

Primljen / Received: 16.10.2025.

Ispravljen / Corrected: 15.5.2026.

Prihvaćen / Accepted: 30.6.2026.

Dostupno online / Available online: 10.9.2026.

Prognostički model radijalnih pomicanja betonskih lučnih brana

Autori:

Mr.sc. **Slobodan Blagojević**, dipl.ing.građ.

Sveučilište Crne Gore

Građevinski fakultet

slobodan.blagojevic93@gmail.com

Corresponding author

Doc.dr.sc. **Željka Beljkaš**, dipl.ing.građ.

Sveučilište Crne Gore

Građevinski fakultet

zeljka@ucg.ac.meProf.dr.sc. **Miloš Knežević**, dipl.ing.građ.

Sveučilište Crne Gore

Građevinski fakultet

milosknezevic@hotmail.com

Stručni rad

Slobodan Blagojević, Željka Beljkaš, Miloš Knežević

Prognostički model radijalnih pomicanja betonskih lučnih brana

U radu je razvijen prognostički model radijalnoga pomicanja betonske lučne brane na osnovi dugoročnih mjernih podataka. Model je utemeljen na umjetnim neuralnim mrežama, pri čemu su kao ulazne varijable upotrijebljeni kota akumulacije, temperatura i razina podzemnih voda. Podaci obuhvaćaju razdoblje od 48 godina eksploatacije brane "Piva". Model je implementiran u Python okruženju primjenom biblioteka TensorFlow i Keras. Točnost modela ocijenjena je s pomoću srednje apsolutne postotne pogreške (MAPE), pri čemu optimalni model (NMC 23) ostvaruje pogrešku od 8,34 % za skupu za učenje i 7,73 % za testni skup. Rezultati pokazuju da razvijeni model omogućava pouzdanu procjenu ponašanja konstrukcije te da je učinkovit alat za podršku sustavima monitoringa brana.

Ključne riječi:

oskultacije, radijalni pomak, neuralne mreže, prognostički model, betonske brane, monitoring brana, strojno učenje

Professional paper

Slobodan Blagojević, Željka Beljkaš, Miloš Knežević

Prognostic model of radial displacements of concrete arch dams

This paper presents a prognostic model for the radial displacement of a concrete arch dam based on long-term monitoring data. The model is developed using artificial neural networks (ANNs), with reservoir water level, air temperature, and groundwater level employed as input variables. The dataset covers 48 years of operational monitoring of the Piva Dam. The model was implemented in the Python environment using the TensorFlow and Keras libraries. Model performance was evaluated using the Mean Absolute Percentage Error (MAPE). The optimal model (ANN 23) achieved a MAPE of 8.34% for the training dataset and 7.73% for the testing dataset. The results demonstrate that the proposed model provides reliable predictions of the structural behaviour of the dam and represents an effective tool for supporting dam monitoring systems.


Key words:

monitoring, radial displacement, artificial neural networks, prognostic model, concrete arch dams, dam monitoring, machine learning


1. Uvod

Betonska lučna brana "Piva" je betonska, nesimetrična lučna brana dvojne zakrivljenosti. Građevinska je visina brane 220 m, te se ubraja u visoke brane i kao takva je prepoznata u svijetu. Pregrađivanjem rijeke Pive formirano je akumulacijsko jezero (Pivsko jezero), voda kojega se upotrebljava za proizvodnju vršne energije (električna energija po potrebi) u postrojenju HE "Piva". Betonska lučna brana "Piva" jedna je od najznačajnijih hidrotehničkih konstrukcija u regiji. Brana je završena 1976. godine nakon desetogodišnje izgradnje, kada je započelo prvo probno punjenje akumulacije. Formirano je akumulacijsko jezero obujma $824,5 \times 10^6 \text{ m}^3$ i površine $15,4 \text{ km}^2$ pri koti normalnog uspora od 675 m n.m. Brana se odlikuje nesimetričnim lučnim oblikom promjenljive debljine i složene geometrije, što znatno utječe na njezino ponašanje pod vanjskim opterećenjem. Takve konstrukcije zahtijevaju kontinuirani monitoring i razvoj pouzdanih modela za prognozu njihovoga ponašanja.

Debljina je brane promjenljiva, a mijenja se idući od temelja (gdje je najveća) prema kruni (gdje je najmanja). Pored debljine brane, promjenljiva je i zakrivljenost luka koji je nesimetričan. Intrados i ekstrados luka su dijelovi kružnica, dok je srednja linija, to jest os luka elipsa sastavljena od kružnih linija opisanih iz tri središta. Na mjestima gdje se te kružne linije sijeku dolazi do nesimetričnosti luka. Lijevi je bok kanjona strmiji od desnoga, a moduli deformacije stijenske mase nisu svuda isti. Posljedicu je toga da se brana na gornjem desnom boku oslanja preko sustava horizontalnih šipova na kvalitetniju stijensku masu koja načelno ima slične geotehničke karakteristike kao stijenska masa koja se nalazi na lijevome boku. Temeljne spojnice brane možemo definirati kao parabolične krivulje. S obzirom na to da je horizontalni presjek definiran na ovakav način, omogućeno je najpovoljnije uklapanje brane na profilu u ovisnosti o pružanju tektonskih linija, o čemu ovisi stabilnost brane u cjelini. Na slici 1. prikazan je razvijen profil brane, na kojem se uočavaju vertikalne lamele (ukupno 18) i horizontalne galerije (ukupno 5).



Slika 1. Skica razvijenog profila brane



Slika 2. Linearni numerički model brane (SAP2000)

Na slici 2. prikazane su karakteristične točke mjerenja koje su korištene kao ulazni podaci u treniranju neuralne mreže, kao i točka u središnjoj lameli (crvena točka) u kojoj se provodi predviđanje radijalnoga pomaka.

U središnjem dijelu, na kruni, nalaze se tri preljevna polja, koji se aktiviraju u slučaju prekomjernoga dotoka vode u akumulaciju. Njihove su dimenzije $13 \text{ m} \times 5 \text{ m}$, a nalaze se na koti 670 mnm. Brana je također sastavljena od 18 konzola i od 5 revizijskih galerija na kotama: 642, 602, 562, 522 i 482 mnm.

