

## Primjena strojnog učenja za predviđanje i procjenu vodostaja i protoka rijeka pod usporom mora

Jonatan Lerga<sup>1,2</sup>, Anna Maria Mihel<sup>1,2</sup>, Nino Krvavica<sup>2,3</sup>

<sup>1</sup>Sveučilište u Rijeci, Tehnički fakultet, Vukovarska 58, 51000 Rijeka

<sup>2</sup>Sveučilište u Rijeci, Centar za umjetnu inteligenciju i kibernetičku sigurnost, R. Matejčić 2, 51000 Rijeka

<sup>3</sup>Sveučilište u Rijeci, Građevinski fakultet, R. Matejčić 3, 51000 Rijeka

**Sažetak:** *Rijeke pod utjecajem mora predstavljaju dinamične sustave u kojima se javljaju složena međudjelovanja toka slatke vode i oscilacija mora. Upravljanje vodnogospodarskim sustavima u takvim okruženjima uvelike ovisi o kvaliteti i pouzdanosti hidroloških podataka. Međutim, nagle i teško predvidljive promjene vodostaja otežavaju primjenu standardnih hidroloških modela, osobito kada je potrebno procijeniti protok na temelju mjerenja vodostaja. U ovom radu istražena je primjena suvremenih metoda strojnog učenja za predviđanje i procjenu hidrodinamičkih značajki rijeka pod usporom mora, s naglaskom na donji tok rijeke Neretve – područje koje je zbog porasta razine mora, sezonskih promjena dotoka slatke vode i čestih ekstremnih događaja prepoznato kao jedno od najosjetljivijih na klimatske rizike.*

*U tu svrhu razvijeni su hibridni modeli temeljeni na neuronskim mrežama koji kombiniraju različite pristupe analize vremenskih serija. Za predviđanje vodostaja korišten je model koji povezuje model duge kratkoročne memorije (LSTM) i konvolucijske mreže, dok je za rekonstrukciju protoka primijenjen LSTM model proširen mehanizmom pažnje. Takvi modeli omogućuju učinkovitije prepoznavanje nestacionarnih procesa te složenih signala povezanih s utjecajem plime i riječnih dotoka pogotovo tijekom ekstremnih događaja.*

*Dobiveni rezultati potvrđuju da hibridni modeli strojnog učenja nadmašuju tradicionalne pristupe, osobito u uvjetima gdje se istodobno javljaju utjecaji rijeke i mora. Praktične primjene ovakvih modela uključuju poboljšanje sustava ranog upozorenja na poplave, optimizaciju upravljanja sustavima navodnjavanja te potporu donošenju odluka u kontekstu prilagodbe klimatskim promjenama.*

**Ključne riječi:** *strojno učenje, predviđanje, procjena, vodostaj, protok*

## 1. Uvod

Značaj dinamičnih sustava, kao što su rijeke pod utjecajem uspora mora prepoznat je u brojnim područjima, od upravljanja vodnim resursima [1], do razvoja strategija zaštite, uključujući prognoziranje ekstremnih pojava i procijene utjecaja podizanja razine mora [2]. Na složeni tok rijeka pod usporom mora negativno utječu dvije kategorije čimbenika, prirodne i antropogene. Kod prirodnih čimbenika poseban naglasak stavlja se na klimatske promjene, koje su u posljednjem desetljeću dovele do značajnih promjena dinamike toka rijeka, poput učestalijih ekstremnih pojava, kao što su poplave i suše [3]. Takve promjene mogu uzrokovati narušavanje bioloških ekosustava [4] te promjene u hidrološkom režimu rijeka [5]. Istodobno, promjene u hidrološkom režimu rijeke su također posljedica utjecaja urbanizacije, intenzivne poljoprivrede, preinaka poplavnih ravnica kao i drugih antropogenih čimbenika [4, 6].

Osiguranje učinkovitog upravljanje vodnim resursima, kao i uspostava strategija zaštite, omogućuju ne samo pravovremene reakcije kroz analize i praćenje, već i očuvanja prirodnih staništa. Uspješno ostvarivanje navedenih ciljeva moguće je postići kroz uspostavu kontinuiranog praćenja osnovnih hidroloških parametara: vodostaja i protoka rijeke. Podaci o vodostaju rijeke dobivaju se putem izravnih mjerenja koristeći uređaje kao što je limnigraf, radarski uređaji ili satelitski visinomjer. Podaci o protoku rijeke nisu dostupni putem direktnih izmjera, već predstavljaju izvedenu veličinu dobivenu putem izračuna ili procjena. U tu svrhu najčešće se koriste izravno dostupne veličine kao što je brzina strujanja vode i površina proticajnog presjeka rijeke.

Iako je u znanstvenoj literaturi dostupan značajan broj radova koji se bave predviđanjem vodostaja ili protoka rijeka [7 - 9] vrlo je malo radova koji se bave priobalnim rijekama koje su pod utjecajem uspora mora. U nedavno objavljenom preglednom radu sistematizirana su sva relevantna istraživanja u području hidrologije koja se bave primjenom strojnog učenja u predviđanju vodostaja ili protoka u rijekama pod utjecajem uspora mora [10]. Pretraživanjem međunarodnih baza, ukupno je identificirano 47 znanstvenih radova objavljenih do 2025. godine koji se bave ovom tematikom. Tijekom pregleda radova primijećen je relativno spor porast u popularnosti primjene strojnog učenja od 1990. do 2000. godine, nedostatak kontinuiteta u učestalosti obavljenih studija, ograničen broj studija koje proučavaju odnos vodostaja i protoka, te neravnomjernu regionalnu zastupljenost, pri čemu su prevladavale rijeke pod usporom mora na području Azije [10, 11].

Protok rijeke istražen je u svega devet radova, počevši s najstarijim radom [12] koji je koristio neuronske mreže za kreiranje protočne krivulje, dok su se ostali radovi uglavnom fokusirali na rekonstrukciju ili predviđanje protoka. Modeli temeljeni na mreži duge kratkoročne memorije (LSTM) primijenjeni su tek nedavno, od 2023.

godine, s dva dostupna rada u području predviđanja protoka [13, 14]. Što se tiče vremenske rezolucije, korištene su skale izražene u danima ili intervalima od pola sata, a ulazni parametri nisu bili ograničeni samo na razinu vodostaja, već su uključivali i varijable poput razine mora, temperature, brzinu protoka ali i druge. Najnoviji rad [15] fokusirao se na praćenja protoka u stvarnom vremenu i istražio je primjenu metodološkog okvira koji omogućuje prilagodljiv odabir algoritma, uz primjenu genetskog algoritma u svrhu optimizacije hiperparametara. Taj okvir se pokazao kao bolje rješenje u odnosu na samostalne modele korištene unutar metodološkog okvira.

Razina vodostaja istražena je u većem broju radova, točnije njih 40. Prva dostupna studija primijenila je osnovnu arhitekturu neuronske mreže za predviđanje razine vodostaja [16]. Primjena modela temeljenih na mreži druge kratkoročne memorije započela je nešto ranije od problema vezanih uz protok, točnije 2018. godine sa studijom usmjerenom na problem plavljenja cestovnog mosta [17]. Recentniji radovi testirali su primjenu navedenog modela kao dijela hibridnih arhitektura, poput modela koji povezuje LSTM s konvolucijskom mrežom [18, 19] ili modela koji povezuje LSTM s hidrodinamičkim modelima [20, 21], što je doprinijelo boljim rezultatima u odnosu na primjenu samostalnog LSTM-a.

