

Primljen / Received: 15.10.2019.

Ispravljen / Corrected: 22.1.2020.

Prihvaćen / Accepted: 15.3.2020.

Dostupno online / Available online: 10.4.2021.

Procjena troškova za integralne mostove primjenom umjetne inteligencije

Autori:

Mr.sc. **Željka Beljkaš**, dipl.ing.građ.

Sveučilište Crne Gore

Građevinski fakultet

zeljka@ucg.ac.me

Autor za korespondenciju

Prof.dr.sc. **Miloš Knežević**, dipl.ing.građ.

Sveučilište Crne Gore

Građevinski fakultet

milosknezevic@hotmail.com

Pregledni rad

Željka Beljkaš, Miloš Knežević

Procjena troškova za integralne mostove primjenom umjetne inteligencije

Procjena troškova u svakoj fazi realizacije projekata u građevinarstvu je važna. Ipak, utjecaj procjene je najveći u ranim fazama jer se tada opredjeljuje o prihvaćanju posla ili odustajanju. Rane faze realizacije projekata oskudijevaju s količinom potrebnih podataka u odnosu na sve sljedeće faze što utječe na preciznost procjene troškova u ranim fazama. U radu je prikazano istraživanje u kojem se upotrebom umjetne inteligencije izvršila procjena troškova pri izgradnji integralnih cestovnih mostova. Model za procjenu izrađen je uz pomoć neuronskih mreža. Najbolji model neuronskih mreža pokazao je visoku točnost pri procjeni troškova na osnovi srednje apsolutne pogreške, koja iznosi 13,40 %.

Ključne riječi:

integralni cestovni mostovi, procjena troškova, umjetna inteligencija, neuronske mreže

Subject review

Željka Beljkaš, Miloš Knežević

Use of artificial intelligence for estimating cost of integral bridges

Estimation of costs is important in every phase of realisation of construction projects. However, the influence of cost estimation is the highest in early phases as it is then that the decision about accepting the job or withdrawing from the project is made. The quantity of data available in initial phases of the project is smaller compared to subsequent phases, which affects accuracy of cost estimation in such early phases. A research making use of artificial intelligence to estimate construction costs of integral road bridges is presented in the paper. The estimation model is prepared by means of neural networks. The best neural network model has proven to be highly accurate in the estimation of costs based on the mean absolute error, which amounts to 13.40 %.

Key words:

integral road bridges, cost estimation, artificial intelligence, neural networks

Übersichtsarbeit

Željka Beljkaš, Miloš Knežević

Kostenschätzung für integrale Brücken unter Verwendung künstlicher Intelligenz

Es ist wichtig, die Kosten in jeder Phase der Projektumsetzung im Bauwesen abzuschätzen. Die Auswirkungen der Schätzung sind jedoch in den frühen Phasen am größten, da dann entschieden wird, den Auftrag anzunehmen oder davon abzusehen. In den frühen Phasen der Projektumsetzung fehlt die für alle nachfolgenden Phasen erforderliche Datenmenge, was sich auf die Genauigkeit der Kostenschätzungen in den frühen Phasen auswirkt. Die Arbeit präsentiert eine Studie, bei der mithilfe künstlicher Intelligenz die Kosten für den Bau integraler Straßenbrücken abgeschätzt wurden. Das Schätzmodell wurde unter Verwendung neuronaler Netze entwickelt. Das beste neuronale Netzwerkmodell zeigte eine hohe Genauigkeit bei der Schätzung der Kosten basierend auf dem mittleren absoluten Fehler von 13,40 %.

Schlüsselwörter:


Integrale Straßenbrücken, Kostenschätzung, künstliche Intelligenz, neuronale Netze

1. Uvod

Građevinarstvo je kompleksna industrijska djelatnost. Kompleksnost građevinarstva se vidi u jedinstvenosti svakog projekta. Osim toga, ova industrijska djelatnost je takva i zbog činjenice da u realizaciji projekata sudjeluje velik broj osoba. Sudionici u realizaciji građevinskih projekata su: investitor, konzultant, projektant, stručni nadzor, izvođač radova i zainteresirane strane. Inicijativu za ulazak u proces realizacije projekata pokreće investitor, što ga određuje da ima vodeću ulogu u tom procesu. Izvođač ima značajnu ulogu u realizaciji projekata, odmah nakon investitora. On predstavlja izravnog izvršitelja gradnje. Investitor je odgovoran za odabir izvođača. Investitor odabire izvođača na temelju određenih kriterija. Ti su kriteriji često teško dostupni i općenito podrazumijevaju realizaciju projekta uz najmanje novca, najkraće vrijeme i najvišu kvalitetu.

Procjenu troškova, svaki za sebe, rade i investitor i izvođač radova. O procjeni troškova ovise idući koraci u procjeni posla. Ponekad procjene troškova dovode i do situacije da se odustaje od realizacije određenog projekta.

Kvaliteta i pouzdanost procjene u smislu zadovoljavajuće točnosti ovise o nizu čimbenika. Neki od tih čimbenika su dostupnost, kvaliteta i razina detalja tehničke dokumentacije, način na koji je izvršena procjena, kao i stručnjaci koji provode postupak procjene. Dostupnost potrebnih podataka s napretkom realizacije projekta je sve veća, pa je točnost procjene također veća. Prema Barnesu (1974.), pouzdanost procjene troškova prikazana je na slici 1. [1].



Slika 1. Pouzdanost procjene troškova prema Barnesu [1]

Najčešće, osnovni kriterij, često i jedini, jest cijena koju izvođač nudi za realizaciju projekta. U tim je slučajevima odabir izvođača jednostavan. Izvođač čija je cijena u ponudi najniža, ulazi u posao realizacije projekta. Odabirom izvođača radova na takav način, postavlja se pitanje hoće li investitor angažirati tvrtku koja će na očekivan, ili barem zadovoljavajući način, izvesti projekt do kraja (kvaliteta i vrijeme).

Procjena troškova izvođenja građevinskih projekata u ovom istraživanju temelji se na vrijednostima uzetim iz troškovnika iz projektne dokumentacije, a na temelju kojih je ugovoreno izvođenje radova. Izvođač obično radi dvije vrste procjene: konceptualnu (grubu) i preliminaranu (detaljnu) [2].