Ako se analizira ponašanje objekata ovakve vrste, može se uočiti da se pri djelovanju raznih opterećenja (hidrotehničko, gravitaciono, seizmicko) očekuju razni odzivi konstrukcije. Zadovoljavajućim odzivom konstrukcije smatra se ostajanje u zoni elastičnosti (linearno stanje). Ako pak govorimo o nezadovoljavajućem odzivu u kojem konstrukcija doživljava određena oštećenja, ali ne i slom, onda govorimo o plastičnosti (nelinearno stanje). Odziv konstrukcije u velikoj mjeri ovisi o interakciji konstrukcije, akumulacije i temelja (eng. *fluid-structure interaction* - FSI), pri čemu različiti pristupi modeliranju mogu dovesti do znatnih razlika u procijenjenim pomacima i naprezanjima [14].

Betonska lučna brana "Piva" sastoji od 18 konzola koje su međusobno neovisne jedna o drugoj. Prostor između konzola zapunjen je betonom visoke marke (međuspojnice) kako bi se spriječilo procurivanje vode zbog hidrotehničkoga pritiska koji zadaje vodeni stub akumulacije. Upravo na tim mjestima (zglobovima) predviđeni su spojevi koji omogućavaju redistribuciju naprezanja koja nastaju zbog različitih djelovanja na branu.

Dosadašnja istraživanja u području betonskih lučnih brana su prepoznata, ali ne i dovoljno istražena s obzirom na važnost teme. Veliki je broj autora analizu odziva brane na djelovanja opterećenja, temeljio na teorijskom pristupu oblikovanja prostornoga (3D) modela u nekom programskom

paketu, dok su, s druge strane, provođena i analize na temelju egzaktnih podataka.

Dinamičko je ponašanje betonskih brana u velikoj mjeri određeno njihovim vlastitim karakteristikama koje se opisuju vlastitim frekvencijama i oblicima osciliranja. Ti su parametri osnovu analize odziva konstrukcije, pri čemu je u inženjerskoj praksi često dovoljno razmatrati ograničen broj dominantnih modova koji imaju najveći utjecaj na globalno ponašanje sistema [15].

Grupa autora u norveškom gradu Norviku provela je analizu za procjenu sigurnosti brane pod djelovanjem projektnih opterećenja. Utvrđeno je da stupovi zadovoljavaju potrebnu nosivost, ali da većina ne zadovoljava potrebni faktor sigurnosti klizanja. Unatoč tome brana pokazuje malo znakova oštećenja, to jest vidljive su samo blage pukotine na određenim mjestima. Zbog toga su na kritičnim mjestima instalirani senzoripomoću kojih će se na temelju dugoročnoga mjerenja donositi odluke o budućem upravljanju branom [1]. Kod ponašanja hidrotehničkih objekata osim eksperimentalnih mjerenja i metoda umjetne inteligencije značajnu ulogu ima numeričko modeliranje utemeljeno na stvarnim hidrološkim i geometrijskim podacima. Primjena prostornih modela omogućava analizu složenih procesa i provjeru konzistentnosti između izmjerenih i proračunatih vrijednosti, čime se unapređuje razumijevanje ponašanja sistema i omogućava validacija rezultata dobivenih drugim metodama [13].

Suvremeni pristupi monitoringu brana sve češće uključuju primjenu naprednih metoda obrade podataka i umjetne inteligencije. Primjena prostornih metoda ispitivanja u kombinaciji s modelima neuralnih mreža omogućava kontinuirano praćenje stanja konstrukcije i identifikaciju potencijalnih oštećenja na temelju mjernih podataka. Takav pristup upućuje na to da je integracija mjernih podataka i inteligentnih modela učinkovit alat za analizu i prognozu ponašanja hidrotehničkih objekata [16].

Na devetnaestom simpoziju građevinskih inženjera koji je održan u Sjevernoj Makedoniji objavljen je rad u kojem se grupa autora bavila primjenom spregnute termotehničke analize brane pri statičkom opterećenju. Primjenom metode konačnih elemenata simuliran je prostorni (3D) numerički model. Simulirana su tri različita scenarija ponašanja koji su u ovisnosti o statičkom opterećenju (razina vode u akumulaciji i temperatura): visoka razina vode i mala temperatura (zabilježeni radijalni pomaci u nizvodnom smjeru od 25,4 mm), niska razina vode i visoka temperatura (zabilježeni radijalni pomaci u uzvodnom smjeru od 26,6 mm), visoka razina vode i visoka temperatura (zabilježeni pomaci prema desnoj obali na 20 % duljine grebena u uzvodnom smjeru od 19,3 mm) [2]. Vrijednosti su pomaka kod betonskih brana razmjerno male i najčešće se kreću u opsegu od nekoliko milimetara do nekoliko centimetara, što upućuje na veliku krutost konstrukcije i dominantno elastično ponašanje u radnim uvjetima.

U literaturi se može naći i studija procjene dinamičkoga ponašanja brane Ermenek, druge najveće brane u Turskoj. Studija je izvršena na temelju geodetskih mjerenja i analize

modela konačnih elemenata tijekom prvoga perioda punjenja. Ukupno se razmatralo osam perioda izmjerene deformacije sve do trenutka dok akumulacija nije dostigla puni kapacitet. Detaljno je ispitivan odziv brane na različite razine akumulacije i temperaturne varijacije. Ukupni pomaci na sredini brane pokazuju periodične i linearne trendove deformacije, što respektivno odgovara promjeni temperature i hidrostatičkog pritiska. Također je zaključeno da deformacije dobijene pomoću MKE i geodetskoga mjerenja koreliraju jedne s drugima [3].