U ovom radu prikazana su ključna zapažanja i rezultati doktorskog istraživanja Anne Marie Mihel [11], koji su prethodno objavljeni u nekoliko znanstvenih radova u vrhunskim međunarodnim časopisima [10, 22]. Istraživanje se bavi primjenom metoda strojnog učenja za predviđanje i procjenu razine vodostaja i protoka rijeke Neretve, rijeke koja je pod snažnim utjecajem mora. U okviru istraživanja razvijena su dva hibridna modela temeljena na rekurzivnim neuronskim mrežama. Prvi model koristi pristup duge kratkoročne memorije uz dodatni mehanizam pažnje te se primjenjuje za procjenu i rekonstrukciju protoka u uzvodnom dijelu rijeke. Pri tome se koriste simulirani i mjereni podaci o vodostaju s nizvodnih, srednjih i uzvodnih lokacija. Drugi model povezuje model duge kratkoročne memorije s konvolucijskom neuronskom mrežom te se koristi za predviđanje razine vodostaja i protoka. Osim podataka o vodostaju dobivenih numeričkim modeliranjem na dostupnim mjernim stanicama, model kao ulazni podatak koristi i protok rijeke. Cilj istraživanja bio je pokazati da hibridni modeli, samostalno ili u kombinaciji s dodatnim metodama, mogu smanjiti pogreške u procjeni i predviđanju vodostaja i protoka. Dobiveni rezultati potvrđuju nalaze ranijih istraživanja, uz dodatni doprinos kroz primjenu novih modela i kombinacija metoda.

## 2. Područje istraživanja i podaci

### 2.1. Rijeka Neretva

Rijeka Neretva, ukupne duljine 215 km, protječe kroz dvije države. Većim dijelom prolazi kroz Bosnu i Hercegovinu (193 km), dok značajno manji dio toka rijeke prolazi kroz Republiku Hrvatsku (22 km), gdje se ulijeva u Jadransko more [23]. Dionica rijeke koja protječe kroz Hrvatsku predstavlja fokus provedenog istraživanja te se smatra dijelom rijeke pod utjecajem uspora mora.

Utjecaj Jadranskog mora očituje se kroz dva glavna aspekta relevantna za hidrološke uvjete. Za vrijeme malih voda tok Neretve karakterizira izrazita vertikalna uslojenost, pri čemu donji sloj morske vode teče uzvodno prema Metkoviću, dok gornji sloj slatke vode teče nizvodno prema ušću [23]. S druge strane, tijekom velikih voda, razina mora generira uspor i utječe na vodostaje duž donjeg toka rijeke Neretve, čak i kod Metkovića, što može imati ozbiljne implikacije za generiranje poplava [24]. Stoga je zaštita ovog područja od potencijalnih opasnosti uzrokovanih hidrološkim ekstremima od iznimnog značaja za budućnost poljoprivrede, kao i za sigurnost lokalnog stanovništva.

Prvi podaci o vodostaju na tom području datiraju iz 1934. godine, dok su najranija dostupna kontinuirana mjerenjima započela 1957. godine na lokaciji Metković. Unatoč velikoj važnosti ovog područja, kontinuirana mjerenja protoka uspostavljena su tek nedavno, od sredine 2015. godine, na profilu cestovnog mosta, smještenog približno 90 m uzvodno od hidrološke postaje Metković [25].

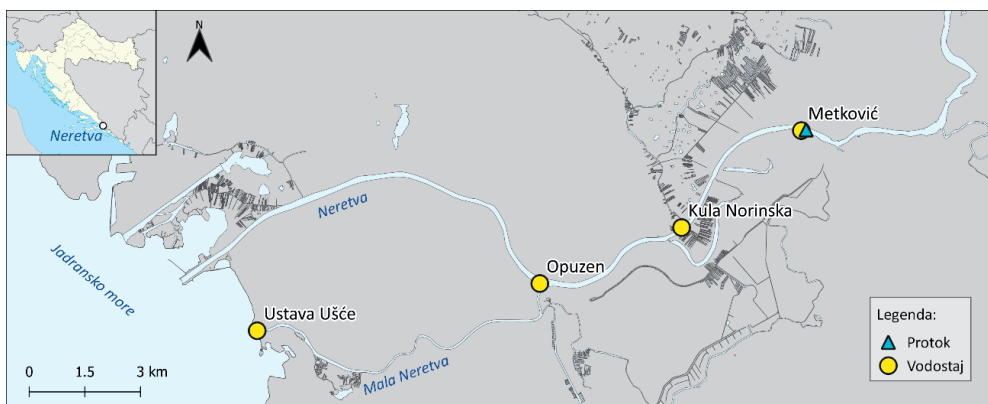
### 2.2. Skupovi podataka

Za potrebe predmetnog istraživanja korištena su tri skupa podataka. Prvi skup obuhvaća mjerene podatke prikupljene od strane Državnog hidrometeorološkog zavoda te Hrvatskih voda. Iako Državni hidrometeorološki zavod pruža podatke o protocima, oni se uglavnom dobivaju primjenom protočne krivulje, što nije pouzdana metoda za dionice rijeke koje su pod usporom mora. Iz tog razloga, na rijeci Neretvi, Hrvatske vode uspostavile su sustav monitoringa protoka Neretve kod Metkovića pomoću horizontalnog akustičnog Dopplerovog strujomjera (H-ADCP), koji omogućuje pouzdanu procjenu protoka. Naime, za razliku od protočne krivulje koja za procjenu razine vodostaja zahtijeva unaprijed poznat protok, ADCP uređaji omogućuju proračun protoka putem direktno izmjenjenog polja brzina i geometrije poprečnog presjeka korita [26].

Zbog potencijalnih problema povezanih s kvalitetom mjerenih podataka, uključujući nedostajuće podatke, utjecaj nefizičkih oscilacija te nepouzdanost vrijednosti niskih

protoka, u okviru ovoga istraživanja uključeni su i simulirani podatci. Stoga, preostala dva skupa podataka generirana su primjenom hidrauličkih modela HEC-RAS i STREAM 1D. Oba modela omogućuju proračun jednodimenzijskog nestacionarnog toka površinskih voda [11] rješavanjem sustava jednadžbi plitkih voda, u svrhu prognoziranja hidrodinamičkih procesa [27]. Odabrana HEC-RAS simulacija bazira se na pretpostavci homogene gustoća fluida, dok salinitet i temperatura ostaju konstantni na cijeloj dužini analiziranog riječnog toka. STREAM 1D ima poseban naglasak na primjenu u stratificiranim estuarijima, gdje za razliku od jednoslojnog HEC-RAS modela, simulira dvoslojnu strukturu riječnog toka i stoga pruža točniji prikaz hidrauličkih parametara u uvjetima malih voda [11].

