

Primljeno / Received: 04.09.2020  
Prihvaćeno / Accepted: 22.10.2020.

UDK 528.482  
Originalni naučni rad / Original scientific paper

# MODELIRANJE POMJERANJA BRANE PRIMJENOM VIŠESTRUKA LINEARNE REGRESIJE I ARIMA MODELA

## DAM MOVEMENT MODELING BY USING MULTIPLE LINEAR REGRESSION AND ARIMA MODELS

*Adis Hamzić, Dina Kamber Hamzić*

### SAŽETAK

*Monitoring deformacija velikih građevinskih objekata (visoke zgrade, mostovi, tuneli, brane, itd.) je zadatak građevinskih i geodetskih inženjera koji u tu svrhu koriste različite metode i instrumente. Na pomjeranje brane utiču brojni faktori među kojima su najznačajniji: promjene temperature, hidrostatski pritisak i starenje brane. U okviru ovog istraživanja ispitan je uticaj termalnih varijacija na pomjeranje krune brane primjenom statističkih metoda: autoregresivnih integrisanih pomičnih sredina (ARIMA) i višestruke linearne regresije. Podaci pomjeranja brane su dobijeni primjenom optičkog aliniranja na betonskoj gravitacionoj brani HE Salakovac. U prvom dijelu istraživanja određen je stepen korelacije između temperature betona na brani i pomaka, drugi dio istraživanja se bavi kratkoročnom predikcijom temperature betona, a posljednji dio istraživanja koristi prethodno podešene modele za predikciju pomaka brane. Rezultati su pokazali da predloženi model na bazi statističkih metoda daje kvalitetne predikcije pomaka krune brane.*

**Ključne riječi:** *monitoring, brana, deformacije, višestruka linearna regresija, ARIMA, predikcija, aliniranje.*

### ABSTRACT

*Structural health monitoring of the large infrastructural objects (high buildings, bridges, tunnels, dams, etc.) is in the domain of civil and geodetic engineers who use different methods and instruments for this task. Dam movement is influenced by various factors among which the most important are: thermal variations, hydrostatic pressure and dam ageing. This research investigates influence of thermal variations on dam crest movement by using statistical methods: autoregressive integrated moving average (ARIMA) and multiple linear regression. Dam crest movement data is obtained by using optical alignment method on the concrete gravity dam HP Salakovac. In the first part of this research correlation between dam crest movement and concrete temperature is determined, the second part deals with short term concrete temperature prediction and in the final part of this research previously fitted statistical models are used for dam movement prediction. The results showed that proposed model based on statistical methods can provide quality prediction of dam crest movement.*

**Keywords:** *monitoring, dam, deformations, multiple linear regression, ARIMA, prediction, alignment.*

## 1 UVOD

Redovan i kvalitetan monitoring brana je od ključnog značaja za utvrđivanje sigurnosti brane. Važno je istaći da bez obzira na poštivanje svih standarda i propisa prilikom projektovanja brana i samog kvaliteta izgradnje ne postoji brana koja je apsolutno sigurna od oštećenja ili čak eventualnog rušenja. Zbog svog velikog značaja za privredu i društvo u cjelini brane se redovno osmatraju, a glavnu ulogu u monitoringu imaju građevinski i geodetski inženjeri. Iako imaju isti cilj prilikom monitoringa, metode i instrumenti koji se koriste se značajno razlikuju. Građevinski inženjeri obično koriste fizikalne metode osmatranja pri čemu se služe deformetrima, klinometrima, viskovima i drugim instrumentima koji imaju jednu zajedničku osobinu, a to je da daju podatke o lokalizovanim pomacima ili rotacijama dijelova brane. S druge strane, geodetske metode daju globalnu sliku ponašanja brane i pratećih objekata (strojara, pristupni putevi, potporni zidovi, tuneli za ispuštanje vode, i sl.) zajedno sa okolnim terenom. Mjerenja dobijena geodetskim i fizikalnim metodama se kombinuju kako bi se prilikom interpretacije rezultata dobila što bolja slika o stanju u kome se nalazi objekat.

Lombardi (2004) navodi da monitoring i interpretacija rezultata monitoringa brana treba dati odgovore na sljedeća pitanja:

- Da li je u ovome trenutku brana sigurna za korištenje?
- Da li će brana biti sigurna za korištenje u budućnosti?
- Da li se brana ponaša kao što je predviđeno?
- Da li se brana ponaša kao što se ponašala u prošlosti?
- Postoje li trendovi koji mogu ugroziti sigurnost brane u budućnosti?
- Da li su evidentirane ikakve anomalije u ponašanju brane?

Da bi se dali odgovori na ova pitanja potrebno je vršiti redovan monitoring, ali i napraviti modele za predikciju ponašanja brane na osnovu postojećih mjerenja i znanja. Za modeliranje ponašanja brana obično se koriste statistički modeli, a u novije vrijeme sve češće i modeli bazirani na mašinskom učenju i vještačkoj inteligenciji. Ovi modeli se obično integrišu u sisteme monitoringa, ali nije neuobičajeno i da se prave nezavisno od ovih sistema. Predikcija pomaka brane je aktuelna tema među istraživačima i postoji veliki broj objavljenih radova na ovu temu, a u nastavku su predstavljeni samo neki, autorima dostupni, radovi.

Kang, Liu, Li i Li (2017) su ispitali mogućnost predikcije pomaka brane primjenom ekstremne učeće mašine (eng. *extreme learning machine* - ELM). Rezultati istraživanja su pokazali da je predloženi pristup jednostavan za korištenje, daje precizne predikcije pomaka, a samo treniranje neuronskih mreža nije vremenski zahtjevno.

Pristup koji kombinuje autoregresivne integrisane pomične sredine (eng. *autoregressive integrated moving average* – ARIMA) i ćelije sa dugoročnom memorijom (eng. *long short-term memory* – LSTM) su primijenili Xu, Jing, Mao i Su (2020) u istraživanju na Manwan brani. ARIMA model je vršio predikciju linearnih komponenti, a LSTM predikciju nelinearnih komponenti. Rezultati su poređeni sa tradicionalnim modelima i pokazano je da predloženi pristup ima manje srednje kvadratne greške predikcije pomaka brane.

Model višestruke linearne regresije, sezonski ARIMA model i model baziran na vještačkim neuronskim mrežama su korišteni za analizu i predikciju horizontalnih pomaka Hoa Binh brane. Istraživanje su uradili Zou, Bui, Xiao i Doan (2018), a zaključak istraživanja je bio da sve tri korištene metode mogu dati kratkoročne predikcije koje kvalitetno opisuju ponašanje brane.

