikciju pomjeranja blokova brane u ovome radu su korištene vještačke neuronske mreže (VNM). Ova metoda predikcije je odabrana jer su VNM jako dobre u učenju iz primjera te pronalaženju veza i šablonu iz podataka koji su naizgled nepovezani. Kvalitetnim predviđanjem pomjeranja i deformacija značajno bi se poboljšala sigurnost i olakšalo održavanje brane.

Predikcija pomjeranja brana i deformaciona analiza primjenom VNM je oblast koju mnogi naučnici istražuju u novije vrijeme pa postoji i znatan broj radova sa ovom tematikom. U nastavku je prikazan kratak pregled radova iz ove oblasti.

Miao, Chu, Zhang i Qiao (2013) kombinacijom Levenberg-Marquardt algoritma za treniranje VNM i genetičkog algoritma za optimizaciju arhitekture VNM su kreirali model za predikciju

deformacija brana. Ovaj model je pokazao bolje performanse i dao bolje predikcije u odnosu na konvencionalne VNM.

Model baziran na VNM je napravljen i provjeren prema kriterijima maksimalnog opterećenja, naprezanja i hidrodinamičkog pritiska na bloku gravitacione brane. Istraživanje su proveli Al-Suhaili, Ali i Behaya (2014) i došli su do zaključka da je primjenom VNM moguće precizno procijeniti vrijednosti za sva tri navedena kriterija.

Nourani i Ghaffarisu (2012) su poredili metod granične ravnoteže (eng. *limit equilibrium method* – LEM) i VNM na slučaju Zonouz nasute brane u Iranu. Zaključak istraživanja je da se VNM mogu koristiti kao alternativa metodu granične ravnoteže koji se uobičajeno koristi za utvrđivanje stabilnosti kosina.

Hu, Zhang i Song (2011) su vršili deformacionu analizu brane koristeći 4 modela, i to: model baziran na linearnoj regresiji, statistički model, model baziran na VNM sa povratnom spregom i kombinovani model baziran na VNM. Kombinovani model kojeg su predložili autori (statistički model u kombinaciji sa VNM) je dao bolje rezultate predikcije pomjeranja od ostala 3 modela. Korištenjem podataka o nivou vode na brani i podataka pomjeranja određenih pomoću viska Boehm i Kutterer (2006) su razvili sistem baziran na VNM i „Fuzzy“ sistemu zaključivanja (eng. *Artificial Neural Network and Fuzzy Inference System* – ANFIS) za predikciju deformacija brane. U zaključku autori ističu da ANFIS daje dobre rezultate predikcije ali i da se rezultati mogu dodatno unaprijediti uvođenjem novih varijabli i mjerena u sistem.

Joghataie i M. S. Dizaji (2009) koriste VNM za modeliranje ponašanja Koyna brane u slučaju zemljotresa. U radu vezanom na prethodno istraživanje Joghataie, M. S. Dizaji i F. S. Dizaji (2012) su razvili softver „Neuro-modeller“ baziran na VNM za dinamičku analizu stabilnosti brane u slučaju zemljotresa. U prvom koraku „Neuro-modeller“ je korišten za analizu ponašanja brane u vrijeme više različitih zemljotresa, a u drugom koraku su korištenjem podataka drugih zemljotresa provedeni numerički testovi. Za uporedbu rezultata analize korišten je i softver „NSAG-DRI“ koji je baziran na metodi konačnih elemenata. Iako su se oba softvera pokazala uspješnim, „Neuro-modeller“ je brže dolazio do rezultata u odnosu na „NSAG-DRI“ softver. Važno je istaći i to da se „Neuro-modeller“ trenira samo jednom, ne zahtijeva ažuriranje, a ipak može precizno predvidjeti reakciju brane na zemljotres.

Behnia, Ahangari, Noorzad i Moeinossadat (2013) koriste genetičko programiranje (eng. *Gene Expression Programming* – GEP) i ANFIS za predikciju slijeganja kod nasutih brana prilikom prvog punjenja akumulacije. Analiza ponašanja tijela brane je izvršena na osnovu podataka sa 24 brane širom svijeta. Rezultati su pokazali da procjene dobijene korištenjem ove metode odgovaraju stvarnim mjeranjima. Behnia i dr. (2014) u drugome istraživanju ispituju slijeganje nasutih brana uzimajući u obzir visinu brane i indeks kompresije. Rezultati su pokazali da je na osnovu ovih faktora moguće kvalitetno predvidjeti slijeganje brana.

Demirkaya i Balcilar (2012) analiziraju radikalne pomake lučne brane na osnovu historijskih podataka o nivou vode u akumulaciji i temperaturi betona. U analizi koriste višestruku linearnu regresiju i VNM. U istraživanju višestruka linearna regresija je pokazala bolje rezultate od VNM, ali zaključak autora je da i VNM imaju zadovoljavajuću performansu prilikom analize deformacija na brani.

Demirkaya (2010) koristi ANFIS za analizu deformacija lučne brane na osnovu sedmogodišnjeg niza podataka o nivou vode, temperature zraka, temperature betona i pomaka mjerениh

inverznim viskom. Rezultati su pokazali da se ANFIS može uspješno primjenjivati u predikciji deformacija jer pruža dobru pouzdanost i preciznost pomaka brane.