Skupovi podataka sadrže podatke o vodostaju s četiri lokacije od ušća do Metkovića. Prva lokacija nalazi se u blizini ušća rijeke Male Neretve, gdje je smještena mareografska postaja, u ovom radu se naziva Ušće. Slijede hidrološke postaje Opuzen (11 km od ušća rijeke), Kula Norinska (16 km od ušća rijeke) i Metković (22 km od ušća rijeke). Podatci o protoku prikupljaju se na lokaciji Metković, 90 m uzvodno od hidrološke postaje. Relevantne postaje prikazane su na Slici 1. Jedina značajnija razlika među korištenim skupovima podataka odnosi se na vremenski raspon podataka. Skup podataka dobiven HEC-RAS modelom korišten je u svrhu preliminarnih analiza te obuhvaća razdoblje od 2016. do kraja 2019. godine, dok preostala dva skupa podataka također započinju 2016. godine, ali traju do 2021. godine.



**Slika 1:** Nizvodni tok rijeke Neretve pod utjecajem uspora mora, s naglaskom na mareografsku postaju (Ušće), hidrološke postaje (Opuzen, Kula Norinska, Metković), i lokaciju gdje se procjenjuje protok (Metković) [28]

### 3. Metodologija

Metodologija provedenog istraživanja sastojala se od nekoliko koraka. U prvom koraku provedena je priprema podataka. Problem nedostajućih podataka u mjerenom skupu riješen je primjenom nelinearne korelacije između H-ADCP uređaja. Pažljivi-

vim filtriranjem šuma nastojao se smanjiti utjecaj nefizičkih oscilacija. Provedena je provjera potencijalnog kašnjenja podataka između mjernih stanica. Nakon toga podaci su podijeljeni na skup podataka za treniranje i skup za testiranje u omjeru od 80% - 20%. Za mjerene podatke i simulirane podatke dobivene modelom STREAM 1D, treniranje je obuhvatilo razdoblje od siječnja 2016. do listopada 2020., dok je za HEC-RAS skup podataka obuhvaćalo razdoblje od siječnja 2016. do veljače 2019., a preostali dio podataka korišten je za testiranje.

Zbog različitih raspona vrijednosti vodostaja i protoka provedeno je skaliranje podataka primjenom MinMaxScaler metode u raspon od [0,1]. Nakon skaliranja podaci su pretvoreni u pomični prozor koji je sadržavao podatke od prethodnog dana (24 sata), pri čemu su za procjenu korišteni samo podaci o vodostaju, dok su za scenarije predviđanja uključeni i podaci o protoku. Duljina prozora odabrana je u skladu s plimnim režimom Jadranskog mora [24], s ciljem obuhvaćanja cjelodnevnog plimnog ciklusa koji uključuje i poludnevne i dnevne komponente.

Za potrebe predviđanja primijenjene su dvije metode obrade signala, pretvorba signala u dvodimenzionalne matrice koje predstavljaju spektrograme te napredne metode kao što je varijacijska dekompozicija modova (VMD). Spektrogrami su kreirani koristeći podatke od prethodnog dana (24 sata unazad), međutim, kao ulaz koriste podatke o vodostaju i protoku. VMD metoda na brz i stabilan način razdvaja izvorne signale u zasebne komponente, s naglaskom na smanjenu prisutnost kumulativnih pogreški [29].

Treniranje i validacija modela proveli su se primjenom peterostruke unakrsne validacije s pretraživanjem mreže parametara. Broj podjela odabran je na temelju dostupne količine podataka, ali i „ravnoteže“ između varijance i pristranosti [30]. Za jednostavnije modele strojnog učenja (DT, RF, SVR, LGBM i XGB) korištena je *scikit-learn* knjižnica, dok za PyTorch modele *skorch* i klasu omotača *NeuralNetRegressor*. U pogledu optimizacijskog algoritma, izabran je NAdam (*engl. Nesterov-accelerated Adaptive Moment Estimation*) koji pruža ubrzanu konvergenciju [31], uz dodatno uključenje broja epoha za rano zaustavljanje, točnije njih 15, dok je sveukupan broj epoha iznosio 500.

Glavna mjera pogreške za validaciju modela bila je srednja kvadratna pogreška ili MSE, dok su za testiranje modela korišteni korijen srednje kvadratne pogreške ili RMSE, srednja apsolutna pogreška ili MAE, srednja apsolutna postotna pogreška ili MAPE, Nash-Sutcliffe koeficijent učinkovitosti ili NSE, te koeficijent korelacije ili R. Dodatne mjere korištene u svrhu pronalaska optimalnih parametara VMD metode odnose se na indeks ortogonalnosti i omjer pogreške rekonstrukcije. Dodatni korak odnosi se na pružanje interpretabilnosti modela kao i transparentnosti uz primjenu SHAP metode na jednostavnijim modelima i ciljanog izostavljanja značajki za modele bazirane na LSTM-u.

Korištene su dvije hibridne arhitekture strojnog učenja. Prva arhitektura predstavlja novo predloženo rješenje temeljeno na modelu duge kratkoročne memorije (LSTM) proširenom mehanizmom pažnje [11]. Druga je hibridna mreža koja je već ranije primijenjena za slične zadatke predviđanja, a temelji se na kombinaciji konvolucijske neuronske mreže i LSTM modela [32, 33]. Novo predložena hibridna arhitektura sastoji se od LSTM modela kombiniranog s mehanizmom pažnje, koji završava s potpuno spojenim slojem. Arhitektura korištena za predviđanje sastoji se od dva konvolucijska sloja, jednog Max Pooling sloja, jednog LSTM sloja, regularizacijskog (Dropout) sloja te potpuno spojenog sloja. Detaljan opis arhitektura dostupan je u [11].

## 4. Rezultati i diskusija

U nastavku su prikazani rezultati četiri smjera istraživanja: (1) procjene protoka, (2) procjene protoka uz primjenu metode dekompozicije signala, (3) predviđanja protoka i (4) predviđanje vodostaja. Prvi smjer istraživanja uspoređuje rezultate predloženog hibridnog modela LSTM-Attention sa samostalnim modelima poput LSTM-a, XGB, LGBM, SVR s rbf i sigmoid jezgrenom funkcijom, RF i DT-om koristeći vremenske serije vodostaja i protoka [22]. Drugi smjer istraživanja uzima dva najbolja modela iz prvog scenarija te uspoređuje rezultate modela nakon što su vremenske serije pretvorene u zasebne kategorije plimnih komponenti koje su zatim korištene za treniranje modela, kako bi se procijenilo je li uz primjenu metode obrade signala moguće smanjiti pogrešku procjene [11]. Zadnja dva smjera istraživanja prikazuju rezultate preliminarnih analiza u pogledu predviđanja protoka i vodostaja, koristeći hibridni model CNN-LSTM [32, 33].

### 4.1 Procjena protoka

Rezultati predloženog hibridnog modela, LSTM-Attention, uspoređeni su s rezultatima samostalnih modela strojnog učenja na mjerenim i simuliranim podacima. Predloženi model pokazao je najbolje performanse, što je vidljivo iz Tablice 1 koja prikazuju mjere pogreške za različite modele. Drugim najboljim modelom pokazao se samostalni LSTM, koji ima lošije performanse od LSTM-Attention za 9,6% RMSE, 9,7% MAE, 0,5% NSE i 0,1% R za mjereni set podataka, te 14,3% RMSE, 16,7% MAE, 0,2% NSE i 0,1% R za simulirani set podataka.