Konceptualna procjena uključuje opravdanost za daljnje faze provedbe projekta. Rezultat te procjene je ukupni iznos bez detaljne analize strukture troškova. Preliminarna procjena rezultira detaljnom ponudom koja daje analizu strukture troškova. Sve se vrste procjena izrađuju na temelju raspoložive dokumentacije koju osigurava investitor (natječajna dokumentacija). S obzirom na to da u početnoj fazi imamo najmanji broj dostupnih ulaznih podataka, konceptualna procjena je prilično gruba. Iz toga proizilazi pitanje o zadovoljavajućoj ili zahtijevanoj točnosti procjene. Prema nekim istraživanjima, točnost procjene u ranim fazama izvedbe projekta obično je između $\pm 25\%$ i $\pm 50\%$ [3-5] ili između 13% i 31% [6]. Osim tih istraživanja postoje i istraživanja koja pokazuju da je točnost procjene u ranim fazama realizacije projekata između $\pm 15\%$ i $\pm 20\%$ [7]. Za potrebe ovog istraživanja usvojena je razina točnosti $\pm 15\%$.

2. Primjena umjetnih neuronskih mreža u građevinarstvu

Primjena jedne od tehnika umjetne inteligencije, tehnike neuronskih mreža, u građevinarstvu vrlo je široka jer se mogu primijeniti u svim fazama realizacije projekta. U časopisu *Microcomputers in Civil Engineering* objavljen 1989. godine rad o primjeni neuronskih mreža na ovom polju [8]. S razvojem računalnih programa neuronske se mreže sve više koriste u građevinarstvu.

Uz pomoć neuronskih mreža mogu se obavljati različite vrste procjena. Jedna od procjena koja se može postići njihovom primjenom jest procjena troškova izgradnje. Često se to radi uz pomoć ove tehnike, na što upućuje veliki broj radova na tu temu (procjena troškova izgradnje stambenih i/ili stambenoposlovnih zgrada [9], procjena troškova sanacije mostova [10], procjena troškova izgradnje hidroelektrana [11], procjena troškova izgradnje vodovodnih i kanalizacijskih mreža [12], itd.). U literaturi postoje brojni radovi koji prikazuju rezultate primjene neuronskih mreža u području građevinarstva.

Uz pomoć neuronskih mreža autori su izradili model za parametarsku procjenu troškova izgradnje autocesta [13]. Na temelju ankete određenog broja voditelja projekata koji su koristili neuronske mreže, utvrđeni su parametri koji utječu na promjenu ukupnih troškova izgradnje cesta [14]. Procjena troškova izgradnje autocesta pomoću neuronskih mreža prikazana je u nekim istraživanjima. Sodikov je u svom radu [5] bio fokusiran na razvoj modela preciznosti predviđanja u području izgradnje autocesta u razvijenim zemljama u početnim fazama projekta. Za istraživanje je korištena baza podataka ROCKS (baza podataka Svjetske banke - Road Costs Knowledge System). Ona sadrži podatke o izgradnji cesta iz 65 zemalja. Najveći broj projekata iz svih zemalja, realiziran je u Poljskoj i Tajlandu, pa su analiza i oblikovanje modela rađeni na osnovi podataka iz tih zemalja. U Poljskoj je provedeno ukupno 315 projekata, od kojih je 38 odabrano za analizu prvog modela. Radovi koji su značajni za troškove uzeti su kao ulazne varijable.

Na Tajlandu su provedena 123 projekta, od kojih su 42 odabrana za analizu drugog modela. U ovom se modelu, za razliku od prvog, broj ulaznih varijabli smanjuje na ukupno 3. U oba slučaja je skup podataka, podijeljen u tri dijela, i to: podaci za učenje 60 %, podaci za validaciju 20 % i podaci za ispitivanje (20 %). Evaluacija točnosti modela je provedena primjenom srednje vrijednosti relativne pogreške (eng. *Mean Magnitude of Relative Error* - MMRE). Sodikov je izvršio i procjenu troškova izgradnje koristeći se modelom višestruke regresije. Uspoređujući rezultate dobivene pomoću tih dviju metoda, zaključio je da su u oba slučaja modeli neuronskih mreža imali veću točnost. Za projekte provedene u Poljskoj, točnost je 24 %, a za projekte iz Tajlanda 26 %. Zaključak autora je da se pomoću neuronskih mreža problemi procjene troškova mogu na zadovoljavajući način rješavati u ranim fazama realizacije projekata.

Nekoliko istraživača također se bavilo problemom procjene troškova u ranim fazama projekata. Primjenom metode neuronskih mreža, razvijen je model za procjenu rizika od povećanja troškova u zgradarstvu [15].

Pregled procjene troškova izgradnje autocesta, koristeći se neuronskim mrežama, dali su i neki drugi autori u svom radu [16].

Korištenjem ove tehnike napravljena je i procjena troškova za izgradnju autocesta u Louisiani. Model opisuje ukupne troškove izgradnje u odnosu na indeks troškova izgradnje autoceste [17]. U literaturi se nalazi i rad u kome je predstavljen model predviđanja za procjenu troškova izgradnje stambenih i stambeno-poslovnih zgrada od 4 do 8 katova u Turskoj. Model je prognozirao troškove s točnošću od 93 % [18].

Autori su se također bavili procjenom troškova sanacije mostova. Cilj njihovog istraživanja bio je opisati uočenu štetu na mostovima nakon uragana Katrina i dati opća zapažanja o troškovima popravaka oštećenih mostova. Za procjenu troškova sanacije primijenili su tehniku neuronskih mreža [19].

Procjena troškova izgradnje uređaja za pročišćavanje vode u državi Oklahoma izrađena je pomoću neuronskih mreža [20].

Korištenjem umjetnih neuronskih mreža napravljena je procjena vrijednosti ulaganja u proces obnove željezničkih pruga. Cilj izrade modela bio je poboljšati učinkovitost i djelotvornost odlučivanja o ulaganjima u projekte željezničke infrastrukture. Zaključeno je da je moguće primijeniti model za eventualne grube i brze procjene investicijskih vrijednosti za obnovu željezničkih pruga s pouzdanosću od 80 do 85 % ako nisu poznati svi ulazni parametri [21].

Studija o odstupanju između stvarnih i procijenjenih vrijednosti troškova napravljena je na temelju baze podataka 258 projekata iz područja prometa. Studija je utvrdila da nije samo podcijenjeno 9 od 10 projekata, već da su i stvarni troškovi u prosjeku 28 % viši od procijenjenih. Ipak, najzanimljiviji zaključak te studije je u tome što je postotak podcijenjenih troškova i danas isti kao i posljednjih 70 godina [22].

