

Primena veštačke inteligencije u prediktivnom održavanju gradske infrastrukture

Emilija Stojanović, Miloš Radenković¹

Sadržaj — Ovaj rad istražuje primenu veštačke inteligencije u prediktivnom održavanju urbanih infrastrukturnih sistema, koje omogućavaju pravovremenu detekciju kvarova i prognozu potencijalnih oštećenja. Korišćenjem simuliranih podataka, istreniran je model za detekciju anomalija, uz analizu ključnih faktora kao što su temperatura, opterećenje i vibracije. Evaluacijom se ukazuje na visoku tačnost modela, dok diskusija pruža smernice za integraciju sa senzorima. Rad obuhvata izazove i potencijalne buduće pravce razvoja prediktivnog održavanja.

Ključne reči — gradska infrastruktura, mašinsko učenje, prediktivno održavanje, veštačka inteligencija, internet stvari

I. UVOD

U PRAVLJANJE infrastrukturom u urbanim sredinama suočava se sa rastućim izazovima usled urbanizacije i povećane upotrebe resursa, što zahteva efikasne sisteme održavanja radi očuvanja pouzdanosti i dugovečnosti ključnih objekata poput mostova, puteva i energetskih mreža. Tradicionalni pristupi, poput preventivnog održavanja, oslanjaju se na unapred definisane vremenske intervale za inspekcije i popravke, što može dovesti do nepotrebnih troškova i propuštanja pravovremenih intervencija.

Prediktivno održavanje gradske infrastrukture uz primenu veštačke inteligencije predstavlja revolucionaran pristup modernizaciji sistema održavanja. Korišćenje podataka prikupljenih putem IoT (eng. *Internet of Things*, internet stvari) senzora omogućava pravovremenu detekciju potencijalnih kvarova i predviđanje strukturnih problema, čime se značajno

¹

E. Stojanović, Računarski fakultet, Beograd, Srbija (email: estojanovic@raf.rs).

M. Radenković, Računarski fakultet, Beograd, Srbija (email: mradenkovic@raf.rs).

povećava bezbednost i smanjuju troškovi održavanja. Veštačke neuronske mreže, rekurentni modeli i druge napredne metode dubokog učenja pokazale su se ključnim za analizu i donošenje odluka na osnovu velikih količina podataka.

Uprkos značajnim prednostima, implementacija ovih tehnologija suočava se s nizom izazova. Nedostatak istorijskih podataka, potreba za skalabilnošću modela i osiguranje interpretabilnosti u realnim uslovima rada ističu se kao ključne prepreke. Ovi problemi zahtevaju razvoj inovativnih algoritama sposobnih za efikasnu obradu simuliranih i stvarnih podataka u svrhu otkrivanja anomalija i unapređenja planiranja održavanja.

Ovaj rad fokusira se na primenu veštačke inteligencije u analizi i održavanju mostova kao ključnih infrastrukturnih objekata. Kroz generisanje simuliranih podataka koji odražavaju realne uslove rada mostova, kao i njihovu obradu pomoću konvolucionih neuronskih mreža, razvija se sistem sposoban za detekciju oštećenja i predikciju potencijalnih problema. Posebna pažnja posvećena je integraciji sa *IoT* sensorima i obradi podataka u realnom vremenu.

Pored analize performansi razvijenog modela, rad identifikuje izazove u prilagođavanju tehnologija sistemima sa ograničenim resursima i predlaže smernice za njihovu praktičnu primenu. Ovaj pristup donosi značajan potencijal za unapređenje održivosti i bezbednosti infrastrukture, postavljajući temelje za širu implementaciju u urbanim sredinama.

II. MODELI I METODE PREDIKTIVNOG ODRŽAVANJA

A. Modeli predviđanja zasnovani na veštačkoj inteligenciji

Modeli veštačke inteligencije igraju ključnu ulogu u prediktivnom održavanju, omogućavajući analizu velikih količina podataka i preciznu predikciju kvarova pre nego što do njih dođe. Prediktivni algoritmi koriste podatke dobijene iz senzora i drugih izvora u realnom vremenu kako bi identifikovali obrasce koji ukazuju na potencijalne probleme. Neki od najpogodnijih modela su: veštačke neuronske mreže (eng. *Artificial Neural Networks*, skraćeno *ANN*), potporne vektorske mašine (eng. *Support Vector Machines*, skraćeno *SVM*), rekurentne neuronske mreže (eng. *Recurrent Neural Networks*, skraćeno *RNN*), model duge kratkoročne memorije (eng. *Long Short-Term Memory*, skraćeno *LSTM*), konvolucione neuronske mreže (eng. *Convolutional Neural Networks*, skraćeno *CNN*), stabla odluke (eng. *Decision Trees*, skraćeno *DT*), model nasumične šume (eng. *Random Forest*, skraćeno *RF*) i hibridni modeli koji predstavljaju kombinaciju različitih algoritama.