Strukturno praćenje "zdravlja" i prognoze igraju ključnu ulogu u životnom ciklusu infrastrukturnoga objekta kao što je brana. Takav proces olakšava da se na temelju bolje informiranosti donose odluke o planiranju održavanja životnoga vijeka. Grupu autora sa Sveučilišta Concordia zainteresirala je studija slučaja brane koja doživljava sporo nepovratno uzvodno kretanje središnjega dijela. Primarni je cilj tog istraživanja da potvrdi i uspostavi razinu povjerenja u numeričko modeliranje uspoređivanjem pomaka koji se očitavaju na seizmičkim, hidrometeorološkim, geotehničkim i geodetskim instrumentima. Da bi se dobili rezultati napravljena je termomehanička analiza na 3D modelu rezervoarskoga s temelja brane. Pored toga studija se koristi poznatim statičkim modelom pod nazivom "Hydrostatic Season Time", koji je utemeljen na analizi višedimenzionalne regresije za predviđanje budućega pomaka brane koristeći se relevantnim podacima sa senzora postavljenih na brani. Dobiveni rezultati upućuju na dobru korelaciju između promatranog pomaka brane zasnovanoga na podacima s instrumenta i onoga izračunanoga primjenom analize konačnih elemenata uzimajući u obzir postojanje vertikalnih spojnica konzola brane. Štaviše, model "HST" blisko se poklapa s izmjerenim podacima na instrumentima i kao takav pokazuje dobre sposobnosti predviđanja za buduće ponašanje brane, kao i za izolaciju učinaka različitih parametara na pomake brane [4].

Korištenje raznih metoda prilikom predviđanja rezultata omogućava bolji pristup u vođenju eksploatacije betonskih brana. U dvadeset prvom stoljeću primat predviđanja koje garantira veliku tačnost jest umjetna inteligencija, posebno hibridni modeli zasnovani na neuralnim mrežama koji pokazuju veliku tačnost u modeliranju deformacija brana [10]. Primjenom umjetne inteligencije radi procjene troškova integralnih mostova bavili su se profesori Crnogorskoga Univerziteta. Od mnoštva modela koji su u znanstvenom radu napravljeni izabran je najbolji model neuralnih mreža koji je pokazao veliku tačnost pri procjeni troškova na temelju srednje apsolutne pogreške koja je iznosila 13,4 % [5].

2. Materijali i metode

U cilju praćenja spomenutih pomaka postavljen je unutar tijela brane velik broj električnih i mehaničkih instrumenata. S obzirom na to da su spomenuti instrumenti ugrađeni od trenutka početka eksploatacije brane, u otežanim uvjetima u kojima prevladava velika vlažnost kako u injekcijskim tako i u

uzdužnim galerijama, došlo se u situaciju da veliki broj električnih instrumenata nije u funkciji, dok su mehanički instrumenti u potpunoj funkcionalnosti. U mehaničke instrumente ubrajamo:

- visak (mjerenje radijalnih i tangencijalnih pomaka u lamelama 5, 9 i 14);
- deformetar (mjerenje radijalnih pomaka na mjestima spajanja konzola);
- dilatometar (mjerenja deformabilnosti stijenske mase na bokovima brane);
- klinomjere (mjerenja kuta rotacije tijela brane na mjestima vertikalnih kampađa).

U ovom radu bit će prikazana mjerenja viskom u centralnoj lameli brane (lamela broj 9). Razlog zbog kojega je izabrana ova lamela jest taj što su najveći pomaci javljaju upravo na spomenutoj lameli i to na samoj kruni brane.

Na slici 2. prikazan je linearni numerički model razvijen u programskom paketu SAP2000, koji je korišten kao referentni okvir za procjenu globalnoga ponašanja brane i usporedbu s rezultatima dobivenim na temelju mjernih podataka [15]. Model je oblikovan korištenjem plošnih (shell) elemenata, jer je fokus istraživanja bio na globalnim deformacijama i općem odzivu sistema, a ne na detaljnoj raspodjeli naprezanja kroz tijelo brane, zbog čega primjena volumnih (solid) elemenata nije bila neophodna. Primjena linearne analize podrazumijeva proporcionalan odnos između vanjskoga opterećenja i odziva konstrukcije, što je prihvatljivo pojednostavljenje u uvjetima radnoga režima i omogućava pouzdanu procjenu dominantnih parametara njezinog ponašanja [14]. U numeričkim analizama složenih konstrukcija, kao što su brane, rješavanje problema velikoga broja stupnjeva slobode zahtijeva određena pojednostavnjenja, pri čemu se uobičajeno izdvajaju dominantni oblici odziva koji imaju najveći utjecaj na globalno ponašanje sistema, dok ostali utjecaji imaju manji značaj [15].

Na taj je način omogućeno da se u rubnim linijama elemenata dobivaju vrijednosti utjecaja. Tako dobivene vrijednosti poklapaju se s izmjerenim vrijednostima na mehaničkim instrumentima unutar brane. Crvena točka prikazana u središnjoj lameli mjesto je na kojem će se dobiti predviđanje pomaka s pomoću neuralne mreže programskoga paketa *Python* u koji su prethodno uneseni izmjerene vrijednosti.



Slika 3. Deformetarsko mjesto na kruni brane (lamela 9) na kojem su provedena mjerenja korištena za neuralnu mrežu

Neuralna će mreža biti trenirana na razne varijable koje će biti unošene u kodu programskoga paketa *Python*. Korišteni pristup odgovara standardnoj praksi primjene MLP modela u problemima regresije deformacija konstrukcija. U tablici 1. prikazani su ulazni parametri sa svojim graničnim (minimalnim, maksimalnim) i srednjim graničnim vrijednostima.