U literaturi je prikazan model za predviđanje ukupnih troškova izgradnje koji se izrađuje tehnikom linearne regresije. Za izradu modela korištena je baza podataka od 300 projekata.

Ocjenjivanje tog modela provedeno je metodom neuronske mreže. Rezultati su pokazali da je glavna prednost neuronskih mreža njihova sposobnost modeliranja nelinearnosti podataka. Model je pokazao točnost izraženu preko MAPE od 16,6 % [23]. Predviđanje troškova izgradnje zgrada u ranim fazama provedbe projekta, također je bio predmet istraživanja. Baza podataka koja se koristi za definiranje modela sadržavala je podatke iz 71 projekta. Za ulazne varijable su uzeti sljedeći podaci: način temeljenja, površina prizemlja, površina tipskog kata, broj katova, broj dizala, broj prostorija, broj stupova. Model je izrađen pomoću neuronskih mreža i to višeslojnim perceptronom. Konačno, nastao je model čija je točnost izražena preko MAE iznosi 16,6 % [24].

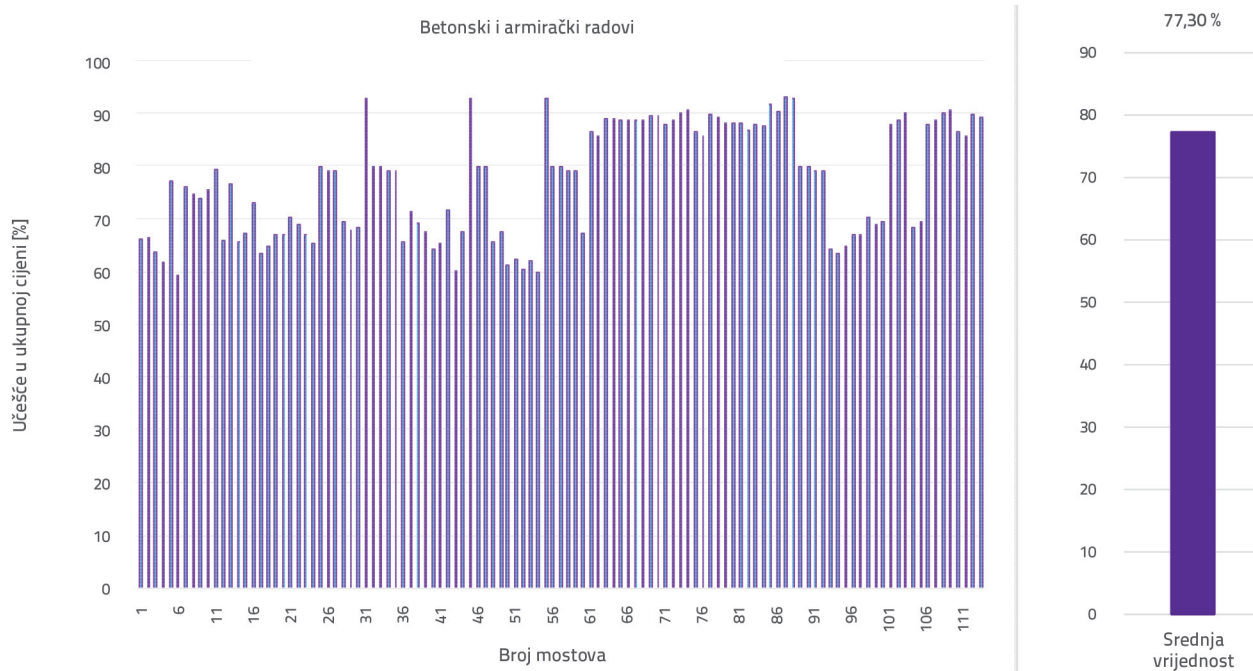
3. Materijali i metode

Za potrebe ovog istraživanja provedeno je prikupljanje i analiza podataka. Nakon toga pripremljeni su podaci za formiranje modela. Na kraju, definiran je konačni model za procjenu troškova izgradnje.

Podaci su prikupljeni iz Glavnih projekata integralnih cestovnih mostova na područjima Crne Gore, Bosne i Hercegovine i Srbije. Naziv integralni mostovi je suvremeni naziv za betonske i spregnute mostove okvirnih konstrukcija bez dilatacija i ležajeva [25]. Treba imati na umu da postoji nekoliko definicija integralnih mostova. Naime, integralnim mostovima nazivaju se jednorasponski okviri bez dilatacija i ležajeva. Takođe, u literaturi možemo pronaći i druge definicije koje govore da su integralni mostovi i mostovi koji predstavljaju kontinuirani okvir bez dilatacija i ležajeva samo iznad srednjih stupova. Projekti čiji su podaci korišteni u ovom istraživanju ili su provedeni, ili su u završnoj fazi provedbe. Sastavni dio tehničke dokumentacije glavnih projekata mostova je dokaznica mjera i troškovnik i iz njega su uzeti svi potrebni podaci. Rasponi tih mostova su od 11,5 do 28 metara, broj raspona je od 1 do 18, dužine mostova bez krilnih zidova iznose 11,5 do 784,4 metra, a visina stupova od 2,8 do 65 metara. Ti su projekti rađeni u razdoblju od 2010. do 2016. godine.

U istraživanje je uvršteno 113 građevina. Pregled je obuhvatio 48 mostova iz Crne Gore, 41 most iz Bosne i Hercegovine i 24 mosta iz Srbije. Kako su građevine izrađene u tri države, projektna dokumentacija nije imala istu formu i sadržaj nego se razlikovala jedna od druge. Faza analize i pripreme podataka zbog toga je bila vrlo zahtjevna. Radi postizanja ujednačenosti, iz svih dokaznica mjera i troškovnika preuzete su samo iste vrste radova. Na ovaj način formirane su dokaznice mjera i troškovnici za sve građevine koje imaju zastupljene iste grupe radova. U dokaznicama mjera i troškovnicima vrste radova dijele se na pripremne, zemljane, betonske, armiračke, prednaprezanje, izolaterske, asfalterske i završne.

Provedena je analiza udjela troška svih vrsta radova u ukupnom iznosu. Analiza je rezultirala utvrđivanjem pozicija radova koje imaju postotno najznačajniji udio u ukupnoj cijeni. To su betonski i armirački radovi, a njihova zastupljenost u ukupnoj cijeni gradnje



Slika 2. Postotni udio betonskih i armiračkih radova u ukupnoj cijeni gradnje

je 77,30 %, što je prikazano na slici 1. Postotak tih dviju vrsta radova u skupinama svih vrsta radova je 25 %. Aproximirajući prethodno dobivene postotne vrijednosti, možemo zaključiti da oko 20 % pozicija radova sudjeluje s oko 80 % u ukupnoj cijeni.