B. Odabir modela

Proces odabira modela uključuje izbor odgovarajuće algoritamske arhitekture, definisanje odgovarajućih hiperparametara i prilagođavanje modela specifičnim potrebama sistema, pri čemu se teži balansu između tačnosti i računarske efikasnosti.

Odabir modela zasniva se na nekoliko ključnih faktora koji obezbeđuju da model bude adekvatan za specifične potrebe:

1. Priroda podataka:

- Podaci sa sekvencijalnom strukturom, poput vremenskih serija (npr. vibracije, temperature), zahtevaju modele kao što su rekurentne neuronske mreže ili duge kratkoročne memorije, koje mogu analizirati istorijske podatke i identifikovati obrasce. Na primer, *LSTM* je efikasan za predikciju preostalog veka trajanja [1].
- Za analizu podataka sa senzora, poput vibracija i temperature, koriste se konvolucione neuronske mreže, koje omogućavaju automatsku ekstrakciju ključnih karakteristika. *CNN* je sposoban da identifikuje obrasce kao što su pikovi, promene u amplitudi i frekvenciji, što je ključno za analizu signala i detekciju anomalija.
- *CNN* se takođe može koristiti za integraciju različitih izvora podataka, poput višekanalnih vremenskih serija, pružajući sveobuhvatniju analizu.
- Za analizu slika, poput termalnih slika ili vibracionih mapa, koriste se takođe konvolucione neuronske mreže.
- Strukturisani podaci s jasno definisanim karakteristikama često se analiziraju pomoću *SVM* modela ili metoda kao što je *RF*.

2. Cilj analize:

- Klasifikacioni zadaci (npr. kategorizacija stanja sistema na normalno, anomalija, kvar) često koriste modele poput *SVM*, *RF* ili *CNN*, koji su visoko precizni u prepoznavanju obrazaca u kompleksnim podacima.
- Regresioni zadaci, poput procene preostalog radnog veka, preferiraju duboke modele poput *LSTM* ili ansambl tehnike (npr. *Gradient Boosting*) zbog njihove sposobnosti predikcije kontinuiranih vrednosti.

3. Raspoloživi resursi:

- Modeli poput *CNN* i *LSTM* zahtevaju značajne računarske resurse, uključujući GPU-ove za ubrzanje treniranja. U sistemima sa ograničenim resursima, lakši modeli poput stabala odluke mogu biti pogodniji.

4. Robusnost i interpretabilnost:

- U industrijskim okruženjima, gde je objašnjivost modela ključna za donošenje odluka, preferiraju se modeli poput *DT* i *RF*, koji omogućavaju vizuelnu interpretaciju procesa donošenja odluka.

III. PRIMERI PRIMENE I SIMULACIJE

U oblasti prediktivnog održavanja gradske infrastrukture, ključni izazov predstavlja nedostatak istorijskih podataka o kvarovima, što značajno otežava obuku algoritama za detekciju anomalija. Dok se mnogi istraživači, poput *Waldhauser*-a i saradnika (2024), oslanjaju na kombinaciju stvarnih podataka prikupljenih iz laboratorijskih eksperimenata i simulacija za popunjavanje praznina u nedostajućim podacima [2], u ovom istraživanju svi podaci su u potpunosti generisani putem simulacija. Razlog za ovu strategiju leži u ograničenoj dostupnosti podataka o anomalijama mostova. Simulacijski pristup pruža visoku fleksibilnost za prilagođavanje različitim scenarijima i omogućava generisanje dovoljne količine podataka za obuku i evaluaciju osnovnog modela. Obučeni model služi kao temelj za dalja unapređenja kada se stvarni podaci, prikupljeni putem senzora, postanu dostupni. Generisani podaci, koji uključuju parametre poput temperature, opterećenja i vibracija, omogućili su analizu uticaja ovih faktora na pojavu anomalija na mostovima, čime su postavljeni temelji za pravovremeno otkrivanje i predikciju potencijalnih strukturnih problema.

A. *Kreiranje simuliranih scenarija za gradsku infrastrukturu*

Mostovi su ključni elementi gradske infrastrukture, omogućavajući povezivanje ljudi i dobara u urbanim i ruralnim sredinama. Njihova pouzdanost i bezbednost direktno utiču na svakodnevni život i ekonomsku stabilnost. Međutim, mostovi su tokom svog životnog ciklusa izloženi različitim opterećenjima, kao što su dinamička opterećenja izazvana saobraćajem, vremenske nepogode i dugoročno habanje materijala. Ovi faktori mogu dovesti do strukturnih oštećenja koja, ako se ne otkriju na vreme, mogu rezultirati ozbiljnim posledicama, uključujući kolaps mosta.