Podaci koji će biti korišteni za formiranje matematičkoga modela trebaju biti međusobno uporedivi. Podaci korišteni u radu stvarni su mjerni podaci prikupljeni tijekom dugoročnoga monitoringa brane. Takav pristup omogućava povezivanje numeričkih i empirijskih modela, pri čemu se validacija vrši na temelju realnih mjerenja i njihovih međusobnih odnosa, što je u skladu sa savremenim metodologijama u hidrotehničkom inženjerstvu [13]. Sličan pristup primjenjuje se i u suvremenim istraživanjima u kojima se kombiniranjem mjernih sistema i naprednih metoda analize podataka omogućava pouzdanija procjena stanja konstrukcije. Integracija realnih mjerenja i modela umjetnih neuralnih mreža omogućava unapređenje točnosti prognoze i bolje razumijevanje ponašanja sustava [16]. S obzirom na to da su vrijednosti uzete iz baze podataka koja datira iz vremena prvih godina eksploatacije pa sve do ovoga trenutka, što je vremensko nesuglasje od 48 godina, izvršena je provjera i ustanovljeno je da vrijednosti prate jedna drugu. Međutim, treba obratiti pozornost na to da se podatak koji se uspoređuje uskladi s podatkom s kojim se uspoređuje za simetrično godišnje doba. Prema projektu praćenja ponašanja brane (iz čije arhive je uzeta baza podataka koji su korišteni za model) predviđena su sljedeća fizičko–telemetrijska mjerenja:

Tablica 1. Ulazni parametri s graničnim vrijednostima

Broj ulaznih promjenljivih parametara	Oznaka ulaznog podatka	Tip podatka	Jedinica mjere	Min	Max	Srednja vrijednost
Ulaz 1	KA	Numerički	m n.m.	641,8	674,76	662,3
Ulaz 2	T	Numerički	°C	-12,84	28,14	6,9
Ulaz 3	P	Numerički	cm	41,1	162,25	85,46
Ulazni parametri imaju različite mjerne jedinice, što dodatno naglašava potrebu za prilagodbom njihovim vrijednostima prije treniranja modela. KA – Kota akumulacije (m n.m.) T – Temperatura betona (°C) P – Pijezometri (nivo podzemnih voda lijeva i desna obala, cm)						

- mjerenje pomaka brane viskom;
- mjerenje rotacije pojedinih tačaka brane;
- mjerenje dilatacija u spojevima lamela brane;
- mjerenje deformacija temeljne stijene;
- mjerenje vodostaja;
- mjerenje temperature betona;
- mjerenje temperature zraka;
- mjerenje temperature vode;
- mjerenje lokalnih deformacija u betonu;
- razina podzemnih voda;
- mjerenje tlačnih naprezanja na temeljnoj spojnici;
- mjerenje veličine uzgona na temelj brane;
- mjerenje veličine pornoga tlaka u betonu;
- mjerenje relativnih horizontalnih pomaka točaka na kruni brane u lamelama 5, 9, 14 u glavnom radijalnom smjeru – alinjan [6].

U odnosu na sva spomenuta mjerenja koja se obavljaju prilikom redovnih oskultacija sljedeća su tri (kota akumulacije, temperature i razina podzemnih voda) najznačajnija, jer njihove promjene u najvećem postotku imaju za posljedicu širenje ili skupljanje dilatacijske spojnice u središnjoj lameli na kruni brani, a to je i razlog zašto su te izmjerene vrijednosti korištene za predviđanje pomaka primjenom neuralne mreže. Za treniranje neuralne mreže korišteni su isključivo izmjereni podaci radijalnih pomaka, dok numerički model u SAP2000 nije korišten za generiranje podataka, već kao pomoćni alat za interpretaciju globalnoga ponašanja konstrukcije. Utjecaji puzanja i skupljanja betona, kao i rezidualna naprezanja nastala tijekom procesa hidratacije cementa nisu u okviru ovoga istraživanja eksplicitno modelirani. Međutim, s obzirom na to da su korišteni dugoročni mjerni podaci koji obuhvaćaju razdoblje od 48 godina, navedeni su učinci implicitno sadržani u izmjerenim vrijednostima i time posredno uključeni u proces treniranja modela. Na taj način je njihov kumulativni utjecaj na deformacijsko ponašanje konstrukcije uzet u obzir povijesnim podacima, što omogućava realističniju aproksimaciju stvarnoga ponašanja brane [14].

Kota akumulacije visina je vodenoga stupca akumulacije izmjerenu u metrima. Vrijednosti kote akumulacije koje se nalaze u bazi podataka od trenutka eksploatacije, to jest od trenutka probnoga punjenja, mjere se svakodnevno i to četiri puta (na svakih 6 h). Podaci se mjere s pomoću vodomjerne letve koja je pripojena uz tijelo brane (uzvodnu strana). U lošim vremenskim uvjetima (magla, snijeg) i kada razina akumulacije nije dovoljno visokanije moguće s krune brane očitati vrijednost visine vodenog stupca, te u takvim uvjetima mjerenje razine akumulacije preuzima ritmajer (rittmeyer). Princip rada ritmajer,

temelji se na električnoj sondi na vrhu koje se nalazi plovak koji promjenom razine vode, po principu zakona spojenih posuda, šalje signal koje se obrađuje unutar "data logera", i tako obrađen šalje se putem električnoga signal prema desktopu računala gdje se očitava. Ako se promatra na godišnjoj razini, najveća vrijednost akumulacije događa se u proljetnom i u jesenjem dijelu godine, dok se najniže kote očekuju u ljetnjem dijelu godine.

Temperaturno je stanje unutar konstrukcije jako složeno iz jednostavnoga razloga što ovisi o mnogobrojnim parametrima, a glavni su: temperatura zraka i vode, temperatura stijene, godišnjega doba, insolacije, geometrijskih karakteristika konstrukcije, osobina materijala koji su ugrađeni. Temperaturni podaci koji su korišteni kao ulazni podaci vrijednosti su temperature betona na točno određenom mjestu i mjere se svakog dana. Samo mjerenje temperature masivnoga betona provodi se s pomoću električnih sondi koje su uronjene u beton i nalaze se na 70 cm od mjesta kontakta beton-voda prema unutrašnjosti tijela brane. Izlazni podatak tako izmjerene temperature je u Hz (hercima), koji se uz pomoć definiranoga matematičkog izraza pretvori u °C (celzijus). Toplinska analiza raspodjele temperature unutar tijela brane u ovom radu nije posebno provedena, jer je fokus istraživanja usmjeren na razvoj modela predviđanja zasnovanoga na izmjerenim podacima. Utjecaj temperature uključen je stvarnim mjerenjem temperaturnoga polja u konstrukciji, čime je njezin učinak posredno uzet u obzir u procesu treniranja neuralne mreže. S obzirom na cilj istraživanja, koji se odnosi na prognozu pomaka na temelju realnih mjerenja, dodatna numerička toplinska analiza nije bila od presudnoga značaja.