S udjelom betonskih i armiračkih radova u ukupnoj cijeni u rasponu od 70 % do 90 %, postoji 69 projekata, što predstavlja 61,06 % od ukupnog broja analiziranih projekata. Ta činjenica govori da je za 61,06 % projekata udio ukupnih cijena u rasponu od ±10 % u odnosu na 80 %. Uzimajući to u obzir, može se reći da armirački i betonski radovi čine troškovno značajne pozicije radova prema distribuciji Pareto.

Najklasičniji način procjene troškova je primjena jediničnih cijena na prethodno izračunane količine radova [2]. Na ovaj način procijenjeni troškovi zapravo predstavljaju dokaznicu mjera i troškovnik projekta. Dokaznica mjera i troškovnik su sastavni dio projektne dokumentacije koju osigurava investitor, i koja je izvođaču uvijek na raspolaganju prilikom izrade ponude. Međutim, u ranim fazama provedbe projekta, kada je količina ulaznih podataka vrlo ograničena, dokaznica mjera i troškovnik ne mogu se izraditi. To je razlog zašto se traže neke druge metode koje će omogućiti procjenu sa što većom točnošću na temelju dostupnih podataka u trenutku kada se procjena provodi i u kratkom vremenu.

Na temelju identificiranih cjenovno značajnih vrsta radova, utvrđene su projektne karakteristika mostova koje će predstavljati ulazne podatke za procjenu. U tom su smislu odabrane karakteristike koje izravno utječu na troškovno značajne vrste radova, a to su: duljina mosta, širina mosta, visina stupova mosta i raspon mosta. Sve navedene karakteristike mostova uzete su iz Glavnih projekata tih građevina. S obzirom da su se u vezi s visinom stupova razmatrali različiti mostovi,

trebalo je ujednačiti te podatke i svesti ih na jednu vrijednost za svaki most. Iz tog razloga, visina stupova, kao ulazni podatak, označava prosječnu visinu srednjih stupova mosta. Kod jednorasponskih konstrukcija, srednja visina stupova znači srednju vrijednost visine krajnjih stupova. Situacija je slična i s rasponom mosta kao ulaznim parametrom. Ovu veličinu je također trebalo ujednačiti zbog činjenice da nije isto ako imate veći broj manjih raspona ili manji broj većih raspona iste duljine mosta. Zbog te činjenice, raspon mosta, kao ulazni parametar, podrazumijeva srednju vrijednost raspona. U tablici 1. prikazani su ulazni podaci s njihovim graničnim i srednjim vrijednostima. Značajne pozicije radova, s obzirom na ukupne troškove gradnje jesu skele i oplata. Međutim, cijena skele i oplata u procijenjene analize uključena je u pozicije radova koje se odnose na betoniranje određenih elemenata konstrukcije i nisu eksplicitno navedene. Iz tog razloga kroz dokaznice mjera i troškovnike nije bilo moguće analizirati troškove vezane za te pozicije radova. Stoga je uvedena ulazna varijabla koja obuhvaća tehnologiju izgradnje mostova. U projektima koji su analizirani, za rasponsku konstrukciju, korištena je oplata na fiksnoj skeli i oplata na pokretnoj skeli. Radi razumijevanja utjecaja ovih vrsta radova na troškove, uvedena je ulazna varijabla pod nazivom tehnologija građenja. Ta varijabla ima vrijednost "0" u slučaju oplata na fiksnoj skeli, a vrijednost "1" kada je oplata na pokretnoj skeli. Uz navedene karakteristika mosta, za procjenu troškova uvode se i podaci o temeljenju građevine. Troškovi temeljenja ovise o načinu temeljenja. Mostovi čiji su podaci korišteni u ovom istraživanju temeljeni su plitko, duboko ili kombinirano. Kako bi se razmotrio utjecaj troškova povezanih s temeljenjem, uvedena je ulazna varijabla pod nazivom način temeljenja. Vrijednost 0 dodijeljena je varijabli u slučaju plitkog temeljenja,

Tablica 1. Ulazni podaci

Broj ulaznih podataka	Opis ulaznog podatka	Tip podatka	Jed. mjere	Min.	Max.	Srednja vrijednost
Ulaz 1	Duljina mosta	numerički	m	11,50	784,40	153,25
Ulaz 2	Širina mosta	numerički	m	6,50	30,55	11,52
Ulaz 3	Visina stupova	numerički	m	2,80	35,90	13,65
Ulaz 4	Raspon mosta	numerički	m	11,33	44,50	24,07
Ulaz 5	Tehnologija građenja	kategorički (diskretni)	-	0	1	-
Ulaz 6	Način temeljenja	kategorički (diskretni)	-	0	2	-

Tablica 2. Izlazni podaci

Broj izlaznih podataka	Opis izlaznog podatka	Tip podatka	Jed. mjere	Min.	Max.	Srednja vrijednost
Izlaz 1	Ukupni trošak izgradnje	numerički	EUR/m ²	409,63	1752,36	915,97

vrijednost 1 u slučaju dubokog temeljenja, a vrijednost 2 u slučaju kombiniranog temeljenja.

Podaci korišteni za oblikovanje prognostičkog modela trebaju biti međusobno usporedivi. Budući da se radi o procjeni troškova i činjenici da su projekti rađeni u razdoblju od šest godina, bilo je nužno provesti revalorizaciju cijena.

Promjena prosječne bruto plaće i indeks rasta cijena građevnog materijala (cementa i armature) u regiji provjeravani su za razdoblje od 2010. do 2016. kada su izrađeni projekti. Na području Crne Gore u tom su razdoblju uočene promjene bruto plaća. Prosječna bruto plaća u građevinarstvu u siječnju 2010. godine iznosila je 634 eura, a u siječnju 2016. povećana je na 666 eura. Ova promjena iznosi 5 %. Na temelju toga možemo zaključiti da promjena prosječne bruto plaće nije bila značajna i može se zanemariti. Na području Bosne i Hercegovine prosječna bruto plaća za isto razdoblje je povećana s 391 euro za 2010. godinu, na 410 eura za 2016. godinu. Ta promjena je također oko 5 %. U Republici Srbiji prosječna je bruto plaća bila 398 eura u 2010. godini, a 464 eura u 2016. godini, što je povećanje od 16 %.