Za potrebe simulacije, odabrani su ključni parametri koji predstavljaju osnovu za praćenje i analizu stanja mostova: temperatura, opterećenje i vibracije. Ovi parametri su pažljivo odabrani zbog svog direktnog uticaja na strukturalno zdravlje mosta i svoje uloge u prediktivnom održavanju.

Vibracije mosta predstavljaju kritičan indikator potencijalnih strukturnih oštećenja. Visoke amplitude vibracija mogu signalizirati slabosti u konstrukciji, kao što su pukotine, habanje ili problemi u spojevima materijala.

Redovno praćenje ovih vrednosti omogućava pravovremenu detekciju odstupanja od normalnog ponašanja mosta, što je ključno za planiranje održavanja.

Promene temperature imaju značajan uticaj na materijale od kojih su mostovi napravljeni. Ekstremne temperaturne varijacije mogu izazvati širenje i skupljanje materijala, što dugoročno doprinosi pojavi pukotina ili slabosti u konstrukciji. Praćenjem temperature može se analizirati njen uticaj na dugoročno ponašanje mosta i predvideti rizik od temperaturno izazvanih problema.

Dinamičko opterećenje izazvano saobraćajem i vremenskim uslovima značajno doprinosi stresu na mostu. Analizom promena u opterećenju moguće je detektovati neuobičajeno visoke vrednosti koje mogu izazvati habanje ili oštećenja, čime se osigurava pravovremena intervencija.

Praćenje ovih parametara ključno je za pravovremenu detekciju anomalija i planiranje preventivnog održavanja. Međutim, stvarni podaci o kvarovima i anomalijama su često ograničeni ili potpuno nepristupačni. Ovo se može objasniti visokom pouzdanošću modernih konstrukcija i nedostatkom standardizovanih metoda za kontinuirano prikupljanje podataka.

Upravo zbog ovih izazova, simulacija postaje neophodna komponenta u analizi stanja mostova. Kroz generisanje sintetičkih skupova podataka, moguće je modelirati različite scenarije koji odražavaju realne uslove rada mostova. Simulirani scenariji ne samo da popunjavaju prazninu u podacima već i omogućavaju razvoj naprednih algoritama za detekciju anomalija, koji se kasnije mogu prilagoditi stvarnim podacima kada postanu dostupni. Ova metodologija pruža osnovu za unapređenje održavanja i pouzdanosti mostova, doprinosi smanjenju troškova i povećava sigurnost svih učesnika u saobraćaju.

Kako bi simulirani podaci bili što realističniji, definisani su opsezi vrednosti za svaki parametar na osnovu literature i inženjerskih standarda:

Frekvencije vibracija su simulirane u opsegu od 0 do 10 Hz, pri čemu su niže frekvencije povezane sa normalnim radnim uslovima, dok više vrednosti ukazuju na potencijalne anomalije.

Temperatura: Vrednosti temperature su simulirane u rasponu od 19°C do 25°C kako bi se obuhvatile uobičajene sezonske varijacije u temperama koje mogu uticati na mostove.

Opterećenje: Simulirane vrednosti opterećenja su varirale oko proseka od 15 tona, sa standardnom devijacijom od 3 tone, što odgovara realnim uslovima saobraćaja na urbanim mostovima.

Ovi opsezi omogućavaju kreiranje podataka koji reflektuju širok spektar mogućih situacija, uključujući i ekstremne scenarije.

U cilju kreiranja realističnog skupa podataka koji može predstavljati ponašanje mostova pod različitim opterećenjima, razvijen je proces generacije i obogaćivanja podataka u više faza. Ovaj proces kombinuje osnovnu simulaciju sa primenom generativnih adversarijalnih mreža (eng. skraćeno. GAN), omogućavajući kreiranje podataka visokog kvaliteta koji reflektuju složene obrasce i potencijalne anomalije.

Za početak, razvijena je funkcija *generate_synthetic_data* koja simulira osnovne parametre mostova: opterećenje, vibracije i temperaturu. Ovi podaci su generisani korišćenjem statističkih distribucija kako bi se postigla realističnost. Simulacija je omogućila definisanje scenarija sa normalnim stanjima, ali i sa anomalijama, gde su vibracije prekoračivale zadate pragove.

Podaci su zatim normalizovani pomoću MinMaksSkalera (eng. *MinMaxScaler*), kako bi se osigurala uniformnost vrednosti za dalju obradu, a ceo dataset je pripremljen za dodatnu obuku putem GAN arhitekture.