Razina podzemnih voda mjeri se u bušotinama kružnoga poprečnog presjeka uz pomoć instrumenta koji se zove razinomjer. Bušotine su smještene u galerijama (injekcijske zavjese) koje su usmjerene okomitona smjer luka brane i nalaze se na lijevoj i desnoj obali u duljini od 700 m unutar stijenke mase. Razinomjer se sastoji od valjka oko kojega je omotan kabel čija duljina može biti i do 200 m, a na njegovom se vrhu nalazi senzor koji šalje signal u trenutku ulaska u vodenu sredinu. Podzemne vode neposredno utječu na deformabilnost tla bočnih dijelova brane. Pojava likvifikacije u tim zonama može dovesti do gubitka stabilnosti temelja brane, a to dovodi do preraspodjele naprezanja unutar tijela brane, što nadalje ima za posljedicu pojave pukotna.

Nakon što se definirani ulazni parametri za model treba definirati i izlazne parametre modela. Na temelju razmatranoga istraživanja utvrđen je jedan izlaz iz modela, a to je radijalni pomak. Izlazna veličina sa svojom graničnom (minimalnom i

Tablica 2. Izlazna veličina s graničnim vrijednostima

Broj izlaznih promjenljivih veličina	Opis izlaznog podatka	Tip podatka	Jedinica mjere	Min	Max	Srednja vrijednost
Izlaz 1	RA	Numerički	cm	4,39	6,736	5,65
RA – Radijalni pomak						

maksimalnom) i srednjom vrijednošću prikazana je u tablici 2. [7, 8]. Postupak formiranja modela provođen je sistematično i sastoji se od određenog broja koraka, a za svaki od modela treba osigurati jednake uvjete.

3. Rezultati

Nakon što su definirane izlazne veličine, što je i svrha modela, određuju se ulazne veličine, a prilikom njihovoga određivanja treba voditi računa o njihovom značaju za izlaznu veličinu. U prvome redu o njima ovisi što mreža uči i koliko dobro generalizira nove podatke, to jest one su temelj na kojem se sve gradi. Njihov pravilan izbor, prilagodba vrijednostii obrada jednako su važni kao i oblikovanje same mreže.

Sljedeća faza prilikom definiranja modela obrada je podataka kako bi se svi podaci našli u određenom opsegu veličina. Omogućavanje dobivanja kvalitetnoga podatka vrši se prilagodbom vrijednosti (skaliranjem). Koliki će opseg prilagodbe vrijednosti ulaza i izlaza biti, ovisi o aktivacijskoj funkciji izlaznih veličina. Standardizacija i normalizacija takođe omogućavaju prilagođavanje vrijednosti podataka. Razlog zbog kojeg se provode sve ove metode jest svođenje podataka na isti red veličina. U ovom je radu izvršena prilagodba vrijednosti podataka na cijelom skupu izmjerenih vrijednosti, a metode koje su primijenjene su Standard Scaler i Min-Max Scaler. Skup podataka korišten u ovom radu obuhvaća kontinuirana mjerenja u periodu od 48 godina, pri čemu su podaci prikupljeni na dnevnoj razini. Prije treniranja modela izvršena je normalizacija i standardizacija ulaznih i izlaznih veličina primjenom StandardScaler i MinMaxScaler metoda. Prilagodba vrijednosti provedena je na cijelom skupu podataka kako bi se osigurala stabilnost i učinkovitost procesa treniranja neuralne mreže.

Nakon što je završena priprema podatka, dijelimo ih na dva skupa, i to na skup za učenje i testni skup. Prvi skup će se upotrijebiti za treniranje mreže, a drugi za njezinu provjeru. Kada biramo podatke koje ćemo upotrijebiti za testni skup, bitno nam je da su podaci kvalitetni za rješavanje određenoga problema. U literaturi koja se bavi ovom tematikom dane su preporuke mnogih autora koji su suglasni prilikom selekcije podatka u odnosu 90 % naprema 10 %, 80 % naprema 20 %, 85 % naprema 15 % ili 70 % naprema 30 % [9]. Također, ako specifičnost traženoga modela zahtijeva drugačiji postotak skupa za učenje i testnoga skupa primjenjuje se drukčija selekcija u odnosu na postotke koji su napisani u prethodnoj rečenici. U ovom radu podjela skupa za učenje u odnosu na testni skup izvršena je u odnosu 80 % naprema 20 %, 90 % naprema 10 % i 85 % naprema 15 % [10, 11]. Kalibracija modela izvršena je na skupu podataka za učenje, dok je validacija performansi provedena na odvojenom testnom skupu koji nije korišten u procesu treniranja, čime je osigurana objektivna procjena sposobnosti generalizacije modela. Podjela podataka izvršena je nasumično kako bi se izbjegla pristrasnost u učenju modela.

Svi modeli u ovom radu na temelju kojih je provedena prognoza

rezultata izrađeni su u programskom paketu *Python*. Model je implementiran korištenjem programskoga jezika *Python* uz primjenu biblioteka *TensorFlow* i *Keras*, koje su standardni alati za razvoj modela umjetnih neuralnih mreža [17, 18]. U svrhu procjene i dobivanja traženih rezultata upotrijebljen je višeslojni perceptron MLP. Kad su u pitanju aktivacijske funkcije u skrivenom sloju, korištene aktivacijske funkcije su: sigmoidalna (*logistic*), tangens hiperbolična (*tanh*), swish i relu (*ReLU*). Izlazni neuroni u su velikoj mjeri imali linearnu aktivacijsku funkciju. Na temelju prethodno rečenoga, a poznavajući broj podataka i njihove karakteristike, za oblikovanje modela upotrijebljene su razne kombinacije unutar samoga koda. Iz tih su kombinacija proizašla 44 prognostička modela. Osim aktivacijskih funkcija, skejlera (*scaler-a*), varijacija postotka testnoga skupa i skupa za učenje, variran je također i broj neurona u skrivenome sloju. U cilju dobivanja najboljeg modela, provedena je kalibracija odnosno treniranje modela [11, 12].