Da bi se utvrdila razina promjena cijena građevnog materijala, u ovom su istraživanju prikupljeni podaci iz zemalja u kojima su se projekti izvodili (Crna Gora, Srbija i Federacija Bosne i Hercegovine). Nakon prikupljenih podataka i provedenih proračuna, ustanovljeno je da se cijena cementa smanjila, i to u Crnoj Gori približno 2,7 %, u Srbiji 1,2 % i u Bosni i Hercegovini 5,6 %. Što se tiče cijene armature, ona je u Crnoj Gori i Bosni i Hercegovini smanjena za 13,3 % i 17 %, dok je u Srbiji povećana 15,2 % [26].

Zbog nedovoljnog broja podataka i uzimajući u obzir da je udio materijala i rada u ukupnoj cijeni, u odnosu 45 % - 55 % [27] ili 40 % - 60 % (s obzirom na to da se radi o konstrukciji mosta), napravljena je gruba procjena promjene cijena. Na temelju navedenog cijene su revalorizirane i nakon toga podaci su bili spremni za unos.

Nakon što su definirani ulazni podaci za model, definirani su i izlazni podaci iz modela. Na temelju razmatranih dijelova

istraživanja određen je jedan izlaz iz modela, a to je ukupni trošak izgradnje integralnih cestovnih mostova, tablica 2.

Prilikom formiranja modela uz pomoć umjetnih neuronskih mreža potrebno je podijeliti dostupne podatke u dva skupa. Jedan od ta dva skupa je trening skup koji će služiti za treniranje-učenje modela mreže, a drugi je testni skup i služiti će za provjeru modela mreže. U literaturi postoje preporuke za formiranje takvih skupova. Mnogi autori biraju podatke u odnosu 90 % prema 10 %, 80 % prema 20 %, 85 % prema 15 % ili 70 % prema 30 % [28]. Naravno, postoje i situacije u kojima se taj odnos utvrđuje na temelju specifičnosti problema koji treba riješiti. U ovom će se istraživanju napraviti podjela podataka u skupove za trening i test u odnosu 80 % prema 20 %. U dva modela nasumično će se odabrati podaci, a u šest modela izravno će se podijeliti na trening i test skup. Slučajnim odabirom podataka provest će se postupak unakrsne validacije (KFold-CrossValidation i LeaveOneOut-CrossValidation).

Nakon podjele podataka na skupove za trening i testiranje, a prije započinjanja treniranja-učenja mreže, potrebno je pripremiti podatke iz baze podataka tako da su svi u određenom rasponu veličina, tj. treba skalirati podatke. Odabir raspona za skaliranje ulaznih i izlaznih podataka ovisi o aktivaciji funkcije izlaznih veličina. Skaliranje se može obaviti uz pomoć standardizacije i normalizacije [29]. Rezultat ovih metoda je svođenje određenih podataka na isti red veličine. Osim toga, omogućuju analizu podataka iste važnosti prilikom formiranja modela, što znači da će osigurati i analizu podataka s manjim rasponom veličine. Skaliranje podataka provedeno je na čitavom skupu od 113 projekata. Metode korištene u istraživanju su Standard Scalar (Z-score normalizacija) i Min-Max normalizacija.

U početnoj fazi formiranja modela potrebno je utvrditi arhitekturu mreže [30]. Arhitektura mreže podrazumijeva definiranje broja slojeva i broja neurona u svakom od slojeva. Neki autori preporučuju da pri definiranju umjetne neuronske mreže nije potrebno uzeti više od dva skrivena sloja [28, 31, 32]. Mreže s takvom arhitekturom dale su vrlo pouzdane rezultate, što

Tablica 3. Aktivacijske funkcije višeslojnog perceptrona modela umjetne neuronske mreže

Funkcija	Oznaka	Objašnjenje	Domet
Identity	x	Koristi se samo u izlaznom sloju.	$(-\infty, +\infty)$
Funkcija ispravljene linearne jedinice-Rectified Linear units	$\max(0, x)$	Aktivacija neurona prenosi se izravno kao izlaz ako je pozitivna, a ako je negativna, prenosi se 0. Pokazalo se da ima šest puta bolju konvergenciju u usporedbi s funkcijom tangens hiperbolički	$(0, +\infty)$
Tangens hiperbolička	$\frac{2}{(1+e^{-2x})} - 1$	Slična je kao i sigmoidna funkcija, ali ima bolje performanse zbog simetrije koju ima. Idealno za MLP ANN modele, posebno za skrivene neurone.	$(-1, +1)$

potvrđuju mnogi teorijski rezultati i brojne simulacije u različitim inženjerskim područjima. Međutim, teorijski rezultati također pokazuju da je jedan skriveni sloj dovoljan da mreža aproksimira bilo koju kompleksnu nelinearnu funkciju s dovoljnom točnosi [33].

Zasada ne postoji precizan i pouzdan način odabira broja neurona. Broj neurona trebao bi biti takav da omogući izražavanje najkorisnijih karakteristika koje podaci imaju. Velik broj neurona dovodi do problema pretreniranja (eng. *overfitting*), a nedovoljan broj neurona dovodi do slabe aproksimacije ovisnosti između ulaznih i izlaznih veličina, tj. dovodi do problema s nedovoljnim treniranjem (eng. *underfitting*). Ono za što postoje preporuke jest gornja granica broja neurona u skrivenom sloju. Jedna od preporuka za određivanje broja neurona dana je u izrazu (1) [34], dok je za maksimalni broj neurona, dan u nejednakosti (2) [35]. Prikladno je prihvatiti manji od brojeva iz navedenih nejednakosti, u kojima je broj ulaznih parametara i broj uzoraka za treniranje.

$$N_H \leq 2 \cdot N_I + 1 \quad (1)$$

$$N_H \leq \frac{N_S}{N_I + 1} \quad (2)$$

Cilj je definirati model s najboljom mogućom generalizacijom. Generalizacija je proces u kojem se znanje koje vrijedi za neki skup slučajeva prenosi na neki njegov nadskup [36], tj. mogućnost modela da rezultira zadovoljavajućim veličinama, a na temelju podataka koji mu nisu predstavljeni tijekom treniranja (skup validacije). Uvodi se skup validacije kako bi se izbjegao problem pretreniranja (*overfitting*) ili kako bi se odredile točke zaustavljanja procesa treniranja [37]. Povećanje razine generalizacije u predviđanju može se postići i pomoću postupka naizmjenične validacije. Taj se postupak provodi na podacima iz skupa za testiranje.