Zatim je razvijen GAN model, sastavljen od dva glavna modula - generatora i diskriminatora. Generator je neuralna mreža koja generiše sintetičke uzorke, simulirajući vibracije, opterećenje i temperaturu u skladu sa distribucijom stvarnih podataka. Diskriminator je neuralna mreža trenirana da razlikuje stvarne od generisanih uzoraka, pružajući povratne informacije generatoru.

Obuka modela sprovedena je iterativno. Na svakom koraku:

1. Diskriminator je unapređivan tako da postaje precizniji u klasifikaciji podataka kao stvarnih ili generisanih.
2. Generator je prilagođavan kako bi stvarao podatke koji sve više liče na stvarne.

Ova interakcija omogućila je stvaranje podataka koji uključuju retke i kompleksne obrasce, poput scenarija sa specifičnim anomalijama.

Za procenu kvaliteta podataka korišćena je Vaserštajnova distanca (eng. *Wasserstein distance*), koja meri sličnost između stvarnih i generisanih distribucija. Rezultati su pokazali visok stepen poklapanja, što potvrđuje sposobnost GAN-a da precizno reprodukuje ponašanje mostova u različitim uslovima.

Podaci generisani simulacijom i obogaćeni pomoću GAN-a služe kao osnov za obuku CNN modela. Podeljeni su na trening i test skup koristeći slojevitu podelu. Ovaj korak obezbeđuje da se distribucija klasa (normalni i anomalijski podaci) zadrži u oba skupa. Trening skup koji je dobijen se koristio za obuku modela i optimizaciju njegovih parametara. Test skup se koristio za procenu performansi modela na neviđenim podacima,

Podaci su potom preoblikovani u trodimenzionalni format kako bi bili kompatibilni sa 1D konvolucionim neuronskim mrežama. Ovo preoblikovanje

omogućava mreži da analizira obrasce među parametrima kao vremenske serije.

Model baziran na *CNN* arhitekturi razvijen je za detekciju anomalija, uzimajući u obzir međusobne odnose između parametara mostova. Struktura modela je prikazana na Sl. 1. i uključuje sledeće slojeve:

1. Konvolucionni sloj: Detektuje lokalne obrasce u podacima (npr. nagle promene u vibracijama). Model koristi 32 filtera sa veličinom kernela 2 i aktivacionom funkcijom *ReLU*.

2. Sloj za smanjenje dimenzionalnosti (eng. *MaxPooling1D*): Redukuje dimenzionalnost podataka i ističe najvažnije karakteristike.

3. Sloja za spljoštavanje podataka (eng. *Flatten layer*): Transformiše višedimenzionalne podatke u jedinstveni vektor kako bi bio kompatibilan sa sledećim slojevima.

4. Gusti slojevi (eng. *Dense layer*): Ima 64 neuronske jedinice i koristi *ReLU* aktivaciju za učenje složenih obrazaca.

5. Sloj za regularizaciju (eng. *Dropout layer*): Implementira regularizaciju, smanjujući rizik od prekomerne obuke.

6. Izlazni sloj: Koristi sigmoid funkciju za binarnu klasifikaciju podataka kao normalnih ili anomalijskih.

Layer (type)	Output Shape	Param #
conv1d (<i>Conv1D</i>)	(None, 2, 32)	96
max_pooling1d (<i>MaxPooling1D</i>)	(None, 1, 32)	0
flatten (<i>Flatten</i>)	(None, 32)	0
dense_8 (<i>Dense</i>)	(None, 64)	2,112
dropout_2 (<i>Dropout</i>)	(None, 64)	0
dense_9 (<i>Dense</i>)	(None, 1)	65

Sl. 1. Prikaz arhitekture neuronske mreže sa slojevima. Izlazni oblici svakog sloja i broj parametara ukazuju na veličinu mreže i način obrade ulaznih podataka.

Model je kompajliran sa Adam optimizatorom koji je poznat po efikasnosti u konverziji, binarnom unakrsnom entropijom kao funkcijom gubitka za precizno klasifikovanje binarnih izlaza i kako bi se merile performanse modela korišćena je tačnost (eng. *accuracy*).

Model je treniran kroz 20 epoha sa veličinom grupe podataka (eng. *batch*) od 32, pri čemu je 20% trening skupa korišćeno za validaciju. Tokom procesa obuke se funkcija gubitka postepeno smanjivala, što ukazuje na uspešnu

optimizaciju modela.

B. Analiza rezultata simulacije

Rezultati simulacije i evaluacije modela pružaju dublji uvid u performanse razvijenog sistema za detekciju anomalija na mostovima. Korišćenjem kombinacije simuliranih podataka i konvolucionog neuronskog modela postignute su visoke vrednosti tačnosti i preciznosti, dok su istaknute mogućnosti za dalje unapređenje modela. Evaluacija je sprovedena na test podacima koji čine 20% ukupnog skupa, a rezultati ukazuju na izvanredne performanse modela. ROC-AUC skor iznosi 0.9962, što potvrđuje sposobnost modela da sa visokim nivoom pouzdanosti razlikuje anomalije od normalnih podataka.