Neuner (2010) ističe da su VNM veoma fleksibilan alat i veoma pogodne za modeliranje nelinearnih veza između ulaznih i izlaznih varijabli. U svom istraživanju Neuner opisuje metodologiju modeliranja deformacija brane prilikom promjena nivoa vode i temperature. Fokus istraživanja je na odabiru broja neurona u skrivenom sloju VNM koja je korištena za deformacionu analizu. Autor koristi dvije metode od kojih je prva kros-validation, a druga tehnika brisanja težina (eng. *weight deletion technique*) bazirana na računanju Hesianske matrice. Obje metode su pokazale veoma slične rezultate, a sama VNM se pokazala dobrom za deformacionu analizu brane.

Zhu i dr. (2016) koriste dugogodišnji niz podataka monitoringa brane za treniranje VNM sa algoritmom povratne sprege (eng. *Backpropagation algorithm*) da bi izvršili deformacionu analizu brane. Korištene VNM su dodatno optimizovane pomoću algoritma vještačke pčelinje kolonije (eng. *artificial bee colony*) čime su se dobili pouzdaniji rezultati uz bržu konvergenciju prilikom treniranja mreže.

Hu i dr. (2017) koriste „ekstremnu učeću mašinu“ (eng. *extreme learning machine*), nova vrsta VNM sa samo jednim neuronom u skrivenom sloju koju je prvi preporučio Huang Guangbin, za predikciju pomjeranja u slučaju pojave abnormalnih vrijednosti mjerjenja. Rezultati istraživanja su pokazali da je ovaj model bolji od klasičnih neuronskih mreža i ispitanih statističkih metoda. Podaci korišteni u ovome radu su prikupljeni geodetskim metodama osmatranja na Hidroelektrani (HE) Jablanica. HE Jablanica je prvo hidroenergetsko postrojenje izgrađeno na rijeci Neretvi. Proizvodnja električne energije u HE Jablanica započela je u februaru 1955. godine. Nakon izgradnje bila je najveći hidroenergetski objekat u bivšoj SFR Jugoslaviji. Akumulacijom HE obuhvaćene su vode Neretve i svih njenih pritoka uzvodno od Jablanice. Podizanjem lučno-gravitacione betonske brane visoke 85 metara oko 5km sjeverno od Jablanice, neposredno ispod ušća rijeke Rame u Neretvu, stvoreno je akumulaciono jezero. Tehnički podaci o brani i akumulaciji su preuzeti iz dokumenta „Korištenje akumulacije Jablanica“ (Elektroprojekt Zagreb, 1963).

Ciljevi rada su sljedeći:

1. Ispitati mogućnost predikcije pomjeranja blokova brane primjenom VNM sa direktnim prostiranjem signala i algoritmom za prostiranje signala unazad (eng. *Feed Forward Backpropagation Neural Network - FFBP*).
2. Izvršiti predikciju pomjeranja blokova brane korištenjem neuronske mreže koja je postigla najbolje rezultate prilikom treniranja mreže.
3. Eksternom validacijom utvrditi kvalitet predikcije primjenom VNM.

Rad je organizovan na sljedeći način:

- U drugom poglavlju je ukratko opisan objekat na kome su prikupljani podaci korišteni u radu. Dodatno, definisan je koordinatni sistem brane i naglašeno je koji podaci su korišteni u treniranju i validaciji VNM.
- Treće poglavlje opisuje korištene metode za obradu podataka i predikciju pomaka. Kratko je opisan osnovni proces obrade podataka korištenjem GOCA softvera i prikazani su osnovni principi rada VNM.
- Četvrto poglavlje prikazuje dobijene rezultate i daje kratku diskusiju dobijenih rezultata.
- U petom poglavlju su navedeni zaključci rada.

## 2 PODACI

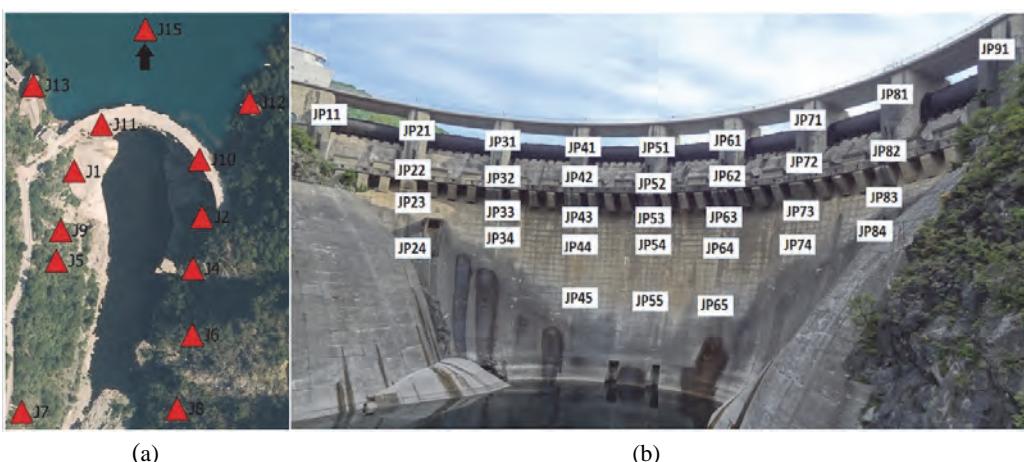
Osmatranje brane geodetskim metodama je započelo 1954. godine neposredno prije prvog punjenja akumulacionog jezera i tada je snimljena tzv. „nulta serija“ mjerena. Od tada se osmatranje vršilo jednom ili dva puta godišnje. Modernizacijom sistema osmatranja 2012. godine (izrada novih geodetskih stubova, postavljanje novih plata na postojeće i nove stubove tako da je moguće prisilno centrisanje instrumenta, postavljanje mjernih prizmi na branu, nabavka modernih instrumenata i softvera za mjerjenje, itd.) omogućeno je brže i pouzdano mjerjenje pomaka brane.