Radi jasnije usporedbe performansi različitih modela u tablici 3. prikazani su najbolji rezultati neuralnih mreža po grupama, u ovisnosti o primijenjenom postupku prilagodbe vrijednosti i aktivacijske funkcije.

Tablica 3. Najbolji rezultati modela umjetnih neuralnih mreža prema kriteriju MAPE [%]

Postupak prilagodbe vrijednosti	Aktivacijska funkcija	Broj neurona u skrivenom sloju	Učenje [%]	Test [%]
MinMaxScaler	ReLU	6	8,35	8,06
StandardScaler	ReLU	3	8,45	8,16
MinMaxScaler	Sigmoid	6	8,63	7,96
StandardScaler	Sigmoid	5	8,14	8,21
MinMaxScaler	Swish	3	8,60	8,12
StandardScaler	Swish	6	8,41	8,23
MinMaxScaler	Tanh	7	8,45	8,12


Za procjenu točnosti modela upotrijebljena je srednja apsolutna postotna pogreška (MAPE) jer omogućava intuitivnu interpretaciju rezultata u postocima i neovisna je o mjernoj jedinici. Ta je mjera posebno pogodna za analizu deformacija brana, gdje su vrijednosti pomaka razmjerno male, jer omogućava direktnu usporedbu odstupanja modela u odnosu na stvarne vrijednosti, bez utjecaja raspona vrijednosti promatranih veličina. Rezultati u Tbllici 3. prikazani su pomoću MAPE izražene u postocima (%), pri čemu niže vrijednosti upućuju na veću točnost modela. Kao referentna vrijednost za izbor optimalnoga modela uzeta je minimalna pogreška na testnom skupu, na temelju koje je izvršena procjena kvalitete modela. Detaljni rezultati svih analiziranih modela prikazani su u tablici 4. Sve neuronske mreže (NMCi, i = 1, 2, ..., 44) imaju tri ulazne veličine, jedan skriveni sloj i jednu izlaznu veličinu. Rezultati modeliranja upućuju na zadovoljavajuću razinu prediktivne

točnosti modela. Radi dodatne vizualne provjere izvršena je usporedba izmjerenih i modeliranih vrijednosti radijalnih pomaka. Kao što se može uočiti na slici 4., model uspješno prati osnovni trend promjena pomaka. Određena su odstupanja prisutna u ekstremnim vrijednostima, što je očekivano zbog složenoga utjecaja temperaturnih i hidrauličkih čimbenika koji nisu u potpunosti obuhvaćeni modelom. Prikazana je slika ilustrativni primjer ponašanja modela na jednoj mjernoj tački. Sličan obrazac poklapanja modeliranih i izmjerenih vrijednosti uočen je i na ostalim mjernim tačkama.



Slika 4. Usporedba izmjerenih i modeliranih radijalnih pomaka (R5 678)

Na slici 5. prikazana je tipična struktura korištene višeslojne perceptronske (MLP) neuralne mreže s tri ulazna neurona, jednim skrivenim slojem i jednim izlaznim neuronom, koja je nelinearni regresijski model sposoban da aproksimira složene funkcionalne odnose između ulaznih parametara i radijalnoga pomaka.



Slika 5. Tipična struktura višeslojne perceptronske (MLP) neuralne mreže (3-5-1 arhitektura)

Na temelju sumiranih rezultata koji su dani u tablici 4. uočava se da NMC 23 ima najveću točnost procjene određenu metodom postotka prosječne apsolutne pogreške. U modelu NMC 23 definirana su 3 sloja neurona od kojih su po jedan ulazni, skriveni (u kojem se nalazi 5 neurona) i izlazni sloj. Upravo je taj model izabran za konačni i na temelju njega određen je prognostički model za procjenu. Uočeni odnosi između ulaznih parametara i radijalnoga pomaka upućuju na dominantan utjecaj hidrostatsičkoga tlaka i temperaturnih varijacija. Ovakvi su nalazi u skladu s istraživanjima u kojima se

kombinacijom mjernih podataka i numeričkih modela identificiraju ključni mehanizmi deformacija [13], dok se utjecaj interakcije konstrukcije i fluida na odziv sistema potvrđuje i dinamičkim analizama brana. Primjena linearne analize u ovom radu prihvatljivo je pojednostavljenje koje omogućava jasno sagledavanje utjecaja dominantnih parametara na ponašanje konstrukcije [14].

Tablica 4. Pregled performansi svih analiziranih modela umjetnih neuralnih mreža (MLP)