Model je u izveštaju klasifikacije postigao preciznost od 99.1%, što znači da je većina predikcija anomalija bila tačna, dok je osetljivost iznosila 98.7%, ukazujući na uspešnu detekciju stvarnih anomalija. Kombinovana metrika F1-skor, koja objedinjuje preciznost i osetljivost, iznosi 98.9%, potvrđujući uravnoteženost performansi modela. Pored toga, za procenu generisanih podataka korišćena je Vaserštajnova distanca, sa vrednostima 0.536 za opterećenje, 0.280 za vibracije i 0.524 za temperaturu, što ukazuje na visok stepen poklapanja između simuliranih i stvarnih podataka.

Tokom treninga, funkcija gubitka progresivno je opadala sa početne vrednosti 0.5053 na završnu vrednost 0.0054, ukazujući na uspešno optimizovanje parametara modela. Na validacionom skupu postignuta je tačnost od 99.37%, što potvrđuje stabilnost procesa učenja. Dodatno, gubitak tokom epoha pokazuje konstantno smanjenje, dok tačnost prikazuje stabilan rast, čime se naglašava efektivnost treninga modela i njegovih predikcija.

Uprkos impresivnim rezultatima evaluacije modela, neophodno je naglasiti da visok nivo tačnosti i preciznosti može biti posledica specifičnosti simuliranih podataka, a ne nužno sposobnosti modela da se nosi sa kompleksnošću stvarnih scenarija. Model nije validiran na stvarnim podacima sa *IoT* senzora, što je sledeći ključni korak u unapređenju sistema.

Prvo je moguća idealizacija podataka. Simulirani podaci su generisani prema unapred definisanim distribucijama i pravilima, što može kao rezultat dati skup podataka koji je "previše čist" i oslobođen šuma, nepravilnosti i nepredvidivosti koje su karakteristične za realne infrastrukturne sisteme. Pored toga, podaci su pažljivo dizajnirani sa jasnim granicama između normalnih stanja i anomalija, što može olakšati zadatak modelu u procesu obuke.

Zatim mora se uzeti u obzir i nedostatak realističnih izazova. U stvarnim uslovima, podaci često sadrže šum, nedoslednosti ili nekompletne vrednosti zbog grešaka u prikupljanju podataka sa senzora. Model trenutno nije testiran

na takvim scenarijima, što može kao rezultat dati preterani optimizam u proceni njegove robusnosti. Takođe, simulirani podaci ne uključuju faktore poput vremenskih fluktuacija, nenormalnih ponašanja ili nepredvidivih interakcija između parametara.

Podaci su generisani tako da zadrže balans između normalnih i anomalijских klasa. U stvarnim situacijama, anomalije su često retke i neravnomerno distribuirane, što predstavlja dodatni izazov za modele u detekciji.

Iako rezultati pokazuju visok nivo performansi modela, potrebno je uzeti u obzir idealizovanost simuliranih podataka koji su možda olakšali obuku modela. Ovi nalazi naglašavaju važnost daljeg testiranja i unapređenja modela kako bi se osiguralo da njegove performanse ostanu konzistentne u stvarnim infrastrukturnim sistemima, koji su često nepredvidivi i kompleksni.

C. Diskusija o potencijalnim praktičnim implikacijama

Rezultati simulacija i evaluacija modela ukazuju na značajan potencijal primene u prediktivnom održavanju gradske infrastrukture, naročito u urbanim sredinama poput Beograda ili drugih gradova u Srbiji. Ipak, prelazak sa simulacija na primenu u stvarnim uslovima suočava se sa brojnim izazovima i mogućnostima za unapređenje.

Jedan od ključnih primera u lokalnom kontekstu su mostovi u Beogradu, poput Gazele ili Pančevačkog mosta, koji su izloženi visokim opterećenjima usled gustog saobraćaja. Održavanje ovih struktura trenutno se oslanja na periodične inspekcije, koje su često skupe i neefikasne. Implementacija sistema zasnovanog na *IoT* senzorima i prediktivnim modelima omogućila bi kontinuirano praćenje parametara poput vibracija, opterećenja i temperature, čime bi se značajno smanjio rizik od nepredviđenih kvarova.