Za potrebe osmatranja brane uspostavljena je mreža geodetskih tačaka (Slika 1). Osnovnu kontrolnu mrežu (Slika 1a) čini 13 geodetskih stubova od kojih je 8 postavljeno nizvodno od brane, 2 na samoj brani (radi prenošenja vizure preko brane) i 3 stuba postavljena uzvodno od brane. Objektnu mrežu (Slika 1b) čine 33 tačke pravilno raspoređene na tijelu brane. Tačke su postavljene tako da je na osnovu mjerena ovih tačaka moguće stvoriti preciznu sliku ponašanja objekta.

Koordinatni sistem brane je definisan na sljedeći način:

- Ishodište koordinatnog sistema je u stubu J5,
- X osa prolazi kroz geometrijski centar stuba J5, a pozitivan smjer ose je smjer sjevera,
- Y osa je okomita na osu X u stubu J5, a pozitivan smjer ose Y je smjer istoka,
- H osa – nadmorska visina.

Mjerjenje pomaka objekta izvršeno je geodetskim metodama, a za obradu podataka korišten je GOCA softver. Prikupljanje podataka je djelomično automatizovano - operatori moraju otići na teren, postaviti instrument i podesiti postavke „GOCA-Terrestrial Positioning System-Control“ softvera (visina instrumenta, visina mjernih prizmi, mjesto pohranjivanja podataka, atmosferski parametri, itd.), a zatim robotizovana totalna stanica automatski vrši viziranje, mjerjenje i pohranu podataka. Na ovaj način proces prikupljanja je ubrzan, a eliminisane su i greške operatora prilikom evidencije mjerjenja.



Slika 1. Položaj stubova osnovne kontrolne mreže brane (a), položaj tačaka objektne mreže brane (b)

U radu je korišteno ukupno 16 epoha mjerjenja (pomaci blokova sračunati iz mjerjenja) od čega je prvih 14 epoha korišteno kao ulaz u mrežu (eng. *inputs*), epoha XV je bila cilj (eng. *target*), a epoha XVI je iskorištena za eksternu validaciju kako bi se provjerila stvarna mogućnost predikcije. Od ukupno 33 objektne tačke, 30 tačaka je učestvovalo u treniranju i validaciji VNM. Tri objektne tačke (JP24, JP44 i JP84) imaju nekompletne vremenske serije osmatranja (nedostaje određen broj mjerjenja) pa nisu korištene u ovome radu.

Tabela 1.  
*Podaci pomjeranja blokova brane*

X osa [mm]					Y osa [mm]				
Epoha Tačka	I	II	...	XVI	Epoha Tačka	I	II	...	XVI
<b>JP11</b>	-1,3	-0,4	...	-0,4	<b>JP11</b>	-3,0	-1,6	...	-1,0
<b>JP21</b>	-12,4	-12,1	...	-9,9	<b>JP21</b>	2,7	3,7	...	4,6
<b>JP22</b>	-11,1	-10,8	...	-9,4	<b>JP22</b>	3,7	4,3	...	5,3
<b>JP23</b>	-10,3	-10,2	...	-8,9	<b>JP23</b>	2,4	3,5	...	4,8
:	:	:	:	:	:	:	:	:	:
<b>JP74</b>	-9,4	-10,0	...	-7,5	<b>JP74</b>	-1,7	-1,6	...	0,4
<b>JP81</b>	-8,2	-8,8	...	-6,3	<b>JP81</b>	-7,2	-7,4	...	-3,6
<b>JP82</b>	-9,5	-10,1	...	-7,9	<b>JP82</b>	-3,2	-2,7	...	-0,1
<b>JP83</b>	-9,2	-9,2	...	-7,9	<b>JP83</b>	-4,1	-3,5	...	-1,6
<b>JP91</b>	-6,0	-6,3	...	-5,4	<b>JP91</b>	-7,9	-8,0	...	-5,5

### 3 METODE

GOCA je višesenzorski sistem koji koristi podatke GPS mjerjenja, totalnih stanica, geometrijskog nivelmana, hidrostatskog nivelmana i lokalnih senzora za monitoring i analizu deformacija u realnom vremenu. GOCA je dizajnirana za monitoring prirodnih i izgrađenih objekata pri čemu kao rezultat daje pomake, brzine i ubrzanja objektnih tačaka u trodimenzionalnom sistemu (Jäger, Hoszislawski i Oswald, 2009). U ovome radu korišteni su samo pomaci objektnih tačaka.

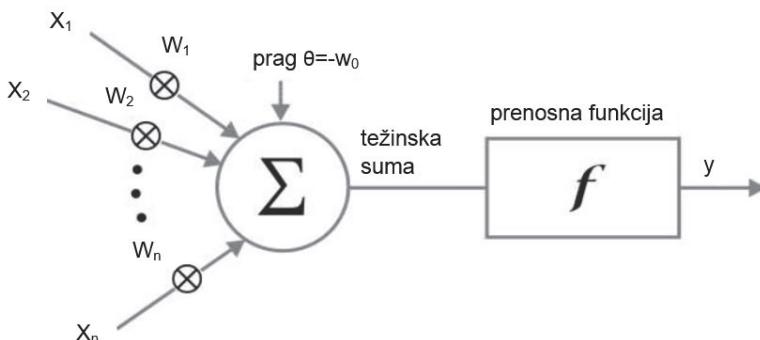
Deformaciona analiza primjenom GOCA-e sastoji se iz 3 koraka (Jäger i González, 2006):

1. Inicijalizacija – izravnjanje slobodne mreže u lokalnom koordinatnom sistemu pri čemu se uklanjuju grube greške Baarda *data snooping* metodom prije dobijanja konačnih rezultata iterativnim postupkom.
2. Drugi korak obuhvata izravnjanje na osnovu mjerenih vrijednosti (dužina, uglova i visina), a matematički model obezbjeđuje georeferensiranje objektnih tačaka vremenske serije. U ovome koraku se definiše i referentni okvir koji se sastoji od stabilnih referentnih tačaka pri čemu matematički model uzima u obzir i koordinate i kovarijacijske matrice referentnih tačaka.