Rezultati pokazuju konzistentno poboljšanje kroz sve mjere za predloženi hibridni model, kod oba skupa podataka, iako je razlika nešto veća za mjereni skup što je očekivano. Razlika između performansi najboljeg modela za mjereni u odnosu na simulirani skup podataka iznosi 48,7% za RMSE, 47,8% za MAE, 2,0% za NSE, i 0,8% za R metriku. Najveće pogreške procjene rezultata pružile su obje varijante SVR modela.

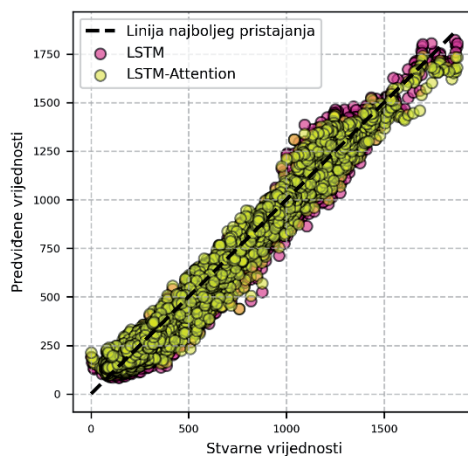
**Tablica 1:** Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skup mjerenih i simuliranih podataka (podebljan je rezultat najboljeg modela, a ostali su poredani od najboljih prema lošijim performansama) [22]

Modeli strojnog učenja	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)	NSE	R
<b>Predloženi model: LSTM-Attention</b>	<b>57,406 / 29,473</b>	<b>43,201 / 22,530</b>	<b>0,974 / 0,993</b>	<b>0,989 / 0,997</b>
LSTM	63,495 / 34,384	47,821 / 27,057	0,969 / 0,991	0,988 / 0,996
XGBoost	73,212 / 48,428	51,836 / 34,739	0,958 / 0,982	0,982 / 0,991
LGBM	73,130 / 53,797	52,260 / 36,341	0,958 / 0,977	0,983 / 0,989
RF	73,306 / 48,729	52,159 / 34,669	0,985 / 0,981	0,982 / 0,991
DT	76,147 / 51,747	54,368 / 37,492	0,955 / 0,979	0,980 / 0,990
SVR-rbf	77,387 / 70,128	54,410 / 36,554	0,953 / 0,962	0,979 / 0,983
SVR-sigmoid	82,155 / 53,010	58,992 / 40,978	0,947 / 0,978	0,947 / 0,990


\*Mjereni skup podataka / Simulirani skup podataka

Dijagram predviđenih naspram stvarnih vrijednosti prikazan je za dva modela koja su pružila najbolje rezultate, i za oba scenarija (Slika 2). Za slučaj mjerenih podataka odstupanja su slična u usporedbi s cijelim rasponom podataka, s naglaskom na veća za protoke čije vrijednosti prelaze 1000 m<sup>3</sup>/s, iako hibridni model ima užu raspršenost točaka oko pravca najboljeg pristajanja u odnosu na LSTM. Za slučaj simuliranih podataka najveća odstupanja procjene uočena su za protoke veće od 1000 m<sup>3</sup>/s za LSTM model, dok je hibridni model adekvatno uhvatio čak i najekstremnije vrijednosti protoka. Najšira raspršenost točaka za simulirane podatke oko pravca najboljeg pristajanja uočena su za najmanje vrijednosti protoka, koje obuhvaćaju najveći dio podataka.

Slika 3 pruža detaljniji uvid kada je riječ o različitim rasponima vrijednosti protoka i distribuciji podataka, te pogrešci MAE za svaku kategoriju protoka i model. Za analizu su generirane četiri grupe raspona protoka: (a) raspon protoka između 0 i 300 m<sup>3</sup>/s, koji predstavlja kategoriju niskih protoka, (b) protok čije vrijednosti se nalaze u rasponu od 300 do 1050 m<sup>3</sup>/s, što predstavlja kategoriju srednjih protoka, (c) protoke između 1050 i 1500 m<sup>3</sup>/s koji predstavljaju kategoriju visokih protoka, te (d) između 1500 i 1900 m<sup>3</sup>/s, koji predstavljaju najekstremnije visoke vrijednosti protoka, točnije jedan događaj.



(a)

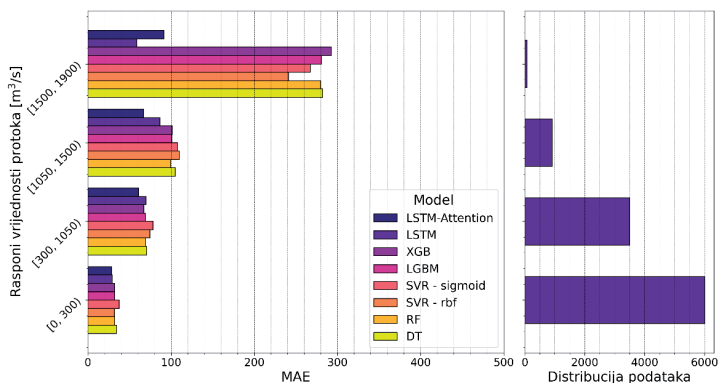


(b)

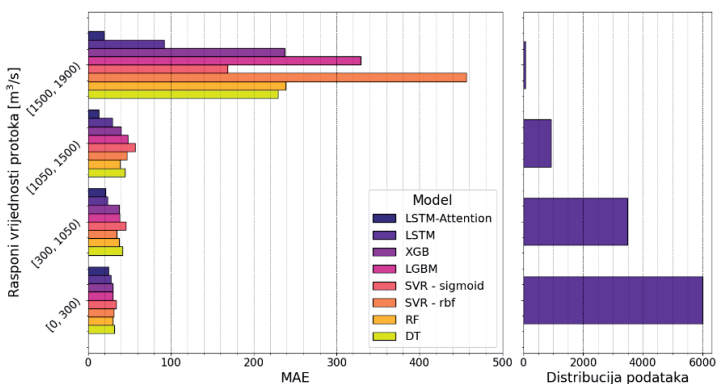
**Slika 2:** Predviđene naspram stvarne vrijednosti: (a) Mjereni podatci i (b) Simulirani podatci [22]

Većina podataka nalazi se u kategoriji niskih protoka, točnije oko 60% podataka, i za ovu kategoriju uočena su najmanja odstupanja kada je riječ o pogrešci procjene modela. Srednja kategorija protoka koja čini drugu najzastupljeniju kategoriju podataka, s oko 30%, pokazuje veća odstupanja između rezultata mjerenih i simuliranih podataka, sa simuliranim podacima gdje su uočena odstupanja veća i od  $20 \text{ m}^3/\text{s}$ . Najveće razlike u performansama očite su za visoke i najekstremnije vrijednosti protoka, gdje su modeli temeljeni na rekurzivnim mrežama pokazali značajno manju pogrešku procjene u odnosu na jednostavne modele strojnog učenja. Predloženi LSTM-Attention model pokazao se kao najbolje rješenje u gotovo svim kategorijama i setovima podataka, s iznimkom kategorije ekstremno visokih protoka u mjerenom skupu podataka.