U ruralnim oblastima, gde su resursi za inspekciju i održavanje mostova često ograničeni ili potpuno nedostupni, prediktivni modeli predstavljaju efikasno rešenje za prevazilaženje ovih izazova. Kombinovanjem simuliranih i stvarnih podataka moguće je stvoriti pouzdane sisteme za daljinsko praćenje infrastrukturnih objekata. Postavljanje senzora na ključne tačke mostova omogućilo bi kontinuirano prikupljanje podataka o njihovom stanju, što bi olakšalo pravovremeno planiranje neophodnih intervencija i sprečilo potencijalne kvarove.

Iako su budžetska ograničenja često prepreka za primenu ovakvih tehnologija u lokalnom kontekstu, inicijalna ulaganja u senzore i prediktivne modele mogu se opravdati dugoročnim smanjenjem troškova održavanja. Efikasnije planiranje intervencija i smanjenje rizika od ozbiljnih kvarova ne samo da doprinose većoj sigurnosti, već i značajno unapređuju održivost infrastrukture u manje razvijenim područjima.

Pored infrastrukturnih izazova, rad sa stvarnim podacima u praksi često donosi dodatne tehničke poteškoće. Naime, stvarni podaci su često opterećeni šumom, koji može nastati usled vremenskih uslova, vibracija okoline ili nepravilnosti u radu senzora. Kako bi model mogao pouzdano da funkcioniše u ovakvim uslovima, neophodno je njegovo prilagođavanje kroz dodatnu obuku na realnim uzorcima.

Primena naprednih tehnika za obradu podataka, poput metoda za uklanjanje šuma ili algoritama za interpolaciju, ima potencijal da značajno unapredi tačnost modela, čineći ga otpornijim na nepravilnosti i varijabilnosti u podacima.

Skalabilnost sistema predstavlja još jedan ključni izazov, naročito kod velikih infrastrukturnih objekata kao što su mostovi sa kompleksnim geometrijama i velikim brojem kritičnih tačaka. Ovi objekti zahtevaju specijalizovane modele i prilagođenu sensoriku kako bi se obuhvatila sva relevantna strukturalna i operativna stanja. Korišćenje distribuisanih sistema za prikupljanje i obradu podataka moglo bi unaprediti performanse modela u realnom vremenu, omogućavajući efikasnije detektovanje i predikciju anomalija.

Kako bi se prevazišli identifikovani izazovi i omogućila šira implementacija, predloženi su određeni ključni koraci.

Prvi korak predstavlja integraciju sa *IoT* tehnologijama: Postavljanje *IoT* senzora na ključne tačke mostova obezbedilo bi kontinuirano prikupljanje i analizu stvarnih podataka u realnom vremenu. Kombinovanjem ovih podataka sa prediktivnim modelima moguće je ostvariti preciznije predikcije i planirati intervencije pre nego što dođe do kritičnih kvarova, čime se smanjuje rizik od ozbiljnih oštećenja.

Drugi korak su lokalna prilagođavanja: Razvoj modela prilagođenih specifičnostima lokalnih infrastrukturnih objekata, kao što su razlike u materijalima, starost objekata i klimatski uslovi, može značajno povećati efikasnost i preciznost sistema. Ova prilagođavanja olakšavaju njegovu primenu u različitim geografskim i infrastrukturnim kontekstima.

Naredni korak bi bili pilot projekti: Realizacija pilot projekata na ključnim infrastrukturnim tačkama, poput mostova na auto-putevima ili u urbanim centrima, omogućila bi testiranje sistema u stvarnim uslovima. Ovi projekti ne samo da identifikuju potencijalne nedostatke, već i služe kao primer dobre prakse za širu implementaciju u nacionalnim okvirima.

Poslednji korak je obuka i edukacija: Organizacija obuka za tehničko osoblje koje će koristiti i održavati sistem doprinosi njegovoj uspešnoj implementaciji. Dugoročna održivost sistema može se osigurati edukacijom

osoblja o prednostima prediktivnih modela i njihovoj praktičnoj primeni, čime se povećava poverenje u tehnologiju i njena primenljivost.

Iako rezultati simulacija pružaju solidnu osnovu za dalju primenu, neophodno je usmeriti pažnju na integraciju sa stvarnim podacima i prilagođavanje lokalnim infrastrukturnim potrebama. Uz odgovarajuću implementaciju i kontinuirana unapređenja, ovakvi sistemi mogu postati osnov za modernizaciju i održivu digitalizaciju održavanja infrastrukture na nacionalnom nivou.

IV. IZAZOVI I BUDUĆI PRAVCI RAZVOJA

A. Ograničenja u primeni mašinskog učenja u urbanim sistemima

Primena mašinskog učenja u urbanim sistemima otvara nove mogućnosti za unapređenje infrastrukture i smanjenje troškova održavanja. Međutim, implementacija ovih tehnologija suočava se s brojnim ograničenjima koja utiču na njihovu efikasnost i prihvatanje u praksi. Jedan od osnovnih izazova jeste kompleksnost i varijabilnost urbanih sistema, što otežava izradu generalizovanih modela za predikciju kvarova i degradacije.