Hamzić, Avdagić i Bešić (2020) koriste kaskadnu predikciju uticajnih faktora za kratkoročnu predikciju pomaka betonske lučne gravitacione brane. Za predikciju uticajnih faktora su korišteni ARIMA modeli i nelinearne autoregresivne neuronske mreže, a za predikciju pomaka klasične neuronske mreže i višestruka linearna regresija. Rezultati istraživanja su pokazali da je kvalitetnom predikcijom vrijednosti faktora koji utiču na pomjeranje brane (nivo vode, temperatura zraka, vode i betona) moguće napraviti i kvalitetnu predikciju horizontalnih pomaka brane.

Hibridni model za predikciju pomaka brane baziran na genetičkom algoritmu i vještačkim neuronskim mrežama su koristili Wang, Yang i Shen (2017). Ovo istraživanje je pokazalo da predloženi hibridni model daje bolje rezultate u smislu preciznosti i brzine konvergencije neuronskih mreža u odnosu na klasične vještačke neuronske mreže i regresione modele.

Dakle, za interpretaciju ponašanja brane moguće je kreirati modele koji neposredno nakon izvršenih mjerenja daju odgovore da li se brana ponaša u skladu sa trenutnim operativnim stanjem (Amberg, 2009). Na ponašanje brane utiču mnogi faktori među kojima su neki koje je jako teško modelirati (npr. zemljotresi) dok drugi imaju jako mali uticaj (pritisak leda, snijeg, mraz) i njihovim uključivanjem u model dobio bi se izuzetno kompleksan model, a sam kvalitet modela ne bi bio značajno bolji. Iz navedenih razloga potrebno je napraviti kvalitetnu identifikaciju faktora koji značajno utiču na pomjeranje brane u konkretnom slučaju kako bi kreirani model bio što jednostavniji, a u isto vrijeme mogao dati i kvalitetnu predikciju ponašanja brane.

Tri faktora koja imaju najznačajniji uticaj na pomake kod betonske gravitacione brane su: starenje betona brane, temperaturne varijacije i hidrostatski pritisak. Naravno, zavisno od konkretnog slučaja objekta za koji se pravi model predikcije pomaka, ali i vremenskog perioda za koji se vrši predikcija zavisi koliki je uticaj svakog pojedinog faktora. U okviru ovog istraživanja fokus je na modeliranju pomaka brane na osnovu temperaturnih varijacija. Kao najvažniji faktor pomaka blokova brane identifikovana je temperatura betona brane. Obzirom da se model predikcije pravi za kratkoročnu predikciju (30 dana unaprijed) faktor starenja betona brane bi imao izuzetno malu vrijednost koja je beznačajna u konkretnom slučaju. Opštepoznato je da se hidrostatski pritisak linearno povećava sa dubinom pri čemu najveći pritisak podnosi donji dio brane, a najmanji gornji dio brane. Obzirom da su u konkretnom slučaju male promjene nivoa vode u odnosu na visinu brane hidrostatski pritisak će se smatrati konstantnim u ovom istraživanju.

U ovom radu korišteni su podaci sa betonske gravitacione brane HE Salakovac. Pomaci krune brane su mjereni metodom optičkog aliniranja, a temperatura brane automatskim sensorima koji su raspoređeni na više lokacija u tijelu brane. Za predikciju vremenskih serija mjerenja temperatura betona brane korišten je ARIMA model uz primjenu Box-Jenkins metodologije za odabir modela za predikciju. Višestruka linearna regresija (eng. *multiple linear regression* –VLR) je primijenjena da se ustanovi korelacija između temperature betona brane u tri nivoa (injekciona galerija, kontrolna galerija i kruna brane) i pomaka krune brane. Kompletan obrada podataka je urađena primjenom MATLAB i MS Excel programskih paketa.

## 2 PODACI I METODE

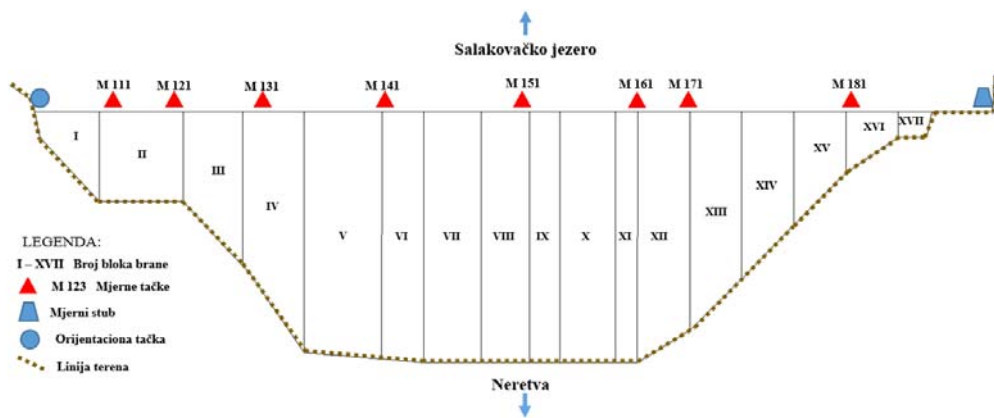
Istraživanje predstavljeno u radu je provedeno na brani HE Salakovac koja je izgrađena 1982. godine na rijeci Neretvi oko 15 km sjeverno od Mostara. Osnovni podaci brane HE Salakovac su prikazani u Tabeli 1, a uzdužni presjek brane na Slici 1 (STRABAG AG, 2012).

U okviru istraživanja korišteni su podaci o temperaturi betona brane i mjerenja pomaka krune brane dobijena metodom aliniranja. Senzori za mjerenje temperature betona brane su postavljeni u tri vertikalna i tri horizontalna nivoa u blokovima VI, VIII i XIII (Slika 1). Senzori su instalirani u zidove brane u nivou injezione galerije, kontrolne galerije i na kruni brane. U horizontalnom smislu senzori su raspoređeni sa uzvodne strane, nizvodne strane i u sredini brane. Senzori vrše konstantna mjerenja i podaci se šalju na server koji bilježi satne temperature u obliku vremenskih serija.