Slika 4 prikazuje analizu doprinosa ulaznih značajki. Za jednostavnije modele analiza je provedena primjenom SHAP metode, pri čemu su kao primjer prikazani rezultati XGB modela. Za predloženi hibridni model LSTM-Attention primijenjena je metoda ciljanog izostavljanja značajki. Budući da je cilj istraživanja procjena protoka na lokaciji Metković, iz prikazanih vizualizacija jasno je vidljivo da razina vodostaja na lokaciji Metković ima najveći utjecaj na rezultate modela. Nakon toga slijedi lokacija Ušće, dok preostale stanice, Opuzen i Kula Norinska, imaju manji, ali i dalje značajan utjecaj.



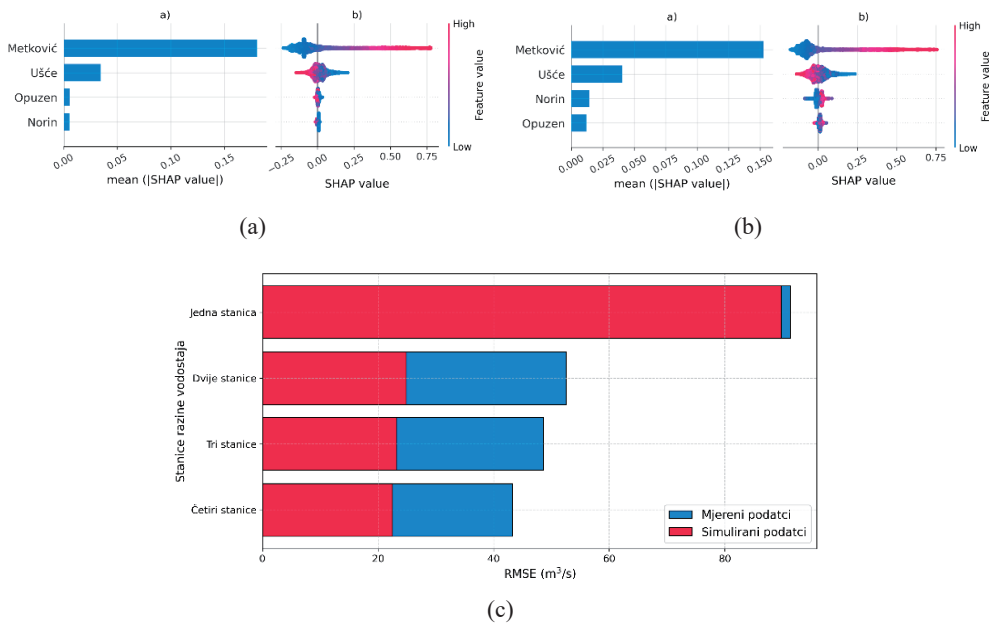
(a)



(b)

**Slika 3:** Pogreška procjene protoka modela prema različitim rasponima vrijednosti protoka, uz prikaz distribucije podataka za: (a) Mjereni skup podataka i (b) Simulirani skup podataka [22]

Analiza rezultata pokazala je da predloženi hibridni model pruža najbolje rezultate procjene protoka u gotovo svim scenarijama, od niskih do visokih protoka, kroz sva godišnja doba, te za skup mjerenih i simuliranih podataka. Konzistentnost najboljih rezultata bila je vidljiva kroz sve kategorije protoka, što znači da se model pokazao pouzdanim čak i kada postoji problem neuravnoteženosti distribucije podataka, te da je primjenjiv u stvarnim uvjetima ekstremnih sušnih i vodnih prilika.




**Slika 4:** Analiza doprinosa značajki putem SHAP metode za jednostavnije modele strojnog učenja (a) XGB rezultat za simulirani skup podataka, (b) XGB rezultat za mjereni skup podataka, te (c) metode ciljanog izostavljanja značajki za modele temeljene na rekurzivnoj neuronskoj mreži za oba skupa podataka [22]

## 4.2 Procjena protoka uz primjenu metode obrade signala

U nastavku istraživanja analizirana su dva modela koja su, prema mjerama pogreške, pokazala najmanje pogreške procjene. Daljnja analiza uključivala je primjenu metoda obrade signala na mjerenim podacima, konkretno varijacijske dekompozicije modova (VMD). Prvi korak sastojao se od dekompozicije signala razine vodostaja u modne funkcije. U tu svrhu istraženi su parametri VMD dekompozicije poput broja modnih funkcija i kvadratnog penalizacijskog parametra. Odabir VMD parametara zasnivao se na pronalasku najmanjeg broja modnih funkcija koji omogućuje dekompoziciju signala u osnovne kategorije plimnih komponenti, ali i kvadratnom penalizacijskom parametru gdje je najmanje prisutno spektralno curenje. Ovaj korak rezultirao je odabirom pet modnih funkcija i kvadratnom penalizacijskom parametru jednakom 5000.

Dobivene modne funkcije svih stanica razina vodostaja klasificirane su u kategorije, dugoperiodne, dnevne, poludnevne, više harmonike i rezidualni signal. Rezidualni signal uz dodatnu dekompoziciju i dalje je ostao jak sadržavajući i poludnevne i dnevne komponente signala, stoga je on pribrojen komponenti viših harmonika, čineći jednu kategoriju koja se referira kao rezidualni miješani signal. Primjer dekompozicije signala razine vodostaja za stanicu Metković prikazan je na Slici 5.



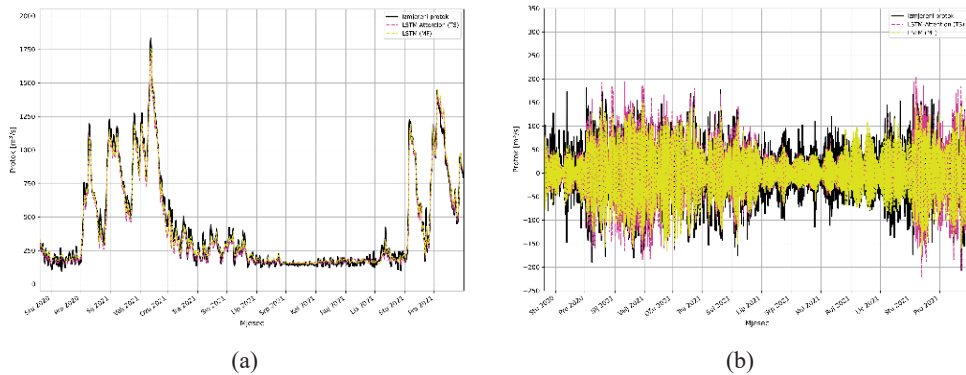
Slika 5: Rezultat dekompozicije signala u plimne komponente za lokaciju Metković [11]

Usporedba rezultata mjera pogreške za različite formate ulaznih podataka prikazana je u Tablici 2. Za format vremenskih serija predloženi hibridni model pokazuje bolje performanse, dok kod korištenja dekomponiranih i klasificiranih plimnih komponenti, samostalni LSTM ostvaruje poboljšanje svih mjera pogreške. Konkretno, samostalni LSTM smanjio je pogrešku procjene za 13,7% RMSE, 12,6% MAE, te 0,2% za NSE u usporedbi s LSTM-Attention modelom treniranim na vremenskim nizovima. Dobiveni rezultati upućuju na činjenicu kako vremenski nizovi rezultiraju manjom pogreškom procjene protoka u Metkoviću, dok jednostavniji modeli poput samostalnog LSTM-a zahtijevaju dodatnu obradu podataka kako bi postigli bolju točnost od predložene hibridne arhitekture.