Naziv modela	Karakteristike modela	Skup za učenje	Testni skup
NMC 1	MLP 3-3-1	8,50	8,04
NMC 2	MLP 3-4-1	8,50	8,17
NMC 3	MLP 3-5-1	8,49	8,13
NMC 4	MLP 3-6-1	8,35	8,06
NMC 5	MLP 3-7-1	8,40	7,97
NMC 6	MLP 3-3-1	8,45	8,16
NMC 7	MLP 3-4-1	8,45	8,16
NMC 8	MLP 3-5-1	8,47	8,31
NMC 9	MLP 3-6-1	8,44	8,15
NMC 10	MLP 3-7-1	8,28	8,33
NMC 11	MLP 3-3-1	8,59	8,24
NMC 12	MLP 3-4-1	8,56	8,12
NMC 13	MLP 3-5-1	8,60	8,25
NMC 14	MLP 3-6-1	8,63	7,96
NMC 15	MLP 3-7-1	8,53	8,17
NMC 16	MLP 3-3-1	8,43	8,11
NMC 17	MLP 3-4-1	8,40	8,07
NMC 18	MLP 3-5-1	8,14	8,21
NMC 19	MLP 3-6-1	8,19	8,10
NMC 20	MLP 3-7-1	8,21	8,11
NMC 21	MLP 3-5-1	8,17 (80%)	8,46 (20%)
NMC 22	MLP 3-5-1	8,63 (90%)	7,96 (10%)
NMC 23	MLP 3-5-1	8,34 (90%)	7,73 (10%)
NMC 24	MLP 3-3-1	8,60	8,12
NMC 25	MLP 3-4-1	8,57	8,14
NMC 26	MLP 3-5-1	8,56	8,21
NMC 27	MLP 3-6-1	8,65	8,16
NMC 28	MLP 3-7-1	8,58	8,15
NMC 29	MLP 3-3-1	8,58	8,15
NMC 30	MLP 3-4-1	8,58	8,28
NMC 31	MLP 3-5-1	8,52	8,38
NMC 32	MLP 3-6-1	8,41	8,23
NMC 33	MLP 3-7-1	8,41	8,13
NMC 34	MLP 3-3-1	8,65	8,12
NMC 35	MLP 3-4-1	8,61	8,14
NMC 36	MLP 3-5-1	8,61	8,12
NMC 37	MLP 3-6-1	8,57	8,16
NMC 38	MLP 3-7-1	8,45	8,12
NMC 39	MLP 3-3-1	8,50	7,74
NMC 40	MLP 3-4-1	8,28	8,10
NMC 41	MLP 3-5-1	8,63	7,96
NMC 42	MLP 3-6-1	8,39	8,22
NMC 43	MLP 3-7-1	8,22	8,03
NMC 44	MLP 3-5-1	8,67 (80%)	8,31 (20%)

Dobiveni rezultati pokazuju da se ponašanje konstrukcije može adekvatno opisati korištenjem ograničenoga broja dominantnih parametara, što je u skladu sa suvremenim pristupima u analizi brana u kojima se kompleksni sustavi reduciraju na ključne komponente koje određuju njihov odziv. Iako realno ponašanje konstrukcije može uključivati nelinearne učinke, linearni se modeli često primjenjuju u inženjerskoj praksi jer omogućavaju stabilnu i učinkovitu procjenu dominantnih karakteristika sustava [15].

Dobiveni rezultati potvrđuju da primjena inteligentnih algoritama omogućava unapređenje interpretacije mjernih podataka i identifikaciju ključnih stanja u konstrukciji, što je u skladu sa suvremenim istraživanjima koja pokazuju prednosti kombinacije mjernih tehnologija i metoda umjetne inteligencije u analizi brana [16].

Predikcija u ovom radu odnosi se na procjenu radijalnog pomaka promatrane točke na brani, a ne na procjenu globalne stabilnosti konstrukcije ili graničnih stanja sistema. Analiza osjetljivosti ulaznih parametara nije eksplicitno u ovom istraživanju provedena, što je jedno od ograničenja modela i potencijalni smjer daljih istraživanja. Zbog toga nije moguće precizno odrediti interval pouzdanosti rezultata, niti kvantificirati pojedinačni utjecaj ulaznih parametara na izlaznu veličinu, što može utjecati na interpretaciju dobivenih predikcija. Model se može smatrati empirijskim regresijskim modelom utemeljenom na mjernim podacima, čime se postiže ravnoteža između točnosti i interpretabilnosti u inženjerskoj praksi.

4. Zaključak

U radu su analizirani radijalni pomaci betonske lučne brane "Piva" na temelju dugoročnih mjernih podataka prikupljenih

tijekom 48 godina eksploatacije. Razvijen je prognostički model utemeljen na umjetnim neuralnim mrežama, pri čemu su kao ulazni parametri korišteni kota akumulacije, temperatura i razina podzemnih voda.

Rezultati istraživanja pokazuju da model može pouzdano aproksimirati ponašanje konstrukcije, pri čemu je kao optimalan izdvojen model NMC 23 s arhitekturom 3–5–1. Ostvarena točnost modela izražena MAPE-om iznosi 8,34 % za skup za učenje i 7,73 % za testni skup, što upućuje na dobru sposobnost generalizacije i primjenljivost modela u inženjerskoj praksi.

Primjena modela zasnovanih na stvarnim mjerenjima omogućava realističnu procjenu ponašanja konstrukcije, pri čemu su učinci dugoročnih procesa, poput puzanja i skupljanja betona, posredno uključeni povijesnim podacima. Dobiveni rezultati potvrđuju da je moguće koristiti se ograničenim brojem dominantnih parametara za opis složenoga ponašanja brane. Razvijeni model može se promatrati kao nelinearni regresijski model koji aproksimira funkcionalnu zavisnost između ulaznih parametara i radijalnoga pomaka.

Važno je istaknuti da analiza osjetljivosti ulaznih parametara nije provedena, što je ograničenje modela i smjer daljih istraživanja. Budući rad treba usmjeriti na kvantifikaciju utjecaja pojedinačnih parametara, kao i na proširenje modela na druge vrste pomaka i dodatne mjerne veličine.

Razvijeni model već nalazi primjenu u procesu modernizacije sustava monitoringa HE "Piva", gdje doprinosi unapređenju interpretacije mjernih podataka i donošenju pouzdanijih inženjerskih odluka.