Prema istraživanju *Zhu* i saradnika (2024), jedno od ključnih ograničenja je potreba za velikim količinama podataka za treniranje modela mašinskog učenja. U urbanim sredinama, prikupljanje i obrada ovakvih podataka često su logistički i tehnički zahtevni. Mnogi senzorski podaci su nepotpuni ili nepouzdana, što dodatno komplikuje izradu tačnih modela [1]. Pored toga, nedostatak standardizovanih formata podataka otežava njihovu integraciju u postojeće IT sisteme i upotrebu u modelima za prediktivno održavanje.

Još jedno značajno ograničenje odnosi se na interpretabilnost algoritama mašinskog učenja. Napredni modeli, poput dubokih neuronskih mreža (eng. *Deep Neural Networks*, skraćeno *DNN*), često funkcionišu kao "crne kutije", što znači da korisnici nemaju uvid u način na koji model donosi odluke. Ovo može smanjiti poverenje operatera u predikcije sistema i otežati identifikaciju potencijalnih grešaka.

Zahtevnost resursa algoritama mašinskog učenja takođe predstavlja ograničenje. Prema radu *Band* i saradnika (2022), implementacija složenih modela, kao što su konvolucione neuronske mreže i rekurentne neuronske mreže, zahteva moćne hardverske resurse i značajna ulaganja u infrastrukturu. Ovo predstavlja izazov za manje razvijene gradove koji nemaju pristup savremenoj tehnologiji [3].

Specifični izazovi se javljaju i u vezi sa transferom tehnologija iz

istraživačkih okvira u praktične primene. Mnogi modeli mašinskog učenja razvijaju i testiraju u kontrolisanim uslovima, što ne odražava uvek složenost stvarnog okruženja u urbanim sredinama. Implementacija ovih modela u realnim sistemima često zahteva prilagođavanje, što dodatno povećava troškove i kompleksnost.

Na kraju, nedostatak stručnog kadra za implementaciju i održavanje sistema baziranih na mašinskom učenju takođe predstavlja značajno ograničenje. Primena ovih tehnologija zahteva specijalizovano znanje iz oblasti analitike podataka, mašinskog učenja i IT infrastrukture, što predstavlja izazov za mnoge gradske uprave.

Ova ograničenja ukazuju na potrebu za daljim istraživanjima i razvojem kako bi se prevazišli postojeći problemi i omogućila šira implementacija mašinskog učenja u urbanim sredinama.

B. Potencijalni pravci budućih istraživanja

Prediktivno održavanje u urbanim sredinama nudi izuzetan potencijal za unapređenje infrastrukture, ali postojeća ograničenja zahtevaju dodatna istraživanja kako bi se u potpunosti iskoristile mogućnosti ove tehnologije. Jedan od ključnih pravaca istraživanja je unapređenje tačnosti i pouzdanosti modela mašinskog učenja. Poseban fokus stavlja se na razvoj algoritama koji pružaju objašnjenje svojih odluka, poznatih kao objašnjiva veštačka inteligencija (eng. *Explainable AI*, skraćeno. *XAI*). Ovi modeli ne samo da povećavaju poverenje korisnika u rezultate analize, već omogućavaju transparentnije donošenje odluka u kritičnim infrastrukturnim sistemima. Na primer, implementacija *XAI* u infrastrukturnim aplikacijama može olakšati identifikaciju uzroka potencijalnih kvarova i omogućiti bolje prilagođavanje održavanja specifičnim potrebama sistema [4].

Transferno učenje predstavlja još jednu perspektivnu oblast istraživanja, jer omogućava prilagođavanje modela razvijenih za jednu vrstu infrastrukture, poput železnica, za primenu u drugim sektorima, kao što su energetske mreže. Na primer, modeli trenirani na podacima prikupljenim iz mostova mogu se prilagoditi za detekciju kvarova u zgradama, što smanjuje troškove razvoja i ubrzava proces implementacije. Ovo je naročito značajno u kontekstu urbanih sistema, gde raznovrsnost infrastrukture često predstavlja izazov za tradicionalne pristupe.

Razvoj naprednih senzorskih tehnologija i njihove integracije sa mašinskim učenjem jedan je od najvažnijih pravaca za buduća istraživanja. Savremeni *IoT* senzori koji simultano mere vibracije, temperaturu, vlagu i buku omogućavaju detaljniju analizu stanja sistema u realnom vremenu. Napredak u analizi podataka prikupljenih putem ovih senzora takođe je ključno područje budućih

istraživanja. Povezivanjem ovih senzora sa centralizovanim analitičkim platformama stvara se osnov za kompleksnije modele predikcije tako što se omogućava identifikacija obrazaca koji prethode kvarovima. Ovakva tehnologija može značajno unaprediti praćenje kritične infrastrukture poput mostova i puteva, čime se obezbeđuje blagovremena reakcija na potencijalne kvarove [5], [6].