Tabela 1

Osnovne tehničke karakteristike HE Salakovac

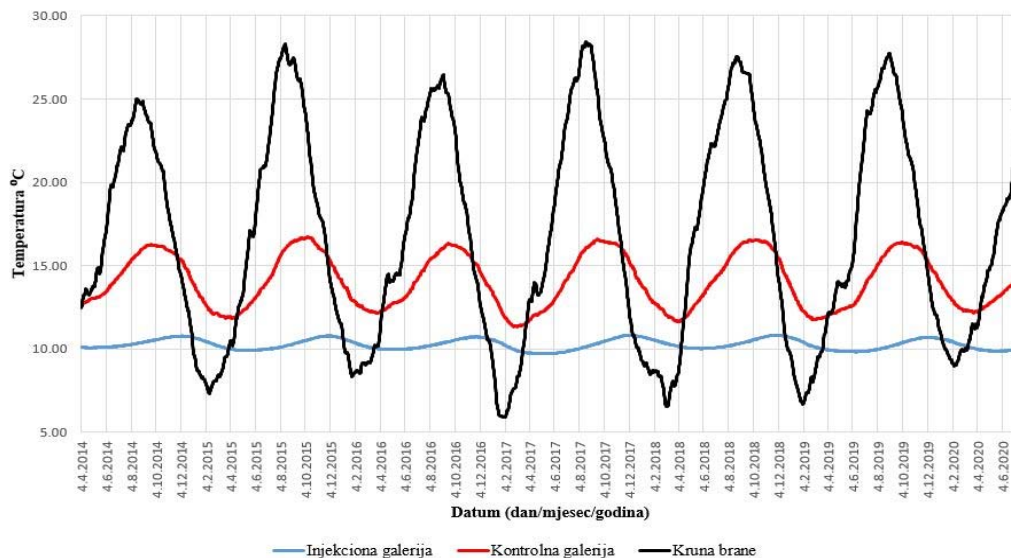
Osobina	Vrijednost
Tip	Betonska gravitaciona
Gradevinska visina	70,00 m
Geodetska visina	52,00 m
Dužina u kruni brane	230,50 m
Kota krune brane	127,00 m.n.m.
Kota maksimalnog nivoa akumulacije	124,70 m.n.m.
Kota normalnog nivoa akumulacije	123,00 m.n.m.
Kota minimalnog radnog nivoa	118,50 m.n.m.
Broj blokova	17
Dužina blokova	Od 6,00 m do 22,50 m
Dužina zone plavljenja u slučaju rušenja	cca 85 km



Slika 1. Uzdužni presjek brane HE Salakovac i geodetska mreža za osmatranje brane metodom aliniranja

Svim podacima osmatranja brane, uključujući mjerene temperature betona i pomake brane, se pristupa kroz softverski paket ARGUS koji nudi mogućnost pregleda, analize i vizuelizacije mjerenih i sračunatih vrijednosti svih faktora koji utiču na ponašanje brane. Na Slici 2 su prikazane srednje dnevne temperature izmjerene u bloku VIII brane HE Salakovac u periodu od 04.04.2014. do 15.07.2020. godine. Analizom grafikona sa Slike 2 evidentno je da se spuštanjem prema temelju brane amplituda mjerene temperature betona smanjuje i da postoji zakašnjela reakcija promjene temperature. Dodatno, jasno su vidljivi sezonski trendovi i sezonalnost što je veoma važno za odabir metode za predikciju temperature betona.

Rezo, Šugar, Težak i Zidar (2007) definišu aliniranje kao opažanja kojima se očitavaju horizontalni pomaci u odnosu na zadani pravac. Mjerenje se vrši tako što se mjerni instrument postavi na stub iz mikrotriangulacijske mreže koji se nalazi na jednoj obali, navizira se na orijentacionu tačku koja je stabilizovana na drugoj obali, a zatim se na kontrolne tačke postavlja mjerna markica sa mikrometrom pomoću kojeg se mjeri odstupanje od pravca definisanog mjernim stubom i orijentacionom tačkom.



Slika 2. Srednje dnevne temperature betona u bloku VIII mjerene od 04.04.2014. do 15.07.2020.

Alinijator, alineator ili optički kolimator su nazivi koji se u praksi koriste, a odnose se na geodetski instrument koji se koristi prilikom aliniranja. Ovaj instrument ima izuzetno veliko uvećanje, osjetljivu libelu, a za razliku od totalnih stanica nema limb jer se mjerenja pomaka vrše na mjernoj markici. Za aliniranje se mogu koristiti i totalne stanice mada je rijedak slučaj da se koriste kod geometrijskog aliniranja. Nekada se umjesto geometrijskog aliniranja radi trigonometrijsko aliniranje, što je u osnovi polarna metoda određivanja koordinata tačaka i tada se koriste precizne totalne stanice za mjerenje. Na Slici 3 je prikazan instrumentarij koji se koristi za mjerenje pomaka metodom optičkog aliniranja.



Slika 3. Mjerni instrument (alinjator), stabilizacija kontrolne tačke i mjerna markica

Kontrolne tačke su stabilizovane u betonu na kruni brane, a baza na koju se postavlja mjerna markica ima dvostruku zaštitu: poklopac koji pokriva cijelu bazu i posebne zaštitne navoje koji se postavljaju na tri oslonačke tačke baze. Nakon postavljanja mjerne markice na bazu, korištenjem vijka za fino pomjeranje markica se dovodi u pravac. Važno je da se prilikom mjerenja fino pomjeranje uvijek vrši u istom smjeru da ne bi došlo do mrtvog hoda vijka.

U istraživanju su korištene ukupno 74 serije mjerenja pomaka krune brane, od čega su 62 serije korištene za podešavanje modela, a 12 serija za validaciju modela. Serije mjerenja koje su korištene u istraživanju su urađene u periodu od 04.04.2014. do 17.06.2019., a validacione serije u periodu od 16.07.2019. do 15.07.2020. godine. Mjerne tačke M111 i M121 nisu uključene u istraživanje obzirom da se nalaze daleko od senzora za mjerenje temperature betona koji su postavljeni u blokovima VI, VIII i XIII (Slika 1).