U postupku definiranja modela s najboljom mogućom generalizacijom provodi se mjerenje performansi. Mjera performansi je predviđanje točnosti. Mjera točnosti često se definira pogreškom predviđanja koja predstavlja razliku između stvarne (željene) i predviđene vrijednosti. U literaturi se susreće nekoliko takvih mjera točnosti predviđanja. Neke od najčešćih primjenjenih metoda su srednja apsolutna pogreška (eng. *mean absolute error* - MAE), srednja kvadratna pogreška (eng. *mean squared error* - MSE), postotak srednje apsolutne pogreške (eng.

mean absolute percentage error - MAPE) i postotna pogreška (eng. *percentage error* - PE). Točnost modela u ovom istraživanju određena je korištenjem postotka srednje apsolutne pogreške (MAPE) i postotne pogreške (PE). Ako je odstupanje između predviđenih i očekivanih rezultata na skupu treninga i testa mala, može se reći da je u modelu postignuta zadovoljavajuća mogućnost generalizacije.

Model predviđanja formiran je u računalnom programu Python 3.7. Budući da je predmet istraživanja model za procjenu troškova, a ova problematika pripada regresijskim problemima, formiran je višeslojni perceptron MLP koji je vrsta umjetne neuronske mreže koja, osim problema s klasifikacijom, rješava i regresijske probleme.

Najčešće upotrebene aktivacijske funkcije neurona u skrivenim slojevima su logistička sigmoidna (logistic), tangens hiperbolička (tanh) i funkcija ispravljene linearne jedinice (ReLU). Aktivacijska funkcija izlaznih neurona uglavnom je linearna. Prema navedenim preporukama i uzimajući u obzir broj podataka kao i njihove druge karakteristike, u formiranju modela korištene su, za skrivene neurone, funkcija ispravljene linearne jedinice (ReLU) i tangens hiperbolički (tanh), a za izlazne neurone, korištena je funkcija identity, tablica 3.

4. Rezultati

Na temelju definiranih ulaznih i izlaznih varijabli i drugih potrebnih parametara, formirani su modeli umjetnih neuronskih mreža - višeslojni perceptron (MLP). Broj slojeva određen je na temelju preporuka, a broj neurona u skrivenim i u izlaznom sloju određen je na temelju broja ulaznih i izlaznih varijabli. Najveći broj skrivenih neurona uzetih u modelima je 13, temeljen na izrazima (1) i (2). Formirano je osam modela umjetnih neuronskih mreža. U jednoj polovici tih modela korišteni su podaci skalirani postupkom StandardScaler, a u drugoj polovici koristi se metoda Min-Max.

Sve neuronske mreže, NM1, NM2, NM3, NM4, NM5, NM6, NM7 i NM8 imaju po šest ulaznih i jednu izlaznu varijablu. U tablici 6. prikazani su modeli neuronskih mreža sa StandardScaler standardizacijom. Također su navedene i karakteristike svakog modela s mjerom točnosti danom preko srednje apsolutne postotne pogreške (MAPE).

Sljedeća tri NM modela formirana su sa skaliranim podacima primjenom postupka normalizacije Min-Max. Podaci o karakteristikama modela kao i točnost procjene određena uz

Tablica 4. Modeli umjetnih neuronskih mreža (StandardScaler)

Naziv modela	Karakteristike modela	Aktivacijska funkcija skrivenih slojeva	Aktivacijska funkcija izlaznog sloja	MAPE Trening skup [%]	MAPE Test skup [%]
NM1	MLP 6-4-1	Tanh	Identity	16,25	14,15
NM2	MLP 6-7-1	ReLu	Identity	17,21	13,40
NM5	MLP 6-13-1	ReLu	Identity	19,50	14,44

Tablica 5. Modeli umjetnih neuronskih mreža (Min-Max normalizacija)

Naziv modela	Karakteristike modela	Aktivacijska funkcija skrivenih slojeva	Aktivacijska funkcija izlaznog sloja	MAPE Trening skup [%]	MAPE Test skup [%]
NM3	MLP 6-5-1	ReLu	Identity	20,79	16,70
NM4	MLP 6-8-1	Tanh	Identity	22,66	19,58
NM6	MLP 6-12-1	ReLu	Identity	18,66	17,26

Tablica 6. Modeli umjetnih neuronskih mreža s nasumičnim odabirom podataka (kFold-CrossValidation, k = 10)

Naziv modela	Postupak skaliranja podataka	Karakteristike modela	Aktivacijska funkcija skrivenih slojeva	Aktivacijska funkcija izlaznog sloja	MAPE [%]	σ [%]
NM7	StandardScaler	MLP 6-13-1	ReLu	Identity	18,31	5,17

Tablica 7. Modeli umjetnih neuronskih mreža s nasumičnim odabirom podataka (LOOCV)

Naziv modela	Postupak skaliranja podataka	Karakteristike modela	Aktivacijska funkcija skrivenih slojeva	Aktivacijska funkcija izlaznog sloja	MAPE Trening skup [%]	MAPE Test skup [%]
NM8	Min-Max	MLP 6-7-1	ReLu	Identity	17,12	17,06

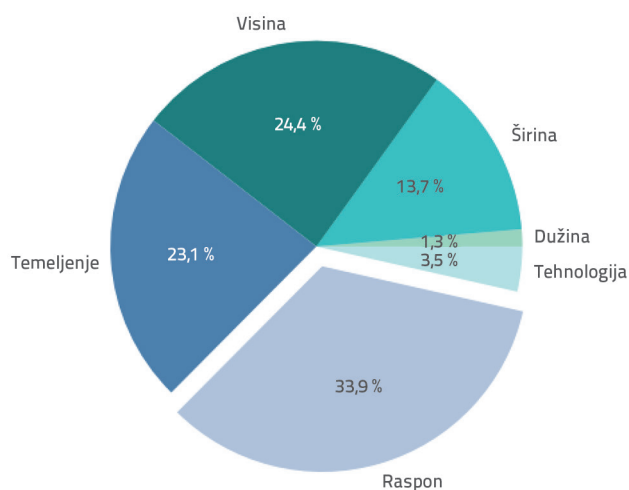
pomoć srednje apsolutne postotne pogreške (MAPE), prikazani su u tablici 5.