Analitika velikih podataka takođe ostaje ključna oblast daljeg razvoja. Prikupljanje i obrada ogromnih količina podataka iz infrastrukturnih sistema pruža priliku za identifikaciju obrazaca koji prethode kvarovima. Na primer, analitika u realnom vremenu može omogućiti treniranje modela na dinamičkim podacima, čime se povećava preciznost predikcije. Razvoj metoda za efikasnu obradu podataka prikupljenih putem IoT uređaja ostaje prioritet, jer omogućava veću skalabilnost i prilagodljivost modela za različite tipove infrastrukture.

Pored tehnoloških inovacija, istraživanja moraju da se bave i pravnim i etičkim pitanjima koja prate implementaciju prediktivnog održavanja. Privatnost i sigurnost podataka postaju sve značajniji, posebno u urbanim sredinama gde se veliki broj senzora koristi za praćenje stanja infrastrukture. Potrebna je harmonizacija regulativnih okvira kako bi se obezbedila usklađenost sa zakonima o zaštiti podataka. Dodatno, standardizacija interoperabilnosti između različitih sistema i tehnologija može značajno olakšati primenu prediktivnog održavanja u urbanim sredinama [7].

Na kraju, multidisciplinarni pristup koji uključuje saradnju stručnjaka iz oblasti mašinskog učenja, urbanog planiranja, građevinarstva i prava može značajno doprineti razvoju održivih rešenja za prediktivno održavanje. Integracija različitih perspektiva omogućila bi bolje razumevanje specifičnih potreba infrastrukture i obezbedila dugoročne benefite u pogledu pouzdanosti i održivosti sistema. Takva rešenja ne samo da unapređuju efikasnost održavanja, već omogućavaju i optimalno korišćenje resursa, čime se dodatno smanjuju troškovi i povećava sigurnost u urbanim sredinama.

LITERATURA

- [1] Zhu T., Ran Y., Zhou X., & Wen Y. (2024). A Survey of Predictive Maintenance: Systems, Purposes and Approaches. arXiv:1912.07383v2
- [2] Waldhauser F., Boukabache H., Perrin D., & Dazer M. (2024). Generating Realistic Failure Data for Predictive Maintenance: A Simulation and cGAN-based Methodology. Proceedings of the 8th European Conference of the Prognostics and Health Management Society 2024 - ISBN – 978-1-936263-40-0, DOI:10.36001/phme.2024.v8i1.3951
- [3] Band S. S., Ardabili S., Sookhak M., Chronopoulos A. T., Elnaffar S., Moslehpour M., Csaba M., Torok B., Pai H.-T., & Mosavi A. (2022). When Smart Cities Get Smarter via Machine Learning: An In-Depth Literature Review. IEEE Access, DOI 10.1109/ACCESS.2022.3181718

- [4] Turri V. (2022) What is Explainable AI? Software Engineering Institute Blog. Preuzeto sa: <https://insights.sei.cmu.edu/blog/what-is-explainable-ai/>
- [5] Future Processing. (2023). The Future of Predictive Maintenance. Future Processing. Preuzeto sa: <https://www.future-processing.com/blog/the-future-of-predictive-maintenance/>
- [6] Artesis. (2024). The Future of Maintenance: How Predictive Strategies Are Revolutionizing Industry. Artesis Blog. Preuzeto sa: <https://www.artesis.com/the-future-of-maintenance-how-predictive-strategies-are-revolutionizing-industry/>
- [7] Soomro K., Bhutta N., Khan Z., & Tahir M. A. (2019). Smart City Big Data Analytics: An Advanced Review. Advanced Review

ABSTRACT

This paper explores the application of artificial intelligence in predictive maintenance of urban infrastructure, with a particular focus on bridges. A machine learning model was trained using simulated data to detect anomalies, analyzing key factors such as temperature, load, and vibrations. The evaluation demonstrated high model accuracy, highlighting its potential for practical implementation. The discussion addresses integration with IoT sensors and scalability in real-world scenarios, providing recommendations for further development. Challenges related to the availability of real-world data and the need for adaptable solutions are also analyzed, laying the groundwork for future research and practical applications.

APPLICATION OF ARTIFICIAL INTELLIGENCE IN PREDICTIVE MAINTENANCE OF URBAN INFRASTRUCTURE

Emilija Stojanović, Miloš Radenković