Za predikciju temperature betona korištena je metoda autoregresivnih integriranih pomičnih sredina (ARIMA), a za izradu modela predikcije pomaka metod višestruke linearne regresije (VLR). ARIMA model je jedan od najpopularnijih pristupa za predikciju vremenskih serija u mnogim oblastima (ekonomija, inženjstvo, vremenska prognoza). ARIMA model koristi linearnu kombinaciju prethodnih vrijednosti i prethodnih grešaka varijable za određivanje budućih vrijednosti te varijable (Anderson, 1977). Generalni oblik ARIMA modela je predstavljen jednačinom (1):

$$y'_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t. \quad (1)$$

U jednačini (1)  $y'_t$  je stacionarni stohastički proces,  $c$  je konstanta,  $\phi_i$  ( $i = 1, \dots, p$ ) je autoregresivni koeficijent,  $\theta_k$  ( $k = 1, \dots, q$ ) je koeficijent pomičnih sredina, a  $\varepsilon_t$  je greška. Ovaj model se obično označava kao ARIMA ( $p, d, q$ ) model gdje je  $p$  red autoregresivnog dijela,  $d$  je stepen diferenciranja, a  $q$  je red pomičnih sredina.

Da bi se mogla vršiti predikcija vremenskih serija ARIMA metodom potrebno je da serija bude stacionarna. Hyndman i Athanasopoulos (2018) definišu stacionarnost na sljedeći način: „Stacionarna vremenska serija je ona čije osobine ne zavise od vremena u kojem je serija opažana“. Dakle, ako vremenska serija ima trendove ili ako ima izraženu sezonalnost takva serija

nije stacionarna. Za potrebe ovog istraživanja neće se ulaziti dublje u definicije stacionarnosti niti će biti analizirani specifični slučajevi već ćemo se zadržati na prethodnoj jednostavnoj definiciji stacionarnosti. Često vremenske serije opažanja nisu stacionarne i kao takve ne mogu se koristiti za predikciju ARIMA metodom. Da bi nestacionarna serija postala stacionarna potrebno ju je diferencirati jedan ili više puta. Diferenciranje u ovom smislu nije ništa drugo nego razlika između dva uzastopna opažanja kao što je prikazano u jednačini (2), dakle:

$$y_{dif} = y_t - y_{t-1}. \quad (2)$$

U jednačini (2)  $y_{dif}$  je diferencirana vremenska serija opažanja,  $y_t$  je opažanje u momentu  $t$ , a  $y_{t-1}$  je opažanje u prethodnom vremenskom trenutku opažanja.

Box i Jenkins (1970) su uveli i metodologiju za identifikaciju, podešavanje i korištenje ARIMA modela za predikciju vremenskih serija. Ova metodologija se odnosi na iterativnu primjenu tri koraka: identifikacija, procjena i provjera dijagnostike modela. Ovaj proces se ponavlja sve dok se ne dođe do toga da je model nemoguće unaprijediti. Eksperti koji se bave analizom vremenskih serija na osnovu stručnog znanja i iskustva mogu odrediti koji model treba koristiti za predikciju. Oni analizom autokorelacijskih i parcijalnih autokorelacijskih grafova vremenske serije određuju uži skup modela koji se testira i kasnije koristi za predikciju. U ovom istraživanju bit će testirano više različitih modela, a zatim će se primjenom statističkih metoda i alata utvrditi koji model od testiranih je najbolji za predikciju.

Jedan od najčešće korištenih testova za ispitivanje stacionarnosti vremenske serije je Dickey-Fuller test (Dickey i Fuller, 1979) koji za nultu hipotezu uzima da serija ima jedinični korijen što je čini nestacionarnom. Uzme li se najjednostavniji primjer autoregresivnog modela iz jednačine (1), tj.  $y'_t = \phi y'_{t-1} + \varepsilon_t$  tada model ima jedinični korijen ako je  $\phi = 1$ , dakle u ovom slučaju model je nestacionaran. Osim klasične verzije Dickey-Fuller testa koristi se i prošireni Dickey-Fuller test kojeg su razvili isti autori 1984. godine. Prošireni test je sposoban da identifikuje stacionarnost i kod kompleksnih i dinamičkih struktura podataka koji se ne mogu opisati jednostavnim autoregresivnim modelom. Ovaj test je korišten u okviru istraživanja kako bi se utvrdila stacionarnost vremenskih serija mjerenih temperatura brane. Važan faktor prilikom vršenja testa je broj kašnjenja koji će biti korišten u testu. Broj kašnjenja prilikom testiranja je određen prema jednačini koju je definisao Schwert (1989):

$$k = 12 * \left( \frac{T}{100} \right)^{\frac{1}{4}}, \quad (3)$$

gdje  $k$  označava broj kašnjenja, a  $T$  broj mjerenja u seriji.

Nakon što se ustanovi da je serija stacionarna vrši se testiranje različitih ARIMA modela. Za ispitivanje kvaliteta modela korišten je Ljung-Box test (Ljung i Box, 1978) koji ispituje da li korišteni podaci odgovoraju modelu,  $H_0$  – reziduali su nezavisno raspoređeni. Ako su reziduali nezavisni, odabrani model je dobar za predikciju. Ljung-Box test je baziran na statistici:

$$Q = T(T + 2) \sum_{h=1}^m \frac{r_h^2}{(T - h)}. \quad (4)$$

U jednačini (4)  $T$  je dužina vremenske serije,  $r_h$  je  $h$ -ti autokorelacijski koeficijent reziduala, a  $m$  je broj kašnjenja u testu. Tsay (2005) preporučuje da se za broj kašnjenja koristi sljedeća jednačina:

$$m \approx \ln(T). \quad (5)$$

Test će odbiti nultu hipotezu ako je:

$$Q > \chi_{1-\alpha, m-(p+q)}^2. \quad (6)$$

U jednačini (6)  $\chi_{1-\alpha, m-(p+q)}^2$  je vrijednost iz tabele Chi-kvadrat distribucije za  $m - (p + q)$  stepeni slobode i stepen značajnosti  $\alpha$ , pri čemu su  $p$  i  $q$  broj parametara ARIMA ( $p, d, q$ ) modela koji se koristi.

Za odabir najboljeg modela među testiranim korišten je Akaike informacioni kriterij koji je definisan jednačinom:

$$AIC = -2\ln(L) + 2p. \quad (7)$$

U jednačini (7)  $L$  označava funkciju maksimalne vjerovatnoće, a  $p$  je broj procijenjenih parametara.

Akaike informacioni kriterij pokušava pronaći najbolju ravnotežu između broja parametara u modelu i kvaliteta uklapanja podataka u model, tj. pokušava odabrati model koji najbolje opisuje stvarnost – što je vrijednost ovog kriterija niža to model bolje opisuje stvarnost (Reddy, Ganesh, Venkateswaran i Reddy, 2017). Dodatni kriterij koji je imao ulogu prilikom odabira najboljeg modela je kriterij „jednostavnosti“ – ako dva ili više modela imaju približno istu vrijednost Akaike informacionog kriterija za predikciju se koristi jednostavniji model.