Tablica 2: Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skupove podataka u formatu vremenskih serija i dekomponiranih signala kategoriziranih u plimne komponente (podebljan je rezultat najboljeg modela zasebno za različiti format ulaznih podataka) [11]

Format ulaznih podataka	Model strojnog učenja	RMSE m <sup>3</sup> /s	MAE m <sup>3</sup> /s	NSE	R
Vremenske serije	LSTM	63,495	47,821	0,969	0,988
	<b>LSTM-Attention</b>	<b>57,406</b>	<b>43,201</b>	<b>0,974</b>	<b>0,989</b>
Plimne komponente	<b>LSTM</b>	<b>49,533</b>	<b>37,776</b>	<b>0,981</b>	<b>0,991</b>
	LSTM-Attention	58,524	43,564	0,973	0,990

Dekompozicija signala protoka u unutardnevne oscilacije (uzrokovane protokom) i međudnevne oscilacije (uzrokovane plimom i osekom) primjenom Butterworthovog filtera na signalu protoka (Slika 6), pružila je dodatni uvid u performanse modela. Međudnevne oscilacije adekvatno su procijenjene putem LSTM-Attention modela treniranog na vremenskim serijama, te u ovom slučaju dekompozicija nije dodatno doprinijela poboljšanju performansi modela već stagnaciju. Suprotan trend uočen je kod samostalnog LSTM modela, čije su procjene bliže stvarnim vrijednostima na dekomponiranim signalima. Međutim, značajnih razlika između ova dva modela nema, stoga u slučaju međudnevnih oscilacija hibridna arhitektura predstavlja dovoljno dobro rješenje. Situacija se mijenja kada se promatraju unutardnevne oscilacije gdje su poboljšanja performansi oba modela uočena nakon dekompozicije signala. Zaključno, predložena hibridna arhitektura predstavlja bolju opciju kada su dostupne sirove vremenske serije, dok samostalni LSTM značajnije prednjači poboljšanju performansi kada je riječ o međudnevnim oscilacijama.



**Slika 6:** Usporedba rezultata samostalnog LSTM modela i predložene hibridne arhitekture, LSTM-Attention, na dekomponirani signal protoka u Metkoviću podijeljen na unutardnevne i međudnevne oscilacije, gdje (a) prikazuje rezultate dva najbolja modela za unutardnevne, dok (b) prikazuje rezultate dva najbolja modela za međudnevne oscilacije [11]

### 4.3 Predviđanje protoka

Problem predviđanja protoka do 12 sati unaprijed temeljio se na korištenju ulazne vremenske serije u trajanju od 24 sata, koja je uključivala podatke o vodostaju s četiri lokacije te protoku s jedne lokacije (navedene stanice su prethodno prikazane na Slici 1). Navedeni podatci korišteni su kao ulaz u tri različita formata: prvi u izvornom obliku vremenskih serija, drugi u formatu spektrograma, odnosno dvodimenzionalnih matrica, te treći kao kombinacija vremenskih serija i spektrograma.

**Tablica 3:** Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skupove podatka u formatu vremenskih serija i dekomponiranih signala kategoriziranih u plimne komponente (podebljan je rezultat najboljeg modela) [32]

Horizont predviđanja	Format ulaznih podataka	RMSE (m <sup>3</sup> /s)	MAPE (%)	NSE
1	Vremenske serije	27,67	8,652	0,988
	<b>Spektrogram</b>	<b>17,696</b>	<b>3,378</b>	<b>0,995</b>
	Vremenske serije i spektrogram	19,309	5,293	0,994
6	Vremenske serije	59,229	14,013	0,943
	<b>Spektrogram</b>	<b>54,406</b>	<b>11,766</b>	<b>0,952</b>
	Vremenske serije i spektrogram	56,603	13,223	0,948
12	Vremenske serije	73,531	16,172	0,915
	<b>Spektrogram</b>	<b>68,532</b>	<b>14,187</b>	<b>0,924</b>
	Vremenske serije i spektrogram	69,523	15,051	0,922


Rezultati provedene studije prikazani su u tabličnom obliku putem mjera pogreške za različite horizonte predviđanja u Tablici 3. Uvođenje vremensko-frekvencijske domene, bilo kao samostalnog formata ulaza ili u kombinaciji s vremenskim serijama, rezultiralo je manjim razlikama u pogreškama predviđanja za područja rijeka pod utjecajem uspora mora. Najveće razlike u performansama između tri formata ulaznih podataka za CNN-LSTM uočene su za prvi sat predviđanja u slučaju vremenskih serija, dok se razlike u pogreškama predviđanja postupno smanjuju s povećanjem horizonta predviđanja.

Provedeno istraživanje dovelo je do zaključka da razmatranje dodatne frekvencijske domene, uz vremensku, pozitivno utječe na rezultate hibridnog modela CNN-LSTM. Iako se razlika između različitih formata ulaznih podataka s produljenjem vremena smanjila, što je bilo očekivano, otvorila se mogućnost budućih istraživanja u pogledu ulaznih podataka koji prethodno nisu bili razmatrani za istraženi tip problema.

#### 4.4 Predviđanje vodostaja

U svrhu predviđanja vodostaja do 24 sata unaprijed korištena je ista hibridna arhitektura modela kao i za problem predviđanja protoka, uz iznimku ulaznih podataka. Osnovni skup podataka, koji sadrži satne izmjere razine vodostaja te protoka, proširen je primjenom metode inženjerstva značajki. Dodatne značajke uključivale su

dnevne, prosječne dnevne i 24-satne pomične prosjeke vrijednosti razine vodostaja i protoka, kao i skup vremenski ovisnih obilježja, uključujući brojne vremenske intervale, počevši od sata, dnevnih razdoblja kao što je jutro, popodne i večer, pa sve do godišnjih doba, mjeseca i godine. Ovisnost značajki o razini vodostaja Metkoviću analizirana je primjenom metode uzajamne informacije, kao što je prikazano na Slici 7. Najmanji utjecaj na razinu vodostaja u Metkoviću imala su dnevna razdoblja, dok su najveći utjecaj imali izvorni sati te dnevne vrijednosti razina vodostaja i protoka.



**Slika 7:** Analiza doprinosa značajki proširenog skupa podataka (RV predstavlja razinu vodostaja, P protok, \* prosječne dnevne vrijednosti, \*\* 24-satne pomične prosjeke) [33]

Rezultati modela (Tablica 4) koji koristi različite formate ulaznih podataka pokazali su se konzistentnima za sve horizonte predviđanja, osim za prvi sat. Naime, prema RMSE, MAE i NSE mjerama pogreške, najbolje rezultate za predviđanja razine vodostaja u Metkoviću u prvom satu dale su vremenske serije, a zatim spektrogrami. Za horizonte predviđanja od dva sata do 24 sata unaprijed prvim najboljim rješenjem pokazao se scenarij u kojem je osnovni skup podataka proširen metodom inženjerstva značajki, nakon čega slijedi osnovni niz vremenskih serija i spektrogrami. Najlošije rezultate tim horizontima, dao je skup podataka koji sadrži spektrograme proširene metodom inženjerstva značajki.