3. Treći korak je deformaciona analiza. U ovom koraku se ispituje stabilnost referentnih tačaka; ako su sve tačke stabilne vrši se testiranje pomaka objektnih tačaka. Međutim, ako test statistika pokaže da postoje nestabilne referentne tačke onda se te tačke identificuju (postupak lokalizacije nestabilnih tačaka), a tek onda se testiraju pomaci objektnih tačaka.

Pomaci dobijeni obradom mjerenja GOCA softverom koriste se za predikciju primjenom VNM. McCulloch i Pitts (1943) uvode teoretsku osnovu i osnovnu logiku rada VNM. Funkcionalnost biološkog neurona imitira McCulloch-Pitts model vještačkog neurona (Slika 2). Model koristi sljedeću analogiju (Bašić, Čupić i Šnajder, 2008):

- signali opisani numeričkim iznosom ( $x_i, i = 1 \dots n$ ) na ulazu u neuron množe se težinskim faktorom ( $w_i, i = 1 \dots n$ ) koji opisuje jakost sinapse,
- signali pomnoženi težinskim faktorima se sumiraju analogno sumiranju potencijala u tijelu stanice,
- ako je dobiveni iznos iznad definisanog praga, neuron daje izlazni signal.



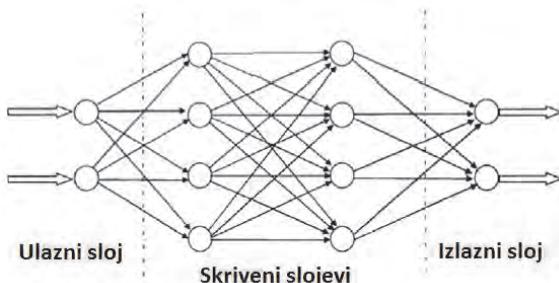
Slika 2. Opšti model vještačkog neurona (Bašić, Čupić i Šnajder, 2008)

Rad na VNM je motivisan spoznajom da ljudski mozak radi na znatno drugačiji način u odnosu na konvencionalne računare. Mozak je ustvari veoma kompleksan, nelinearan i paralelan računar. Mozak ima sposobnost da organizuje svoje neurone da vrše različita računanja kao što je prepoznavanje šablonu u ponašanju ili podacima, kontrola pokreta, vid, itd. (Haykin, 1999).

Kao što je prethodno naglašeno VNM su razvijene da oponašaju ljudski mozak. VNM se sastoji od više neurona koji su povezani tako da svaki neuron prima ulazni signal od drugih neurona, procesira taj signal i proizvodi transformisani izlazni signal kojeg šalje drugim neuronima (Avdagić, 2003). Uče iz primjera i „hvataju“ funkcionalne veze između podataka čak i kada su te veze teško opisive. Zbog ovih osobina često se koriste za rješavanje problema čija rješenja zahtijevaju znanje koje je teško opisati, ali za koje postoji dovoljno podataka koji opisuju taj problem (Zhang, Patuwo i Hu, 1998).

Za predikciju pomjeranja blokova brane odabrane su vještačke neuronske mreže sa direktnim prostiranjem signala i algoritmom za prostiranje signala unazad (slika 3). Ovaj tip neuronske mreže je odabran za predikciju pomjeranja blokova brane jer je pokazao dobre rezultate u istraživanjima koja su proveli: Kim i Kim (2008), Wang, Li i Shen (2007), Majdi i Beiki (2010), Sheng i dr. (2010), Wu, Qiao, Liang i Zhao (2010), Ma, Wang i Chen (2009), itd.

FFBP mreže (slika 3) se sastoje od serije slojeva. Prvi sloj ima težine koje dolaze od ulaza, svaki sljedeći sloj dobija težine od prethodnog sloja, a posljednji sloj je izlaz iz mreže (Beale, Hagan i Demuth, 2015).



Slika 3. Šematski prikaz FFBP neuronske mreže (Ata, 2015)

Prilikom treniranja VNM uobičajena praksa je da se korišteni podaci podijele u tri podskupa. Prvi podskup je skup za treniranje koji se koristi za učenje VNM. Drugi podskup je validirajući skup podataka, a njegova uloga je da zaustavi treniranje mreže u onome momentu kada je greška treniranja mreže minimalna. Treći podskup je testni skup podataka i ovaj skup se koristi za poređenje različitih modela (Beale, Hagan i Demuth, 2015).

U VNM koje su korištene za predikciju pomaka blokova brane korištena je *dividerand* MATLAB funkcija. Ova funkcija podatke dijeli u navedena tri podskupa slučajnim odabirom pri čemu su predodređeni odnosi za trenirajući, validirajući i testni skup 70%, 15% i 15% respektivno (Beale, Hagan i Demuth, 2015). Za treniranje mreže odabran je Levenberg-Marquardt algoritam koji je poznat po tome što brzo konvergira ka rješenju (Yu i Wilamowski, 2011).