Regresiona analiza je statistička metoda za predikciju vrijednosti zavisne varijable (ciljna varijabla) na osnovu vrijednosti jedne ili više nezavisnih varijabli (prediktora). Također se može koristiti za procjenu uticaja nezavisnih varijabli na zavisnu varijablu. Ako se za predikciju zavisne varijable koristi samo jedna nezavisna varijabla tada se radi o jednostavnoj linearnoj regresiji, a ako se zavisna varijabla predviđa na osnovu dvije ili više nezavisnih varijabli tada se radi o višestrukoj linearnoj regresiji (Johnson i Wichern, 2002). U okviru ovog istraživanja korištena je višestruka linearna regresija za analizu uticaja temperature betona brane na pomjeranje krune brane i zatim za predikciju pomaka brane na osnovu predviđenih vrijednosti temperatura betona u injekcionoj galeriji, kontrolnoj galeriji i na kruni brane.

Model višestruke linearne regresije ima sljedeći oblik (Rencher i Schaalje, 2008):

$$y_t = \beta_0 + \beta_1 x_{1,t} + \beta_2 x_{2,t} + \dots + \beta_k x_{k,t} + \epsilon_t. \quad (8)$$



U jednačini (8)  $x_1, \dots, x_k$  su nezavisne varijable, a  $\beta$  koeficijenti mjere uticaja svake nezavisne varijable nakon uzimanja u obzir uticaja ostalih nezavisnih varijabli u modelu.

Za određivanje prediktivne snage modela korišten je višestruki korelacijski koeficijent  $R$  koji je definisan jednačinom:

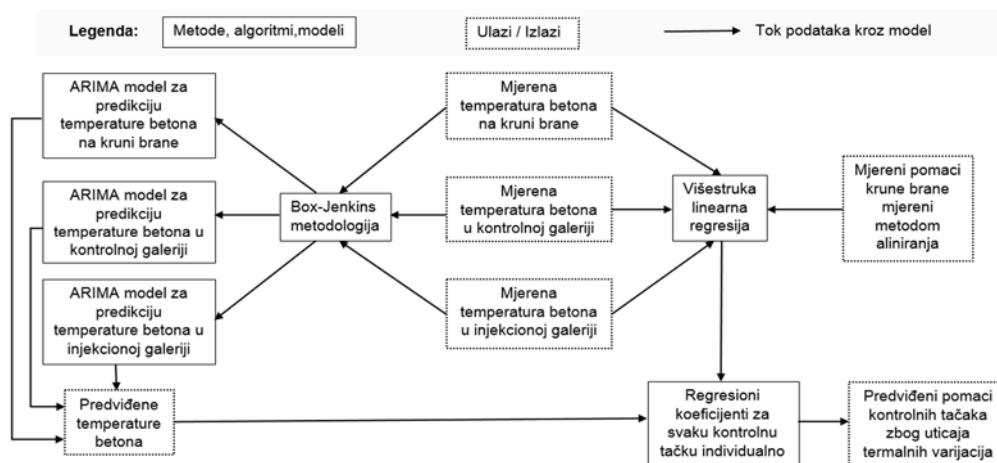
$$R = \sqrt{1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (9)$$

gdje je  $Y$  mjerena varijabla,  $\hat{Y}$  je procjenjena vrijednost, a  $\bar{Y}$  srednja vrijednost od  $Y$ .

Višestruki korelacijski koeficijent  $R$  se može smatrati kvadratnim korijenom odnosa varijacije u procijenjenoj vrijednosti  $\hat{Y}$  (varijacija objašnjena modelom) i varijacije varijable  $Y$ . Ako model daje dobre procjene  $Y_i$  (procjene bez disperzije), tada će vrijednost koeficijenta  $R$  biti blizu 1. Zbog toga koeficijent  $R$  smatramo razumnom mjerom prediktivne snage (Takahashi i Kurosawa, 2016).

### 3 MODELIRANJE SISTEMA PREDIKCIJE POMJERANJA BRANE ZBOG TERMALNIH VARIJACIJA

Na Slici 4 je prikazan model sistema za predikciju pomaka brane na osnovu predviđenih vrijednosti temperature betona brane u tri nivoa: injkciona galerija, kontrolna galerija i krana brane.



Slika 4. Model predikcije pomjeranja brane pod uticajem termalnih varijacija

Prvo se na osnovu mjerenih vrijednosti temperature i pomaka kreiraju ARIMA modeli za predikciju temperature betona i modeli višestruke linearne regresije za svaku tačku individualno. Dakle, kreiraju se tri ARIMA modela (za predikciju temperature u injkcionoj galeriji, kontrolnoj galeriji i na krani brane) i šest modela višestruke linearne regresije (za mjerne tačke M131, M141,

M151, M161, M171 i M181). Zatim se koriste predviđene vrijednosti temperature kao ulazi u regresione modele da bi se dobili predviđeni pomaci krune brane.

## 4 REZULTATI I DISKUSIJA

Test statistika mjeri stepen slaganja između uzoraka podataka i nulte hipoteze i u sebi sadrži informacije o podacima koji su relevantni za prihvatanje ili odbijanje nulte hipoteze. Test statistika poredi korištene podatke sa onim što se očekuje pod nultom hipotezom i koristi se za računanje  $p$ -vrijednosti.  $p$ -vrijednost se koristi prilikom testiranja hipoteza pri čemu predstavlja dokaz protiv nulte hipoteze. Što je ova vrijednost manja to je jači dokaz da treba odbiti nultu hipotezu (praksa je da se uzima kritična vrijednost od 0,05, tj. 5%). Kritična vrijednost je tačka na distribuciji test statistike pod nultom hipotezom koja definiše skup vrijednosti koje ukazuju na odbijanje nulte hipoteze (Shafer i Zhang, 2012). Rezultati ispitivanja stacionarnosti originalnih podataka vremenskih serija su prikazani u Tabeli 2.