LITERATURA

- [1] Popescu, C., Sas, G., Arnstsen, B.: Structural health monitoring of a buttress dam using digital image correlation, Proceedings of the ICOLD Symposium, 2019, <https://doi.org/10.1201/9780429319778-151>
- [2] Mitovski, S., Petkovski, L., Panovska, F.: Numerical analysis of concrete arch dam at static loading, Proceedings of the 19th International Symposium of MASE, Ohrid, 2022, <http://hdl.handle.net/20.500.12188/32177>
- [3] Yigit, C.O., Alcay, S., Ceylan, A.: Displacement response of a concrete arch dam to seasonal temperature fluctuations and reservoir level rise during the first filling period: Evidence from geodetic data, Engineering Structures, (2014), pp. 285–297, <https://doi.org/10.1016/j.engstruct.2014.05.012>
- [4] Sarkar, A., Patra, B., Ghodke, S.: Monitoring the deformation pattern of an instrumented concrete arch dam, International Journal of Structural Stability and Dynamics, (2019), <https://doi.org/10.12783/shm2023/36742>
- [5] Beljkaš, Ž., Knežević, M.: Procjena troškova za integralne mostove primjenom umjetne inteligencije, Građevinar, 73 (2021) 3, pp. 265–273, <https://doi.org/10.14256/JCE.2831.2019>
- [6] Xu, B., Chen, Z., Su, H., Zhang, H.: A deep learning method for predicting the displacement of concrete arch dams considering the effect of cracks, Advanced Engineering Informatics, 62 (2024), Paper No. 102574, <https://doi.org/10.1016/j.aei.2024.102574>
- [8] Cheng, L., Yang, J., Li, B.: The health monitoring method of concrete dams based on ambient vibration testing and kernel principal analysis, Mechanical Systems and Signal Processing, 2018, <https://doi.org/10.1016/j.ymssp.2017.11.032>
- [8] Wu, W., Su, H., Feng, Y., Zhang, S., Zheng, S., Cao, W., Liu, H.: A Novel Artificial Intelligence Prediction Process of Concrete Dam Deformation Based on a Stacking Model Fusion Method. Water, 16 (2024) 13, Paper No. 1868, <https://doi.org/10.3390/w16131868>
- [9] Xi, W., Yang, J., Song, J., Qu, X.: Deep learning model of concrete dam deformation prediction based on CNN, *IOP Conference Series: Earth and Environmental Science*, 580 (2020), Paper No. 012042. <https://doi.org/10.1088/1755-1315/580/1/012042>
- [10] Nourani, V., Kisi, O., Komasi, M.: Two hybrid Artificial Intelligence approaches for modeling dam deformation Journal of Hydrology, 2011, <https://doi.org/10.1016/j.jhydrol.2011.02.031>

- [11] Salazar, F., Toledo, M., Morán Moya, R., Oñate, E.: An empirical comparison of machine learning techniques for dam behaviour modelling, *Structural Safety*, 56 (2015), pp. 9–17, <https://doi.org/10.1016/j.strusafe.2016.11.001>
- [12] Mata, J., Tavares de Castro, A., Sã da Costa, J.: Constructing statistical models for arch dam deformation. *Struct. Control Health Monit.*, 21(2014), pp. 423–437, <https://doi.org/10.1002/stc.1575>
- [13] Stipičić, M., Budinski, L., Fabian, J.: Matematičko modeliranje tečenja i pronosa nanosa – primjer brane na rijeci Tisi, *Građevinar*, 73 (2021) 9, pp. 917–932, <https://doi.org/10.14256/JCE.2903.2020>
- [14] Altunisik, A.C., Sesli, H.: Effect of near-fault ground motion with pulse signal on dynamic response of dam–reservoir–foundation systems, *Građevinar*, 74 (2022) 12, pp. 1059–1083, <https://doi.org/10.14256/JCE.1573.2016>
- [15] Mircevska, V., Nastev, M., Hristovski, V., Bulajic, I.: Eigenvalue solution for arch dams: ADAD-IZIIS software, *Građevinar*, 70 (2018) 10, pp. 881–890, <https://doi.org/10.14256/JCE.1662.2016>
- [16] Zhao, Y., Wang, R., Gao, T., Guo, T., Guo, X.: Research on leakage hazards of embankments based on 3D electrical resistivity tomography technology, *Građevinar*, 76 (2024) 4, pp. 323–333, <https://doi.org/10.14256/JCE.3901>
- [17] Abadi, M., et al.: TensorFlow: Large-scale machine learning on heterogeneous systems, 2015, <https://www.tensorflow.org>
- [18] Chollet, F.: Deep Learning with Python, Manning Publications, 2017.

OTPORNIJA HRVATSKA POČINJE POUZDANIM PODACIMA: **CROSSNET** USPOSTAVLJA NOVU NACIONALNU MREŽU SEIZMOLOŠKIH POSTAJA



Financira
Europska unija
NextGenerationEU



Seizmološka služba Republike Hrvatske privodi kraju provedbu projekta CROSSNET - razvoj mreže seizmoloških podataka, jednog od najvažnijih ulaganja u seizmološku infrastrukturu u Hrvatskoj posljednjih desetljeća.



U sklopu projekta uspostavlja se nova nacionalna mreža od 95 seizmoloških postaja diljem Hrvatske. Njezina je uloga omogućiti preciznije praćenje seizmičke aktivnosti te kvalitetnije prikupljanje, obradu i primjenu seizmoloških podataka u područjima važnima za cijelo društvo.



Potresi su prirodna pojava koju nije moguće spriječiti. No, zahvaljujući pouzdanim i preciznim podacima, moguće ih je bolje razumjeti, kvalitetnije pratiti seizmičku aktivnost i stvarati pouzdanije podloge za donošenje važnih stručnih odluka. Upravo zato modernizacija seizmološke mreže predstavlja važan korak u jačanju otpornosti Hrvatske na potrese i povezane rizike.



Nova mreža omogućit će preciznije registriranje i lociranje potresa te prikupljanje kvalitetnijih podataka za znanstvena istraživanja, procjenu seizmičkog hazarda, prostorno planiranje, projektiranje i izgradnju objekata te praćenje javne infrastrukture.



Što su seizmološki podaci kvalitetniji, to su pouzdanije analize, procjene i planovi koji se na njima temelje. Njihova važnost zato ne završava u znanstvenim laboratorijima. Oni su važna podloga za planiranje prostora, gradnju i razvoj infrastrukture te dugoročno jačanje otpornosti zemlje.



Uspostavom nove nacionalne mreže Hrvatska dobiva suvremen sustav prikupljanja i obrade seizmoloških podataka usklađen s modernim tehnološkim i stručnim standardima. Riječ je o ulaganju u znanje, tehnologiju i infrastrukturu čije će koristi dugoročno osjećati znanstvena i stručna zajednica, nadležne institucije, ali i svi građani Republike Hrvatske.

Jer otpornija Hrvatska počinje pouzdanim podacima.
CROSSNET. Nova nacionalna mreža seizmoloških postaja.

Projekt sufinancira Europska unija - NextGenerationEU.