**Tablica 4:** Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skupove podataka u formatu vremenskih serija i dekomponiranih signala kategoriziranih u plimne komponente (podebljan je rezultat najboljeg modela koji koristi određeni format ulaznih podataka) [33]

Horizont predviđanja	Format ulaznih podataka	RMSE (m <sup>3</sup> /s)	MAE (m <sup>3</sup> /s)	NSE
1	<b>Vremenske serije</b>	<b>0,026</b>	<b>0,021</b>	<b>0,994</b>
	Vremenske serije s inženjerstvom značajki	0,055	0,040	0,975
	Spektrogram	0,033	0,024	0,991
	Spektrogram s inženjerstvom značajki	0,081	0,060	0,946
12	Vremenske serije	0,096	0,062	0,925
	<b>Vremenske serije s inženjerstvom značajki</b>	<b>0,080</b>	<b>0,052</b>	<b>0,947</b>
	Spektrogram	0,095	0,056	0,926
	Spektrogram s inženjerstvom značajki	0,112	0,092	0,896
24	Vremenske serije	0,100	0,070	0,919
	<b>Vremenske serije s inženjerstvom značajki</b>	<b>0,093</b>	<b>0,064</b>	<b>0,928</b>
	Spektrogram	0,100	0,069	0,919
	Spektrogram s inženjerstvom značajki	0,115	0,080	0,892

U stvarnom svijetu veći značaj se pridaje duljim predviđanja kako bi se osigurale pravovremene reakcije i zaštita područja, pa se fokus stavlja upravo na takve situacije. Istraživanje je pokazalo da proširenjem postojećeg skupa podataka izvornih vremenskih serija s metodom inženjerstva značajki doprinosi poboljšanju performansi postojećeg hibridnog modela CNN-LSTM.

## 5. Zaključak

Provedeno istraživanje pokazalo je učinkovitost primjene hibridnog pristupa strojnog učenja za procjenu protoka iz mjerenih vodostaja na više lokacija, u odnosu na samostalne modele strojnog učenja. Dekompozicija signala omogućuje postizanje zadovoljavajućih performansi i primjenom samostalnih modela, poput LSTM-a, uz točnost usporedivu s hibridnim modelima, osobito u analizi unutardnevnih oscilacija protoka. Inženjerstvo značajki pozitivno je unaprijedio performanse modela, među-

tim samo u scenariju gdje se koriste vremenske serije. Uključivanje dodatnih prikaza signala, poput spektrograma uz vremenske serije, može dodatno smanjiti pogrešku procjene modela. Zaključno, provedeno istraživanje ukazuje na mogućnost primjene hibridnih modela strojnog učenja za kontinuirano praćenje i procjenu protoka, koji inače zahtijevaju instalaciju i održavanje skupih mjernih uređaja, poput akustičnih strujomjera. Takvi pristupi pokazuju velik potencijal za praktičnu primjenu, uključujući unapređenje sustava ranog upozorenja na poplave, optimizaciju upravljanja sustavima navodnjavanja te pružanje potpore procesima donošenja odluka u kontekstu upravljanja vodnim resursima i prilagodbe klimatskim promjenama.

## 6. Literatura

- [1] Phan, T.-T.-H.; Nguyen, X. H.: Combining statistical machine learning models with ARIMA for water level forecasting: The case of the Red River, *Advances in Water Resources*, **142** (2020) 103656, <https://doi.org/10.1016/j.advwatres.2020.103656>
- [2] Orton, P. M.; Conticello, F. R., Cioffi, F., Hall, T. M., Georgas, N., Lall, U., Blumberg, A. F., MacManus, K.: Flood hazard assessment from storm tides, rain and sea level rise for a tidal river estuary, *Natural hazards*, **102** (2020) 2, 729-757, <https://doi.org/10.1007/s11069-018-3251-x>
- [3] Chen, K.; Kuang, C., Wang, L., Chen, K., Han, X., Fan, J.: Storm surge prediction based on long short-term memory neural network in the east China sea, *Applied Sciences*, **12** (2022) 1, 181, <https://dx.doi.org/10.3390/app12010181>
- [4] Renaud, F.G.; Syvitski, J.P., Sebesvari, Z., Werners, S.E., Kremer, H., Kuenzer, C., Friedrich, J.: Tipping from the Holocene to the Anthropocene: How threatened are major world deltas?, *Current Opinion in Environmental Sustainability*, **5** (2013) 6, 644-654, <https://doi.org/10.1016/j.cosust.2013.11.007>
- [5] Bilskie, M. V.; Hagen, S. C., Medeiros, S. C., Passeri, F. L.: Dynamics of sea level rise and coastal flooding on a changing landscape, *Geophysical Research Letters*, **41** (2014) 3, 927-934, <https://doi.org/10.1002/2013GL058759>
- [6] Vercruyssen, K.; Grabowski, R.: Human impact on river planform within the context of multi-timescale river channel dynamics in a himalayan river system, *Geomorphology*, **381** (2021) 107659, <https://doi.org/10.1016/j.geomorph.2021.107659>
- [7] Wee, W. J.; Zaini, N. B., Ahmed, A. N., El-Shafie, A.: A review of models for water level forecasting based on machine learning, *Earth Science Informatics*, **14** (2021) 4, 1707-1728, <https://doi.org/10.1007/s12145-021-00664-9>
- [8] Ibrahim, K. S. M. H.; Huang, Y. F., Ahmed, A. N., Koo, C. H., El-Shafie, A.: A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting, *Alexandria Engineering Journal*, **61** (2022) 1, 279-303, <https://doi.org/10.1016/j.aej.2021.04.100>
- [9] Ng, K.; Huang, Y., Koo, C., Chong, K., El-Shafie, A., Najah Ahmed, A.: A review of hybrid deep learning applications for streamflow forecasting, *Journal of Hydrology*, **625** (2023) 130141, <http://dx.doi.org/10.1016/j.jhydrol.2023.130141>