Tabela 2

*Ispitivanje stacionarnosti originalnih vremenskih serija mjerenja temperature betona primjenom proširenog Dickey-Fuller testa*

Nivo mjerenja	Nulta hipoteza odbačena	$p$ -vrijednost	Test statistika	Kritična vrijednost
<b>Injekciona galerija</b>	Netačno	0,5465	-0,2879	-1,9416
<b>Kontrolna galerija</b>	Netačno	0,4452	-0,5643	-1,9416
<b>Kruna brane</b>	Netačno	0,1090	-1,5751	-1,9416

Nulta hipoteza Dickey-Fuller testa je da vremenska serija sadrži jedinični korijen što je čini nestacionarnom. Analizom rezultata iz Tabele 2 evidentno je da se nulta hipoteza ne može odbiti jer je apsolutna vrijednost test statistike manja od kritične vrijednosti, a  $p$ -vrijednost je veća od 0,05 što znači da vremenske serije mjerenja temperature betona brane u sva tri nivoa nisu stacionarne i kao takve se ne mogu koristiti za predikciju ARIMA modelom. Nakon diferenciranja ovih vremenskih serija ponovo je izvršeno testiranje, a rezultati su prikazani u Tabeli 3.

Tabela 3

*Ispitivanje stacionarnosti diferenciranih vremenskih serija mjerenja temperature betona primjenom proširenog Dickey-Fuller testa*

Nivo mjerenja	Nulta hipoteza odbačena	$p$ -vrijednost	Test statistika	Kritična vrijednost
<b>Injekciona galerija</b>	Tačno	0,0224	-2,2728	-1,9416
<b>Kontrolna galerija</b>	Tačno	0,0071	-2,7015	-1,9416
<b>Kruna brane</b>	Tačno	0,0037	-2,9506	-1,9416

Nakon diferenciranja vremenskih serija apsolutna vrijednost test statistike je veća od kritične vrijednosti, a  $p$ -vrijednost je manja od 0,05 pa se uz ove statističke dokaze nulta hipoteza odbija – vremenske serije mjerenja temperature betona nakon diferenciranja su stacionarne.

Nakon što je utvrđeno da su nakon diferenciranja serije mjerenja postale stacionarne ispitano je ukupno 25 različitih ARIMA modela ( $p = 1, \dots, 5$  i  $q = 1, \dots, 5$ ) za svaku vremensku seriju pojedinačno kako bi se pronašao adekvatan model za predikciju. Da bi se ograničila kompleksnost modela uvedeno je ograničenje tako da su  $p, q \leq 5$ . Modeli bez AR ili MA komponente nisu razmatrani, dakle  $p, q \neq 0$ . Osnovni kriterij za odabir najboljeg modela među testiranim je bila vrijednost AIC-a. Rezultati testiranja su prikazani u Tabeli 4.

Tabela 4  
Vrijednost AIC-a za testirane ARIMA modele

R.br.	AR	MA	Kruna brane	Kontrolna galerija	Injekciona galerija
1	1	1	-5722	-9653	-11370
2	1	2	-5732	-9663	-12209
3	1	3	-5749	-9684	-12221
4	1	4	-5762	-9682	-12233
5	1	5	-5768	-9681	-12232
6	2	1	-5723	-9667	-11939
7	2	2	-5722	-9673	-12217
8	2	3	-5781	-9682	-12220
9	2	4	-5779	-9681	-12239
10	2	5	-5777	-9679	-12244
11	3	1	-5783	-9681	-12042
12	3	2	-5781	-9680	-12229
13	3	3	-5779	-9681	-12244
14	3	4	-5730	-9680	-12260
15	3	5	-5778	-9682	-12258
16	4	1	-5781	-9680	-12123
17	4	2	-5782	-9678	-12236
18	4	3	-5776	-9679	-12251
19	4	4	-5780	-9683	-12259
20	4	5	-5778	-9681	-12274
21	5	1	-5779	-9681	-12147
22	5	2	-5780	-9679	-12249
23	5	3	-5779	-9681	-12259
24	5	4	-5778	-9679	-12265
25	5	5	-5779	-9680	-12275

Kao što se vidi iz Tabele 4 među testiranim modelima najbolje su se pokazali ARIMA (5,1,5) za predikciju temperature u injekcionoj galeriji, ARIMA (1,1,3) za predikciju u kontrolnoj galeriji i ARIMA (3,1,1) za predikciju na kruni brane. Primjenom Ljung-Box testa ispitano je da li su kod odabranih modela reziduali nezavisni, tj. da li su odabrani modeli dobri za predikciju vremenskih serija. Rezultati Ljung-Box testa su prikazani u Tabeli 5.

Tabela 5

Ispitivanje ARIMA modela primjenom Ljung-Box testa

Model	Nulta hipoteza odbačena	p-vrijednost	Test statistika	Kritična vrijednost
ARIMA (5,1,5)	Netačno	0,1587	14,3230	18,3070
ARIMA (1,1,3)	Netačno	0,3160	4,7313	9,4877
ARIMA (3,1,1)	Netačno	0,5755	2,8949	9,4877

Nulta hipoteza Ljung-Box testa je da su reziduali nezavisno raspoređeni i u ovom slučaju testiranja nemogućnost odbijanja nulte hipoteze znači da su odabrani modeli dobri za predikciju vremenskih serija. Obzirom da je apsolutna vrijednost test statistike manja od kritične vrijednosti, a p-vrijednost značajno veća od 0,05 ne postoje statistički dokazi za odbijanje nulte hipoteze – reziduali su nezavisno raspoređeni.

Tabela 6

Rezultati predikcije temperature betona brane (legenda: M – mjereno, P – predikcija, in. – injekciona galerija, kon. – kontrolna galerija, kr. – krana brane, jedinica: °C)

R. br.	Predviđeno dana	Predviđeno za dan	M. in.	M. kon.	M. kr.	P. in.	P. kon.	P. kr.
1	16.06.2019.	16.07.2019.	9,90	14,30	24,09	9,83	13,79	24,99
2	27.07.2019.	26.08.2019.	10,09	15,85	27,45	10,07	15,76	28,60
3	14.08.2019.	13.09.2019.	10,22	16,26	26,52	10,20	16,81	30,06
4	15.09.2019.	15.10.2019.	10,48	16,32	22,21	10,42	16,65	25,56
5	20.10.2019.	19.11.2019.	10,67	15,86	17,17	10,66	16,23	18,88
6	12.11.2019.	12.12.2019.	10,69	14,92	13,30	10,71	15,77	14,23
7	18.12.2019.	17.01.2020.	10,53	13,50	9,94	10,59	13,61	9,10
8	18.01.2020.	17.02.2020.	10,32	12,53	9,36	10,37	12,50	9,01
9	19.02.2020.	20.03.2020.	10,07	12,26	11,15	10,06	11,85	10,53
10	19.04.2020.	19.05.2020.	9,87	13,02	16,72	9,84	12,68	16,47
11	18.05.2020.	17.06.2020.	9,90	13,65	19,02	9,93	13,52	20,03
12	15.06.2020.	15.07.2020.	9,97	14,44	24,14	9,95	14,19	21,24

Odabrani ARIMA modeli su upotrijebljeni za predikciju temperature betona pri čemu je predikcija rađena 30 dana unaprijed, a za validaciju je korišteno 12 validacijskih serija. Rezultati predikcije temperature su prikazani u Tabeli 6.