Potrebno je istaći da ne postoji formula kojom bi se tačno odredila arhitektura VNM koja će biti korištena za predikciju, međutim postoje određene smjernice koje pomažu da se odredi broj skrivenih slojeva i broj neurona u skrivenom sloju. Heaton (2008) daje sljedeće smjernice kada je u pitanju odabir arhitekture VNM:

1. Broj skrivenih slojeva:
  - a. VNM bez skrivenih slojeva može predstaviti samo linearno odvojive funkcije ili odluke.
  - b. Korištenje jednog skrivenog sloja je dovoljno za rješavanje velike većine problema. Jedan skriveni sloj može aproksimirati bilo koju funkciju koja sadrži neprekidno preslikavanje iz jednog konačnog prostora u drugi.
  - c. Dodavanje drugog ili trećeg skrivenog sloja će samo u jako rijetkim situacijama poboljšati performansu VNM. Sa dva ili više skrivenih slojeva moguće je aproksimirati svako zaglađeno (eng. *smooth*) preslikavanje sa željenom tačnošću.
2. Broj neurona u skrivenim slojevima:
  - a. Treba biti između veličine ulaznog sloja i veličine izlaznog sloja.
  - b. Treba biti 2/3 veličine ulaznog sloja plus veličina izlaznog sloja.
  - c. Treba biti dvostruko manji od ulaznog sloja.

Korištenjem Heaton-ovih smjernica određena je početna arhitektura, a zatim je metodom pokušaja i pogreške određen najbolji model iz testiranog podskupa (različit broj skrivenih slojeva i broj neurona u skrivenim slojevima). Važno je naglasiti da je testiran samo jedan mali podskup iz cijelog skupa modela FFBP VNM i da dobijeno rješenje najvjerovaljnije nije najbolje rješenje. Međutim, kako je cilj ovoga rada ustanoviti mogu li se VNM koristiti za predikciju pomaka blokova brane ili ne, dovoljno je dobiti dobro rješenje (a ne optimalno) da se odgovori na ovo pitanje.

## 4 REZULTATI I DISKUSIJA

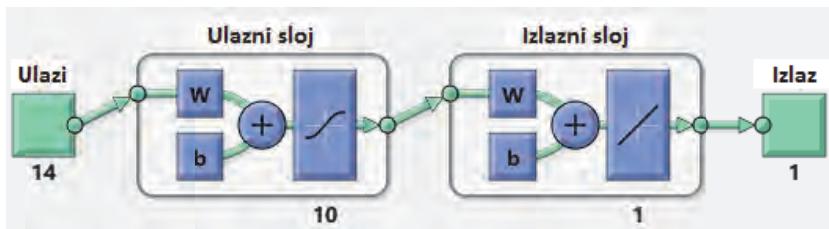
Ako se sa  $y_i$  označi  $i$ -to mjerjenje, a sa  $\bar{y}_i$  predikciju od  $y_i$ , tada je greška predikcije  $e_i$  (Hyndman i Athanasopoulos, 2014):

$$e_i = y_i - \bar{y}_i. \quad (1)$$

Za ocjenu kvaliteta predikcije VNM korištena su dva parametra: srednja apsolutna greška i maksimalna greška. Srednja apsolutna greška je korištena da pokaže ukupni kvalitet predikcije, a maksimalna apsolutna greška je korištena kao mjera pouzdanosti predikcije, tj. koliko se može vjerovati svakoj predviđenoj vrijednosti. Srednja apsolutna greška (SAG) je definisana sa:

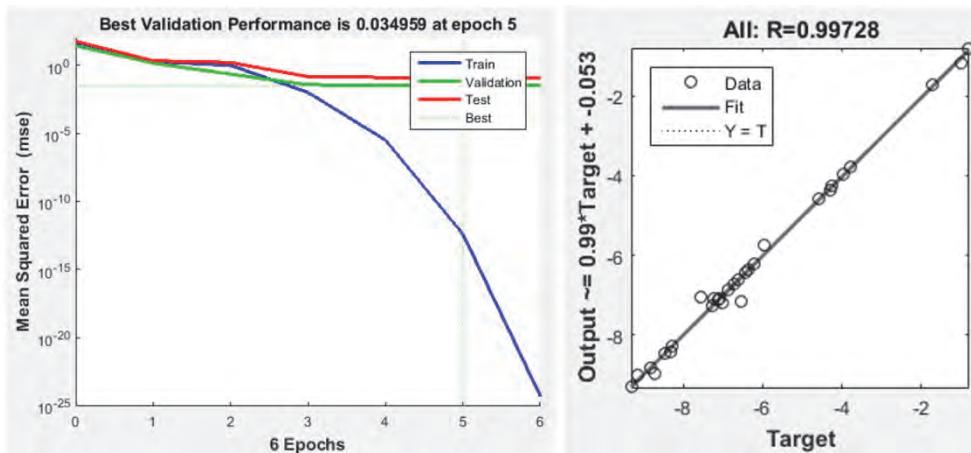
$$SAG = \frac{1}{n} \sum_{i=1}^n |e_i|. \quad (2)$$

Treniranje VNM je izvršeno za sve objektne tačke zajedno s tim da se treniranje vršilo nezavisno za pomake u smjeru  $X$  ose i pomake u smjeru  $Y$  ose. U prvom krugu ispitivanja VNM broj neurona u skrivenom sloju je varirao između 5 i 15. Nakon prvog kruga testiranja ustanovljeno je da modeli sa 10 i 11 neurona u skrivenom sloju daju najbolje rezultate (najbolja validaciona performansa treniranja – eng. *best validation performance*). Dodatnim testiranjem ustanovljeno je da je model sa 10 neurona u skrivenom sloju (Slika 4) najbolje rješenje iz skupa testiranih modela i za predikciju pomaka u smjeru  $X$  ose i za predikciju pomaka u smjeru  $Y$  ose.