Dva modela u kojima su slučajno odabrani podaci koristeći kFold-CrossValidation za $k = 10$ i LeaveOneOut-CrossValidation (LOOCV), a točnost procjene određena je srednjom apsolutnom postotnom pogreškom (MAPE), prikazani su u tablicama 6. i 7. U modelu u kojem je podjela podataka izvršena s kFold-CrossValidation, podaci su skalirani pomoću StandardScaler, a u modelu u kome je podjela izvršena s LOOCV, podaci su skalirani Min-Max funkcijom. Ovdje su prikazana dva modela koja su dala najbolji rezultat.

Usporedbom prikazanih modela jasno je da model NM 2 ima najveću točnost procjene. U tom se modelu primjenjuje skaliranje podataka pomoću StandardScalera. U modelu NM2 definirana su tri sloja neurona, od kojih je jedan ulazni, jedan skriveni i jedan izlazni sloj. U skrivenom sloju nalazi se sedam neurona. Aktivacijska funkcija skrivenog sloja je funkcija ispravljene linearne jedinice (ReLu). Mjera točnosti procjene modela izražava se preko srednje apsolutne postotne pogreške i iznosi 13,40 %. Dobivena vrijednost MAPE zadovoljava ciljanu točnost od ± 15 %. Ovaj je model odabran za konačni model, a na temelju njega definiran je prognostički model za procjenu.

Činjenica je da ulazne veličine imaju različite razine utjecaja na procijenjene vrijednosti. Razina utjecaja određuje se pomoću analize osjetljivosti. Ovo je metoda koja nam pomaže u

definiranju uzročno posljedične veze između ulaznih i izlaznih veličina. Rezultati metode prikazani su na slici 2. tj., prikazan je utjecaj svih šest ulaznih veličina na izlaznu veličinu.



Slika 3. Utjecaj ulaznih veličina na izlaznu veličinu, tj. cijenu mosta

Na slici 3. može se vidjeti da je ulazna veličina, koja najviše utječe na cijenu mosta (izlaznu veličinu), zapravo raspon konstrukcije.

5. Zaključak

Na temelju rezultata koji su prikazani u ovom istraživanju zaključuje se da model s najvećom točnošću procjene troškova izgradnje integralnih cestovnih mostova jest model umjetne neuronske mreže. Njegova je arhitektura predstavljena s tri sloja neurona od kojih je šest u prvom sloju, sedam neurona u drugom, skrivenom sloju, i jedan u posljednjem, izlaznom sloju. Aktivacijska funkcija skrivenog sloja neurona je funkcija ispravljene linearne jedinice (ReLU), a aktivacijska funkcija izlaznog sloja je linearna (Identity). Mjera točnosti je predstavljena srednjom apsolutnom postotnom pogreškom (MAPE) i iznosi 13,40 %. Ulazna veličina koja ima najznačajniji utjecaj na cijenu izgradnje mosta je raspon mosta, a izražen u postocima on iznosi, 33,90 %.

Povećanje broja podataka u bazi podataka dodatno bi poboljšalo točnost modela predviđanja. Uz to, proširenje baze podataka s karakteristikama građevine kao što su vrsta poprečnog presjeka, visina poprečnog presjeka, broj raspona, broj stupova, konstrukcijski sustav itd., dovelo bi do mogućnosti šire upotrebe modela predviđanja. Potencijalni parametri kojima bi se mogla


proširiti baza podataka bili bi, ustvari, ulazni parametri modela predviđanja. Proširenje baze podataka s karakteristikama buduće građevine ili dostupnim informacijama koje predstavljaju određena ograničenja za gradnju buduće građevine, omogućava nam da napravimo procjenu u fazi prije izrade lidejnog projekta. Neke od tih informacija su karakteristične prepreke – postojanje vodotoka ili ne, dubina korita, uvjeti temeljenja itd. Ako bi se u toj početnoj fazi provedbe projekta postigla točnost procjene približna onoj koja je ostvarena u ovom istraživanju, pogreška pri procjeni troškova u ranim fazama realizacije projekata bila bi još manja.

Model predviđanja može koristiti i investitoru i izvođaču. U ranim fazama je količina dostupnih podataka o budućim građevinama prilično mala, pa je i pogreška pri procjeni troškova veća u odnosu na procjene izrađene u kasnijim fazama provedbe. Primjena modela ovisi o podacima koji su nam dostupni u trenutku izrade procjene. To je razlog zašto je potrebno prilagoditi ulazne veličine podacima koje imamo. Činjenica je da su iznimno važne procjene u ranim fazama jer nas rezultati upravo te rane procjene usmjeravaju da prihvatimo ili odbacimo provedbu projekta.

LITERATURA

- [1] Quantity Surveying Techniques-New Directions, (ed. Brandon, P.S.), Blackwell Scientific Publications, 1992.
- [2] Ivković, B., Popović, Ž.: Upravljanje projektima u građevinarstvu, treće izdanje, Građevinska knjiga, Beograd, 2005.
- [3] Lowe, D.J., Emsley, M.W., Harding, A.: Predicting construction cost using multiple regression techniques, *Journal of Construction Engineering and Management*, 132 (2006) 7, pp. 750–758
- [4] Schexnayder, C.J., Mayo, R.E.: *Construction Management Fundamentals*, McGraw-Hill Higher Education, Boston, MA, 2003.
- [5] Sodikov, J.: Cost estimation of highway projects in developing countries: artificial neural network approach, *Journal of the Eastern Asia Society for Transportation Studies*, 6 (2005), pp. 1036-1047
- [6] Mahamid, I.: Early cost estimating for road construction projects using multiple regression techniques, *Australasian Journal of Construction Economics and Building*, 11 (2011) 4, pp. 87-101
- [7] Ashworth, A., Skitmore, R.M.: *Accuracy in estimating*, The Chartered Institute of Building, Englemere, Berkshire, England, 1983.
- [8] Adeli, H., Yeh, C.: Perceptron learning in engineering design, *Microcomputers in Civil Engineering*, 4 (1989) 4, pp. 247–256
- [9] Arafa, M., Alqedra, M.A.: Early Stage Cost Estimation of Buildings Construction Projects using Artificial Neural Networks, *Journal of Artificial Intelligence*, 4 (2011) 1, <https://doi.org/10.3923/jai.2011.63.75>.
- [10] Bouabaz, M., Hamami, M.: A Cost Estimation Model for Repair Bridges Based on Artificial Neural Network, *American Journal of Applied Sciences*, 5 (2008) 4, pp. 334-339
- [11] Gunduz, M., Sahin, H.B.: An early cost estimation model for hydroelectric power plant projects using neural networks and multiple regression analysis, *Journal of civil engineering and management*, 21 (2015) 4, pp. 470–477, <https://doi.org/10.3846/13923730.2014.890657>
- [12] Alex, D.P., Hussein, M.A., Bouferguene, A., Fernando, S.: Artificial Neural Network Model for Cost Estimation: City of Edmonton's Water and Sewer Installation Services, *Journal of Construction Engineering and Management*, 136 (2010) 7, pp. 745 - 756
- [13] Hegazy, T., Ayed, A.: Neural Network Model for Parametric Cost Estimation of Highway Projects, *Journal of Construction Engineering and Management*, 124 (1998) 3, pp. 210-218
- [14] Al-Tabtabai, H., Alex, A.P., Tantash, M.: Preliminary cost estimation of highway construction using neural networks, https://www.researchgate.net/publication/284778900_Preliminary_cost_estimation_of_highway_construction_using_neural_networks, Mart (1999)
- [15] Pearce, A.R., Gregory, R.A., Williams, L.: Range Estimating for Risk Management Using Artificial Neural Networks, *Journal of Parametrics*, 19 (1999) 1, pp. 3-31, <https://doi.org/10.1080/10157891.1999.10462578>
- [16] Wang, X., Duan, X., Liu, J.: Application of Neural Network in the Cost Estimation of Highway Engineering, *Journal of computers*, 5 (2010) 11, pp. 1762-1766, <https://doi.org/10.4304/jcp.5.11.1762-1766>
- [17] Wilmont, C.G., Cheng, G.: Estimating Future Highway Construction Costs, *Journal of Construction Engineering and Management*, 129 (2003) 3, pp. 272-279, <https://doi.org/10.1061/%28ASCE%29073-9364%282003%29129%3A3%28272%29>