Analizom rezultata iz Tabele 6 može se zaključiti da su rezultati predikcije temperature zadovoljavajući. Srednja apsolutna greška predikcije temperature u injekcionoj galeriji je izuzetno mala (0,03 °C) što u stvarnosti ne znači da je model predikcije izuzetno dobar. Razlog male greške je to što se temperatura u injekcionoj galeriji sporo mijenja, a uz to i razlika između minimalne i maksimalne temperature je veoma mala. Srednja apsolutna greška predikcije temperature u kontrolnoj galeriji je 0,33 °C što je dobar rezultat pa se može zaključiti da je odabrani ARIMA model dobar za predikciju kao što je prethodno Ljung-Box test statistički tvrdio. Srednja apsolutna greška predikcije temperature na krani brane je 1,46 °C što je znatno

veća greška u odnosu na kontrolnu galeriju, ali ovo je i očekivano jer se promjene temperature na kruni dešavaju znatno brže nego u kontrolnoj galeriji, a uz to je i amplituda promjena znatno veća. Maksimalna greška predikcije na kruni brane je bila 3,54 °C što je zadovoljavajući rezultat obzirom da se temperatura predviđa 30 dana unaprijed jednovarijabilnom predikcijom.

Predviđene vrijednosti temperature su korištene za predikciju pomaka krune brane primjenom modela VLR koji su prethodno podešeni na osnovu 62 serije mjerenja temperature i pomaka kontrolnih tačaka. Izračunati regresioni koeficijenti za svaki model su prikazani u Tabeli 7.

Tabela 7

*Izračunati regresioni koeficijenti*

Tačka	M131	M141	M151	M161	M171	M181
<i>R</i>	0,59	0,81	0,77	0,80	0,88	0,79

Vrijednosti regresionih koeficijenata su uglavnom blizu ili preko statistički značajne vrijednosti od 0,80 što govori da su modeli višestruke linearne regresije adekvatni za predikciju pomaka brane. Dodatno, ove vrijednosti pokazuju da su pomaci krune brane izazvani termalnim varijacijama što potvrđuje da je identifikacija uticajnih faktora na pomake urađena ispravno. Izuzetak od prethodno navedenog je model napravljen za tačku M131 sa regresionim koeficijentom  $R = 0,59$ . Ova vrijednost pokazuje da uticaj temperature na tačku M131 nije izražen kao kod ostalih kontrolnih tačaka koje su razmatrane. Postignuti rezultati svakog modela su prikazani u Tabeli 8.

Tabela 8

*Apsolutne greške predikcije, srednja apsolutna greška predikcije u seriji i srednja apsolutna greška za svaku kontrolnu tačku (legenda: SAG – srednja apsolutna greška, jedinica: mm)*

R. br. serije	M131	M141	M151	M161	M171	M181	SAG serije
<b>1</b>	2,78	2,21	1,57	0,85	0,80	0,48	<b>1,45</b>
<b>2</b>	0,13	1,54	0,04	0,42	0,39	0,20	<b>0,46</b>
<b>3</b>	0,19	2,61	1,48	0,72	1,43	0,55	<b>1,16</b>
<b>4</b>	5,02	7,12	4,49	3,16	3,90	1,17	<b>4,14</b>
<b>5</b>	4,18	5,23	2,74	2,75	2,23	0,17	<b>2,88</b>
<b>6</b>	2,90	1,91	1,78	1,43	0,70	0,12	<b>1,47</b>
<b>7</b>	0,97	1,39	0,51	0,54	0,32	0,46	<b>0,70</b>
<b>8</b>	0,20	1,42	1,46	0,43	0,68	0,12	<b>0,72</b>
<b>9</b>	3,12	2,30	2,72	1,86	1,54	0,05	<b>1,93</b>
<b>10</b>	1,08	0,30	0,21	0,60	0,37	0,36	<b>0,49</b>
<b>11</b>	2,20	0,29	0,31	0,03	0,18	0,34	<b>0,56</b>
<b>12</b>	4,47	1,98	2,35	2,27	1,52	0,16	<b>2,13</b>
<b>SAG tačke</b>	<b>2,27</b>	<b>2,36</b>	<b>1,64</b>	<b>1,25</b>	<b>1,17</b>	<b>0,35</b>	

Ako se analiziraju rezultati svake tačke pojedinačno iz Tabele 8 vidi se da najveću srednju apsolutnu grešku ima kontrolna tačka M131 što je i očekivano obzirom na rezultate prikazane u Tabeli 7 koji pokazuju da je regresioni koeficijent najmanji kod modela za predikciju pomaka tačke M131 ( $R = 0,59$ ). Ako se posmatraju rezultati predikcije u svakoj seriji rezultati su smisleni uz izuzetak postignutih rezultata u serijama 3 i 5. Greške predikcije temperature su najveće u serijama 3, 4 i 12, a greške predikcije pomaka su najveće u serijama 4, 5 i 12. Dakle, serije 4 i 12 imaju velike greške predikcije temperature što se odrazilo na predikciju pomaka što je i bilo očekivano obzirom da je korišteni model predikcije zasnovan na predviđenim temperaturama. Neočekivani rezultati su postignuti u dvije serije:

- u seriji 3 koja je imala najveće greške predikcije temperature, a greške predikcije pomaka su bile zadovoljavajuće i
- u seriji 5 koja je imala dobre rezultate predikcije temperature, ali su greške predikcije pomaka bile značajne.

U pet serija korištenih za validaciju srednja apsolutna greška predikcije je bila manja od 1 mm, u četiri serije između 1 i 2 mm, dok je greška bila veća od 2 mm u tri testirane serije mjerenja.

## 5 ZAKLJUČAK

U okviru rada su predstavljene rezultati istraživanja uticaja termalnih varijacija na ponašanje krune betonske gravitacione brane HE Salakovac. Podaci pomaka brane su dobijeni mjerenjem metodom aliniranja, a temperature betona su mjerene u tri nivoa: injekciona galerija, kontrolna galerija i kruna brane.