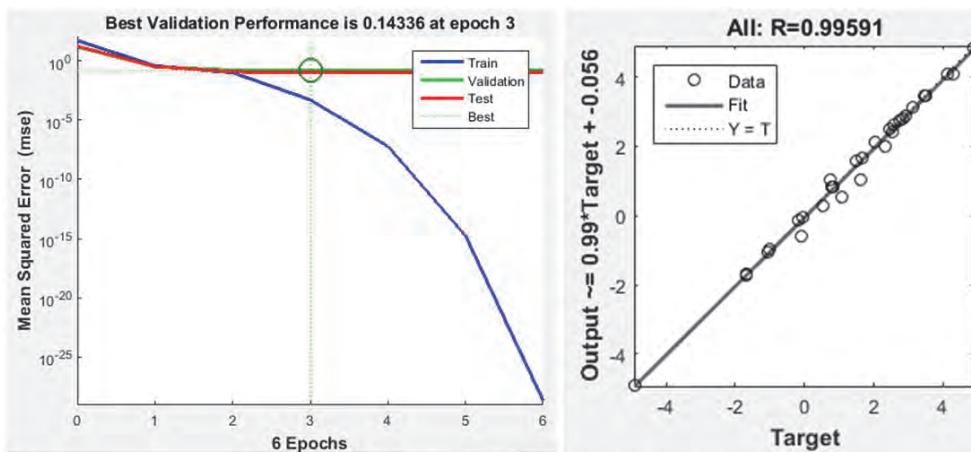


Slika 4. Šema VNM korištene za predikciju pomaka blokova brane (MATLAB 2015b)

Rezultati treniranja VNM (najbolja validaciona performansa i grafikon „izlazi vs. ciljevi“) za predikciju pomaka u smjeru  $X$  i  $Y$  ose su prikazani na Slikama 5 i 6.



Slika 5. Najbolja validaciona performansa treniranja VNM i grafikon „izlazi vs. ciljevi“ (eng. „outputs vs. targets“) za predikciju pomaka u smjeru X ose (MATLAB 2015b)



Slika 6. Najbolja validaciona performansa treniranja VNM i grafikon „izlazi vs. ciljevi“ (eng. „outputs vs. targets“) za predikciju pomaka u smjeru Y ose (MATLAB 2015b)

Trenirane VNM su iskorištene za predikciju pomaka blokova brane u epohi XVI, a rezultati predikcije su poređeni sa stvarnim izmjerениim vrijednostima koji su dobijeni na osnovu podataka prikupljenih geodetskim metodama osmatranja brane. Izmjereni pomaci iz epohe XVI su prikazani uporedno sa predviđenim vrijednostima pomaka blokova brane korištenjem VNM u tabelama 2 i 3.

Pregledom dobijenih rezultata iz tabela 2 i 3 vidljivo je da su predviđene vrijednosti blizu mjeranim. Kada su u pitanju pomaci u smjeru X ose (Tabela 2) srednja apsolutna greška predikcije je 1,0 mm, a najveća greška predikcije je napravljena na tački JP51 i iznosi 2,5 mm. Kod pomaka u smjeru Y ose (Tabela 3) srednja apsolutna greška predikcije je 0,9 mm, a najveća pogreška predikcije je napravljena na tački JP61 i iznosi 3,6 mm.

Tabela 2.

*Mjereni pomaci (epoha XVI) i predviđeni pomaci blokova brane - X osa*

Tačka	JP11	JP21	JP22	JP23	JP31	JP32	JP33	JP34	JP41	JP42
<b>Mjereni [mm]</b>	-0,4	-9,9	-9,4	-8,9	-9,3	-9,8	-8,3	-9,6	-8,7	-9,8
<b>Predikcija [mm]</b>	-0,7	-8,8	-8,7	-8,6	-8,1	-9,2	-7,4	-9,4	-7,6	-8,7
Tačka	JP43	JP45	JP51	JP52	JP53	JP54	JP55	JP61	JP62	JP63
<b>Mjereni [mm]</b>	-9,0	-2,0	-8,6	-5,0	-9,7	-8,3	-8,8	-7,9	-9,8	-8,6
<b>Predikcija [mm]</b>	-8,2	-1,7	-6,1	-5,0	-8,8	-6,8	-8,4	-8,5	-8,4	-6,8
Tačka	JP64	JP65	JP71	JP72	JP73	JP74	JP81	JP82	JP83	JP91
<b>Mjereni [mm]</b>	-8,7	-9,8	-9,1	-7,6	-7,6	-7,5	-6,3	-7,9	-7,9	-5,4
<b>Predikcija [mm]</b>	-7,7	-8,7	-7,0	-6,7	-6,5	-6,4	-4,8	-6,7	-6,8	-3,9

Tabela 3.