- [10] Mihel, A. M.; Lerga, J., Krvavica, N.: Estimating water levels and discharges in tidal rivers and estuaries: Review of machine learning approaches, *Environmental modelling & software*, **176** (2024) 106033, <https://doi.org/10.1016/j.envsoft.2024.106033>
- [11] Mihel, A. M.: Estimation and prediction of discharges in tidal rivers and estuaries using machine learning, *Dostupan na*: <https://dabar.srce.hr/object/riteh:5401>, *Pristupljeno*: 2025-12-18
- [12] Habib, E. H.; Meselhe, E. A.: Stage-Discharge Relations for Low-Gradient Tidal Streams Using Data-Driven Models, *Journal of Hydraulic Engineering*, **132** (2006) 5, 482-492, [https://doi.org/10.1061/\(ASCE\)0733-9429\(2006\)132:5\(482\)](https://doi.org/10.1061/(ASCE)0733-9429(2006)132:5(482))
- [13] Vu, M.; Jardani, A., Krimissa, M., Zaoui, F., Massei, N.: Large-scale seasonal forecasts of river discharge by coupling local and global datasets with a stacked neural network: Case for the Loire River system, *Science of the Total Environment*, **879** (2023) 165494, <https://doi.org/10.1016/j.scitotenv.2023.165494>
- [14] Chen, Z.; Zong, Y., Wu, Z., Kuang, Z., Wang, S.: Prediction of discharge in a tidal river using the LSTM-based sequence-to-sequence models, *Acta Oceanologica Sinica*, **43** (2024) 7, 40-51, <https://doi.org/10.1007/s13131-024-2343-6>
- [15] Li, Y.; Zhao, X., Wang, Y., Zeng, L.: Deep characteristic learning model for real-time flow monitoring based on H-ADCP, *Journal of Hydrology: Regional Studies*, **57** (2025) 102115, <https://doi.org/10.1016/j.ejrh.2024.102115>
- [16] Supharatid, S.: Tidal-level forecasting and filtering by neural network model, *Coastal Engineering Journal*, **45** (2003) 1, 119-137, <https://doi.org/10.1142/S0578563403000695>
- [17] Jung, S.; Cho, H., Kim, J., Lee, G.: Prediction of water level in a tidal river using a deep-learning based LSTM model, *Journal of Korea Water Resources Association*, **51** (2018) 12, 1207-1216, <https://doi.org/10.3741/JKWRA.2018.51.12.1207>
- [18] Gao, S.; Feng, X., Xu, H., Wu, Y., Feng, W.: A hybrid deep learning model based on emd algorithm for non-stationary water level prediction of estuarine systems, *Estuarine, Coastal and Shelf Science*, **314** (2025) 109128, <https://doi.org/10.1016/j.ecss.2025.109128>
- [19] Shi, X.; Chen, P., Ye, Z., Zhang, X., Wang, W.: Tide level prediction during typhoons based on variable topology in graph convolution recurrent neural networks, *Ocean Engineering*, **312** (2024) 119228, <https://doi.org/10.1016/j.oceaneng.2024.119228>
- [20] Cremer, C. J. M.; Mariegaard, J. S., Andersson, H. J.: A hybrid data assimilation and machine learning approach for enhancing operational forecasting in 2D hydrodynamic models, *Journal of Hydroinformatics*, **27** (2025) 3, 493-507, <https://doi.org/10.2166/hydro.2025.289>
- [21] Zhang, Z.; Zhang, L., Yue, S., Wu, J., Guo, F.: Correction of nonstationary tidal prediction using deep-learning neural network models in tidal estuaries and rivers, *Journal of Hydrology*, **62** (2023) 129686, <https://doi.org/10.1016/j.jhydrol.2023.129686>
- [22] Mihel, A. M.; Krvavica, N., Lerga, J.: Regression-based machine learning approaches for estimating discharge from water levels in microtidal rivers, *Journal of Hydrology*, **646** (2025) 132276, <https://doi.org/10.1016/j.jhydrol.2024.132276>
- [23] Krvavica, N.; Ružić, I.: Assessment of sea-level rise impacts on salt-wedge intrusion in idealized and Neretva River Estuary, *Estuarine, Coastal and Shelf Science*, **234** (2020) 106638, <https://doi.org/10.1016/j.ecss.2020.106638>

- [24] Krvavica, N.; Gržić, M. M., Innocenti, S., Matte, P.: Impact of storm surge and power peaking on tidal-fluvial processes in microtidal Neretva River estuary, *Estuarine, Coastal and Shelf Science*, **234** (2025) 109227, <https://doi.org/10.1016/j.ecss.2025.109227>
- [25] Krvavica, N.; Lončar, G., Oskoruš, D., Ružić, I.: A contribution to improving the system of transitional waters' hydrological measurements: Hydraulic and spectral analyses of the Neretva River flow rate, *Dostupan na*: <https://hrcak.srce.hr/274289>, *Pristupljeno*: 2025-12-16
- [26] Lee, M.; Yoo, Y., Joo, H., Kim, K. T., Kim, H. S., Kim, S.: Construction of rating curve at high water level considering rainfall effect in a tidal river, *Journal of Hydrology: Regional Studies*, **37** (2021) 100907, <https://doi.org/10.1016/j.ejrh.2021.100907>
- [27] Krvavica, N.; Kožar, I., Travaš, V., Ožanić, N.: Numerical modelling of two-layer shallow water flow in microtidal salt-wedge estuaries: Finite volume solver and field validation, *Journal of Hydrology and Hydromechanics*, **65** (2017) 1, 49-59, <https://doi.org/10.1515/johh-2016-0039>
- [28] Mihel, A. M.; Krvavica, N., Lerga, J., Oskoruš, D.: Primjena umjetne inteligencije u procjeni hidroloških parametara priobalnih rijeka, 8. *Hrvatska konferencija o vodama*, Biondić, D., Holjević, D., Vizner, M., 205-212, 978-953-7672-29-4, Poreč, Hrvatska, Studeni 2023, HRVATSKE VODE, Zagreb, Hrvatska (2023)
- [29] Dragomiretskiy, K.; Zosso, D.: Variational mode decomposition, *IEEE Transactions on Signal Processing*, **62** (2014) 3, 531-544, <https://doi.org/10.1109/TSP.2013.2288675>
- [30] Rodriguez, J. D. M; Perez, A., Lozano, J. A.: Sensitivity analysis of k-fold cross validation in prediction error estimation, *IEEE transactions on pattern analysis and machine intelligence*, **32** (2009) 3, 569-575, <https://doi.org/10.1109/TPAMI.2009.187>
- [31] Villeneuve, Y.; Sguin, S., Chehri, A.: AI-Based Scheduling Models, Optimization, and Prediction for Hydropower Generation: Opportunities, Issues, and Future Directions, *Energies*, **16** (2023) 8, 3335, <https://doi.org/10.3390/en16083335>
- [32] Mihel, A. M.; Lenac, K., Krvavica, N., Lerga, J.: Discharge Forecasting in Coastal Rivers Using CNN-LSTM Hybrid Approach, *2023 International Symposium ELMAR*, Muštra, M., Vuković, J., Božek, J., 55-60, 979-8-3503-2513-3, Zadar, Hrvatska, Rujan 2023., IEEE, Zadar, Hrvatska (2023)
- [33] Mihel, A. M.; Pečnik, Š., Vrbančić, G., Lerga, J., Krvavica, N.: Employing Feature Engineering for River Stage Forecasting to Improve Hybrid Model Performance, *2024 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, Begušić, D., Radić, J., Šarić, M., 1-6, 979-8-3503-5461-4, Bol, Brač, Hrvatska, Rujan 2024., IEEE, Split, Hrvatska (2024)

## Zahvala

Ovaj je rad sufinanciran sredstvima Europske unije iz programa NextGenerationEU kroz projekte Sveučilišta u Rijeci pod brojem uniri-mzi-25-1 i uniri-iz-25-86, Hrvatske zaklade za znanost u okviru projekta IP-2022-10-7598 te EU Horizon projekta „INNO2MARE“ broj 101087348.