Predikcija temperature betona brane je vršena primjenom ARIMA modela. Odabir najboljih modela je izvršen primjenom Box-Jenkins metodologije pri čemu je odabir najboljih modela izvršen primjenom statističkih testova, a ne ekspertnim znanjem i analizom autokorelacijskih i parcijalnih autokorelacijskih grafova. Postignuti rezultati predikcije 30 dana unaprijed su bili zadovoljavajući i greška predikcije je samo u dva slučaja prešla vrijednost od 3 °C. Rezultati predikcije pomaka na osnovu predviđenih vrijednosti temperature su bili zadovoljavajući i srednja apsolutna greška je bila manja od 2 mm u devet od dvanaest serija. Najveće greške predikcije pomaka su direktno povezane sa najvećim greškama predikcije temperature što je bilo očekivano.

Istraživanje je pokazalo da je primjenom predloženog modela moguće dobiti kvalitetne predikcije pomaka brane na osnovu predviđenih vrijednosti temperature betona. Slaba strana modela je to što su maksimalne greške u pojedinim slučajevima prelazile vrijednost od 5 mm. Nekada greška od 5 mm nije značajna, međutim prilikom monitoringa strukturnih objekata kao što je brana ova vrijednost je izuzetno velika. Povećanje pouzdanosti modela kroz umanjenje maksimalnih grešaka je sljedeći korak koji će se poduzeti kako bi se unaprijedio model.

Unapređenje modela se može uraditi na više načina, a jedan od njih je povećanje kvaliteta predikcije temperature betona jer je evidentno da greška u predikciji temperature utiče negativno

na kvalitet predikcije pomaka. Dodatno, model se može unaprijediti i dodavanjem novih faktora u model. Prilikom izrade modela pretpostavljeno je da je pritisak vodene mase na branu konstantan pa je ovaj uticaj zanemaren kao značajan. Iako ovaj uticaj nije dominantan u konkretnom slučaju treba istražiti koliko stvarno utiče nivo vode na pomake brane kod brana sa malim varijacijama nivoa vode. Kombinovanje prethodno pomenutih faktora u zajednički model je planirano u jednom od narednih istraživanja.

## LITERATURA

Amberg, F. (2009). Interpretative models for concrete dam displacements. *23th ICOLD congress, Brasilia*.

Anderson, O. D. (1977). The Box-Jenkins approach to time series analysis. *RAIRO-Operations Research*, 11(1), 3-29.

Dickey, D. A., Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, 74(366a), 427-431.

Hamzić, A., Avdagić, Z., Bešić, I. (2020). Multistage Cascade Predictor of Structural Elements Movement in the Deformation Analysis of Large Objects Based on Time Series Influencing Factors. *ISPRS International Journal of Geo-Information*, 9(1), 47. DOI: <https://doi.org/10.3390/ijgi9010047>.

Hyndman, R. J., Athanasopoulos, G. (2018). *Forecasting: principles and practice*. Australia: OTexts.

Johnson, R. A., Wichern, D. W. (2002). *Applied multivariate statistical analysis*. Upper Saddle River: Prentice hall.

Kang, F., Liu, J., Li, J., Li, S. (2017). Concrete dam deformation prediction model for health monitoring based on extreme learning machine. *Structural Control and Health Monitoring*, 24(10), e1997. DOI: 10.1002/stc.1997.

Lombardi, G. (2004). Advanced data interpretation for diagnosis of concrete dams. *CISM Udine, Italy*.

Ljung, G. M., Box, G. E. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303.

Reddy, J. R., Ganesh, T., Venkateswaran, M., Reddy, P. (2017). Forecasting of monthly mean rainfall in Coastal Andhra. *International Journal of Statistics and Applications*, 7(4), 197-204. DOI: 10.5923/j.statistics.20170704.01

Rencher, A. C., Schaalje, G. B. (2008). *Linear models in statistics*. New Jersey: John Wiley & Sons.

Rezo, M., Šugar, D., Težak, I., Zidar, M. (2007). Određivanje horizontalnih pomaka, rotacija i nagiba metodom aliniranja i klinometrijom na hidroelektranama. *Zbornik radova SIG 2007. simpozija o inženjerskoj geodeziji*, 151-164.

Schwert, G. W. (2002). Tests for unit roots: A Monte Carlo investigation. *Journal of Business & Economic Statistics*, 20(1), 5-17. DOI: 10.2307/1391432.

Shafer, D.S., Zhang, Z. (2012). *Beginning statistics*. New York: Environmental Protection Agency.

STRABAG AG (2012). *Rehabilitacija i modernizacija monitoring sistema HE Salakovac – Projekt izvedenog stanja*.

Takahashi, A., Kurosawa, T. (2016). Regression correlation coefficient for a Poisson regression model. *Computational Statistics & Data Analysis*, 98, 71-78. DOI: 10.1016/j.csda.2015.12.012

Tsay, R. S. (2005). *Analysis of financial time series*. New Jersey: John Wiley & Sons.

Wang, X., Yang, K., Shen, C. (2017). Study on MPGA-BP of gravity dam deformation prediction. *Mathematical Problems in Engineering*, 2017. DOI: 10.1155/2017/2586107.

Xu, G., Jing, Z., Mao, Y., Su, X. (2020). A Dam Deformation Prediction Model Based on ARIMA-LSTM. *2020 IEEE Sixth International Conference on Big Data Computing Service and Applications (BigDataService)*, (pp. 205-211). United Kingdom: Oxford. DOI: 10.1109/BigDataService49289.2020.00040.

Zou, J., Bui, K. T. T., Xiao, Y., Doan, C. V. (2018). Dam deformation analysis based on BPNN merging models. *Geo-spatial information science*, 21(2), 149-157. DOI: 10.1080/10095020.2017.1386848

### ***Autori:***

#### ***Adis Hamzić, dipl. inž. geod.***

Elektroprivreda BiH, Hidroelektrane na Neretvi  
Jaroslava Černija 1, 88420 Jablanica  
Bosna i Hercegovina  
E-mail: hamzicadis87@gmail.com

#### ***Doc. dr. sc. Dina Kamber Hamzić***

Univerzitet u Sarajevu, Prirodno-matematički fakultet  
Zmaja od Bosne 33-35, 71000 Sarajevo  
Bosna i Hercegovina  
E-mail: dinakamber@pmf.unsa.ba