*Mjereni pomaci (epoha XVI) i predviđeni pomaci blokova brane – Y osa*

Tačka	JP11	JP21	JP22	JP23	JP31	JP32	JP33	JP34	JP41	JP42
<b>Mjereni [mm]</b>	-1,0	4,6	5,3	4,8	5,0	4,0	4,6	4,0	2,3	2,3
<b>Predikcija [mm]</b>	-1,0	3,0	4,3	3,4	3,2	2,8	2,9	2,7	2,5	1,1
Tačka	JP43	JP45	JP51	JP52	JP53	JP54	JP55	JP61	JP62	JP63
<b>Mjereni [mm]</b>	1,0	0,1	0,5	-0,8	0,9	1,1	1,4	0,6	1,3	0,8
<b>Predikcija [mm]</b>	-0,2	-1,4	0,6	-2,3	-0,2	1,0	0,3	4,3	1,9	1,8
Tačka	JP64	JP65	JP71	JP72	JP73	JP74	JP81	JP82	JP83	JP91
<b>Mjereni [mm]</b>	1,3	2,5	1,6	-1,8	-1,3	0,4	-3,6	-0,1	-1,6	-5,5
<b>Predikcija [mm]</b>	1,9	2,8	2,7	-1,0	-0,9	0,8	-3,5	0,2	-1,4	-5,4

Rezultati predikcije pomaka blokova brane primjenom VNM su zadovoljavajući obzirom na to da srednja apsolutna greška predikcije ne prelazi vrijednost od 1mm. Međutim, važno je naglasiti da su maksimalne greške predikcije znatno veće od srednje apsolutne greške što govori da pouzdanost predikcije nije zadovoljavajuća pa se tako na nekim tačkama dobije predikcija bez greške, dok na drugima doseže vrijednost i preko 3 mm.

## 5 ZAKLJUČAK

U radu je opisan postupak predikcije pomaka blokova brane primjenom vještačkih neuronskih mreža. Ukupno je korišteno 16 epoha mjerenja, od čega je 15 epoha korišteno za treniranje (učenje) neuronske mreže, a epoha XVI je iskorištena za ispitivanje koliko dobro trenirana mreža može predvidjeti buduće pomake. Za predikciju je korištena neuronska mreža sa direktnim prostiranjem signala i algoritmom za prostiranje signala unazad. Testiranjem

različitim modela ustanovljeno je da iz testnog podskupa najbolje rezultate daje mreža sa jednim skrivenim slojem i 10 neurona u skrivenom sloju. Mreža sa ovakvom arhitekturom (1 skriveni sloj sa 10 neurona) je korištena za predikciju pomaka blokova brane.

Analizom dobijenih rezultata iz ispitivanja koja su izvršena u okviru ovoga rada može se zaključiti da su vještačke neuronske mreže dobar alat za predikciju pomaka blokova brane. U okviru ovoga rada za treniranje VNM su korišteni samo historijski podaci pomaka blokova brane što nije velika osnova za učenje VNM. Ipak, usprkos maloj bazi za učenje VNM su pokazale da mogu dati dobre predikcije pomaka blokova.

Dobijeni rezultati bi se mogli unaprijediti, prema kriteriju preciznosti i pouzdanosti, ako bi se koristio veći broj mjerena za učenje (duža vremenska serija opažanja) ili ako bi se uzeli u obzir kriteriji koji utiču na pomjeranje brane kao što su nivo vode i temperatura betona brane. Uvođenje ovih kriterija u učenje VNM bi mogao biti jedan od budućih zadataka za istraživanje. Dodatno, poželjno je uporediti dobijene rezultate sa drugim metodama za predikciju, kao što su npr. Kalman filter ili autoregresivni integrisani model pokretnih sredina (ARIMA), da bi se dobio realan osjećaj o kvalitetu predikcije primjenom neuronskih mreža.

## ZAHVALA

Javno preduzeće Elektroprivreda Bosne i Hercegovine, podružnica Hidroelektrane na Neretvi, je dozvolilo korištenje podataka osmatranja brane u Jablanici, a Elektrotehnički Fakultet u Sarajevu je ustupio na korištenje Laboratoriju za vještačku inteligenciju i bioinformatiku. Bez pomoći ovih institucija pisanje ovoga rada ne bi bilo moguće zbog čega im se autori iskreno zahvaljuju.

## LITERATURA I IZVORI

Al-Suhaili, R. H., Ali, P. D. A. A., Behaya, S. A. (2014). Artificial Neural Network Modeling for the Dynamic Analysis of Dam-Reservoir-Foundation System. *Journal of Engineering Research and Application*, 4(1), 10-32.

Ata, R. (2015). Artificial neural networks applications in wind energy systems: a review. *Renewable and Sustainable Energy Reviews*, 49, 534-562.

Avdagić, Z. (2003). *Vještačka inteligencija i fuzzy-neuro-genetika*. Sarajevo: Grafoart.

Bašić, B., Čupić, M., Šnajder, J. (2008). Umjetne neuronske mreže. Skripta. Dostupno na: [https://www.fer.hr/\\_download/repository/UmjetneNeuronskeMreze.pdf](https://www.fer.hr/_download/repository/UmjetneNeuronskeMreze.pdf)

Beale, M. H., Hagan, M. T., Demuth, H. B. (2015). Neural networks toolbox user's guide. The MathWorks, Inc. Dostupno na: [https://www.mathworks.com/help/pdf\\_doc/nnet/nnet\\_ug.pdf](https://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf)

Behnia, D., Ahangari, K., Noorzad, A., Moeinossadat, S. R. (2013). Predicting crest settlement in concrete face rockfill dams using adaptive neuro-fuzzy inference system and gene expression programming intelligent methods. *Journal of Zhejiang University SCIENCE A*, 14(8), 589-602.