- [18] Gunaydin, H.M., Dogan, S.Z.: A neural network approach for early cost estimation of structural systems of buildings, *International Journal of Project Management*, 22 (2004) 7, pp. 595-602
- [19] Kazez, M.B., Vipulanandan, C.: Bridge Damage and Repair Cost Estimates after a Hurricane, *THC Conference & Exhibition, USA*, 2010.
- [20] Atta-Asiamah, E.: Estimation of the cost of building a water treatment plant and related facilities for Kaw City, Oklahoma, Faculty of the Graduate College of the Oklahoma State University, 2005
- [21] Milić Marković, Lj., Marković, Lj., Čirović, G., Mihajlović, D.: Procjena investicijske vrijednosti u procesu rekonstrukcije željezničkih pruga, *GRAĐEVINAR*, 69 (2017) 9, pp. 811-892, doi.org/10.14256/JCE.1013.2014
- [22] Flyvbjerg, B.H., Mette, S., Buhl, S.: Underestimating costs in public works projects, error or lie, *Journal of the American Planning Association*, 68 (2002) 3, pp 279-292
- [23] Emsley, M.W., Lowe, D.J., Duff, A.R., Harding, A., Hickson, A.: Data modelling and the application of a neural network approach to the prediction of total construction costs, *Construction Management and Economics*, 20 (2002), pp. 465-472
- [24] Arafa, M., Alqedra, M.: Early Stage Cost Estimation of Buildings Construction Projects using Artificial Neural Networks, *Journal of Artificial Intelligence*, 4 (2011) 1, pp. 63-75
- [25] Pržulj, M.: *Mostovi*, Udruženje Izgradnja, Beograd, 2014.
- [26] Izvori: Cemex Crna Gora, Cemex Federacija BiH, Cijevna Komer Podgorica, Letač Indija, Graditelj NS Novi Sad
- [27] Gichuhi, F.: Percentage of cost breakdown between labour, materials and contractor profit in construction, *A4architect.com*, Architects, Nairobi, Kenya, <https://www.a4architect.com/2013/04/percentage-of-cost-breakdown-between-labour-materials-and-contractor-profit-in-construction/>, <https://answers.angieslist.com/what-labor-percentage-cost-building-5000-sq-ft-home-q231700.aspx>, 2013.
- [28] Zhang, G., Patuwo, B.E., Hu, M.Y.: *Forecasting with artificial neural networks: The state of the art*, Graduate School of Management, Kent State University, Kent, Ohio, USA, (1997)
- [29] Brownlee, J.: *Machine Learning Mastery with Weka*, Machine learning mastery, Australija, (2016)
- [30] Knežević, M., Cvetkovska, M., Ivanišević, N., Samardžioska, T., Gavriloska, A.T., Lazarevska, M.: Fire-resistance prognostic model for reinforced concrete columns, *GRAĐEVINAR*, 64 (2012) 7, <https://doi.org/10.14256/JCE.674.2011>
- [31] Goodfellow, I., Bengio, Y., Courville, A.: *Deep learning* (Adaptive Computation and Machine Learning series). The MIT Press, Cambridge, Massachusetts, London, England, 2016.
- [32] Reed, R., MarksII, R.: *Neural Smithing: Supervised Learning in Feedforward Artificial Neural Networks* (A Bradford Book). The MIT Press, Cambridge, Massachusetts, London, England, 1999.
- [33] Cybenko, G.: Approximation by Superpositions of a Sigmoidal Function. *Math. Control Signals Systems*, 2 (1989), pp. 303-314
- [34] Heaton, J.: *Introduction to Neural Networks for C#*, Second Edition, Publisher: Heaton Research, Inc, 2008.
- [35] Kingston, G.B.: *Bayesian Artificial Neural Networks in Water Resources Engineering*, doctoral dissertation, University of Adelaide, Australia: School of Civil and Environmental Engineering, Faculty of Engineering, 2006.
- [36] Janičić, P., Nikolić, M.: *Veštačka inteligencija*, Matematički fakultet Univerziteta u Beogradu, Beograd, 2019.
- [7] Simonović, M.: *Primena veštačkih neuronskih mreža za kratkoročno predviđanje i analizu sistema daljinskog grejanja*, Doktorska disertacija Mašinski fakultet Univerzitet u Nišu, Niš, 2016.



CETRA^{2020*}

6th International Conference on Road and Rail Infrastructure

NEW DATE: 20 - 21 May 2021

~~20 - 22 May 2020~~

Pula, Croatia

www.grad.unizg.hr/cetra

Organizer



University of Zagreb
Faculty of Civil Engineering
Department of Transportation

Supporting organizations



IRF
GLOBAL

International Road Federation



Forum of European National
Highway Research Laboratories