Behnia, D., Moeinossadat, S. R., Behnia, B., Behnia, M., Safari-Gorgi, A., Zakerian, P. (2014). Prediction of settlement in sloping core rockfill dams using soft-computing. *Research in Civil and Environmental Engineering (RCEE)*, 2(2), 55-65.

Boehm, S., Kutterer, H. (2006). Modeling the Deformations of a Lock by Means of Neuro-Fuzzy Techniques. U *XXIII international FIG Congress*. Munich: FIG. Dostupno na: [http://www.fig.net/resources/proceedings/fig\\_proceedings/fig2006/papers/ps06/ps06\\_03\\_boehm\\_kutterer\\_0597.pdf](http://www.fig.net/resources/proceedings/fig_proceedings/fig2006/papers/ps06/ps06_03_boehm_kutterer_0597.pdf)

Demirkaya, S. (2010). Deformation analysis of an arch dam using ANFIS. U A. Reiterer, U. Egly, M. Heinert, B. Riedel (ur.), *Second International Workshop on Application of Artificial Intelligence and Innovations in Engineering Geodesy* (pp. 21-31). Braunschweig. Dostupno na: <http://info.tuwien.ac.at/ingeo/sc4/wg423/AIEG2010.pdf>

Demirkaya, S., Balcilar, M. (2012). The contribution of soft computing techniques for the interpretation of dam deformation. U *FIG Working Week 2012 - Knowing to manage the territory, protect the environment, evaluate the cultural heritage*. Rome: FIG. Dostupno na: [https://www.fig.net/resources/proceedings/fig\\_proceedings/fig2012/papers/ts01f/TS01F\\_demirkaya\\_balcilar\\_5866.pdf](https://www.fig.net/resources/proceedings/fig_proceedings/fig2012/papers/ts01f/TS01F_demirkaya_balcilar_5866.pdf)

Elektroprojekt Zagreb (1963). Korištenje akumulacije Jablanica - Dopuna. Zagreb: Elektroprojekat Zagreb.

Haykin, S. (1999). *Neural networks - A comprehensive foundation, 2nd Edition*. Upper Saddle River, NJ: Prentice Hall

Heaton, J. (2008). *Introduction to neural networks with Java*. St Louis: Heaton Research, Inc.

Hu, W., Zhang, F., Song, L. (2011). Merging Model of Dam Deformation Analysis Based on Neural Network. U *Joint International Symposium on Deformation Monitoring*. Hong Kong: FIG, IAG. Dostupno na: <http://dma.lsgi.polyu.edu.hk/JISDM-Proceeding/Proceeding/Full%20paper/117.pdf>

Hu, D., Ran, L., Hou, H., Cheng, L., Li, T. (2017). Displacement Prediction Model of Earth-Rock Dam Based on Outlier-robust Extreme Learning Machine. U *2nd International Conference on Architectural Engineering and New Materials (ICAENM 2017)*. Lancaster: DEStech Publications, Inc. Dostupno na: <http://dpi-proceedings.com/index.php/dtetr/article/view/7844/7420>

Hyndman, R. J., Athanasopoulos, G. (2014). Forecasting: principles and practice. OTexts. Dostupno na: <https://www.otexts.org/fpp>

Jäger R., González F. (2006) GNSS/LPS Based Online Control and Alarm System (GOCA) - Mathematical Models and Technical Realization of a System for Natural and Geotechnical Deformation Monitoring and Hazard Prevention. U F. Sansò, A. J. Gil (ur.), *Geodetic Deformation Monitoring: From Geophysical to Engineering Roles, International Association of Geodesy Symposia, vol 131* (pp. 293-303). Berlin, Heidelberg: Springer.

Jäger, R., Hoscislawski, A., Oswald, M. (2009). GNSS/LPS/LS based Online Control and Alarm System (GOCA)-Mathematical Models and Technical Realization of a Scalable System for Natural and Geotechnical Deformation Monitoring and Analysis. U E. Bauer, S. Semprich, G. Zenz (ur.), *Proceedings of the 2nd International Conference "Long Term Behaviour of Dams"* (pp. 387-394). Graz: Technischen Universität Graz

Joghataie, A., Dizaji, M. S. (2009). Nonlinear analysis of concrete gravity dams by neural networks. U *Proceedings of the World Congress on Engineering (Vol. 2)* (6 p). London: International Association of Engineers.

Joghataie, A., Dizaji, M. S., Dizaji, F. S. (2012). Neural Network Software For Dam-Reservoir Foundation Interaction. U *Proceedings of the International Conference on Intelligent Computational Systems (ICICS'2012)* (pp. 129-133). Dubai: Planetary Scientific Research Centre

Kim, Y. S., Kim, B. T. (2008). Prediction of relative crest settlement of concrete-faced rockfill dams analyzed using an artificial neural network model. *Computers and Geotechnics*, 35(3), 313-322.

Ma, L. X., Wang, F. Y., Chen, J. P. (2009). Analysis & Prediction of Dam Deformation Based on ANN - An Example of Deformation at Monitoring Point 27 of Xijin Dam. *Journal of Jilin University (Earth Science Edition)*, 39(3): 486–491.

Majdi, A., Beiki, M. (2010). Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses. *International Journal of Rock Mechanics and Mining Sciences*, 47(2), 246-253.

McCulloch, W. S., Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of mathematical biology*, 5(4), 115-133.

Miao, X., Chu, J., Zhang, L., Qiao, J. (2013). An evolutionary neural network approach to simple prediction of dam deformation. *Journal Of Information & Computational Science*, 10(5), 1315-1324.