

Primljen / Received: 1.3.2026.

Ispravljen / Corrected: 16.6.2026.

Prihvaćen / Accepted: 24.6.2026.

Dostupno online / Available online: 10.10.2026.

Procjena lokacije i veličine curenja u vodoopskrbnim mrežama primjenom optimiranoga dvostupanjskog modela lokalizacije curenja

Autori:



Hillary M. Zodape, dipl.ing.građ.

Nacionalni tehnološki institut Visvesvaraya
Nagpur, Indija

Odjel za građevinarstvo

[hzodape@gmail.com](mailto:h zodape@gmail.com)

Autor za korespondenciju



Doc.dr.sc. **Shilpa R. Dongre**, dipl.ing.građ.

Nacionalni tehnološki institut Visvesvaraya
Nagpur, Indija

Odjel za građevinarstvo

shilpadongre@civ.vnit.ac.in

Izvorni znanstveni rad

Hillary M. Zodape, Shilpa R. Dongre

Procjena lokacije i veličine curenja u vodoopskrbnim mrežama primjenom optimiranoga dvostupanjskog modela lokalizacije curenja

Gubici vode u urbanim vodoopskrbnim mrežama velik su izazov u održivome upravljanju vodnim resursima i radu komunalnih poduzeća. Rano otkrivanje curenja i njegova precizna lokalizacija ključni su za smanjenje količine neprihodovane vode te očuvanje učinkovitosti mreže. U ovome radu predlaže se modelski okvir utemeljen na strojnome učenju koji objedinjuje statičke hidrauličke simulacije generirane programom EPANET i umjetnu neuronsku mrežu (engl. Artificial Neural Network – ANN) optimiranu algoritmom optimizacije roja čestica radi učinkovitog izdvajanja pojedinih pogonskih svojstava. Simulirani su podaci o tlaku za različite scenarije s curenjem i bez njega, pri čemu su pažljivo odabrani osjetljivi senzorski čvorovi kako bi se povećala točnost modela. Povezivanjem simulacijskih modela sa stvarnim radnim uvjetima vodoopskrbnog sustava predložena metoda uspješno integrira hidrauličko modeliranje i podatkovno utemeljeno učenje te potvrđuje velik potencijal hibridnog okvira za skalabilno i precizno otkrivanje, lokalizaciju i procjenu veličine curenja u vodoopskrbnim mrežama.

Ključne riječi:

vodoopskrbna mreža, hibridno strojno učenje, optimizacija rojem čestica (PSO), lokalizacija curenja, procjena veličine curenja

Original research paper

Hillary M. Zodape, Shilpa R. Dongre

Leak location and magnitude estimation in water distribution networks using an optimised two-stage leak localisation model

Water loss from urban water distribution networks (WDNs) challenges sustainable water management and utility operations. Early leak detection and accurate localisation are crucial for reducing non-revenue water and maintaining network efficiency. This study proposes a machine learning-based framework integrating EPANET-generated static hydraulic simulations with an artificial neural network (ANN) optimised using particle swarm optimisation (PSO) for effective feature extraction. Pressure data under various leak and no-leak scenarios were simulated, and sensitive sensor nodes were strategically selected to enhance accuracy. By bridging simulation and reality, this method successfully integrates hydraulic modelling with data-driven learning, demonstrating the hybrid framework's strong potential for scalable and accurate leak detection, localisation, and magnitude estimation in WDNs.

Key words:

water distribution network, hybrid machine learning, PSO, leak localization, leak magnitude

1. Uvod

Gubici vode u urbanim vodoopskrbnim mrežama (engl. *Water Distribution Networks* – WDN) znatan su izazov u održivome upravljanju vodnim resursima, osobito u zemljama u razvoju, gdje ograničena dostupnost resursa i nedostatna infrastruktura dodatno pogoršavaju taj problem. Međunarodna udruga za vode (engl. *International Water Association* – IWA) uspostavila je sveobuhvatne okvire za razumijevanje i kvantificiranje tih gubitaka, pri čemu zabrinjavajući statistički podaci potvrđuju hitnost potrebnih tehničkih rješenja [1]. Ekonomske posljedice jednako su ozbiljne. Prema navodima iz [2], ukupni trošak neprihodovane vode (engl. *Non-Revenue Water* – NRW) konzervativno se procjenjuje na oko 141 milijardu američkih dolara na godinu za komunalna vodovodna poduzeća diljem svijeta, pri čemu zemlje u razvoju stvaraju približno trećinu tih gubitaka. Nadalje, u radu [3] procijenjeno je približno 3800 oštećenja na jednoj vodoopskrbnoj mreži nakon seizmičkog događaja, uz troškove sanacije veće od 3,7 milijuna eura, što dodatno naglašava gospodarske posljedice nedostatnog nadzora mreže. Uzroci curenja mogu biti unutarnji ili vanjski te uključuju starenje infrastrukture, koroziju cjevovoda, materijalne nedostatke, nepravilnu ugradnju cijevi, prekomjerna prometna opterećenja iznad ukopanih cjevovoda te pomicanje tla [4]. Sve izraženiji nesklad između ograničene dostupnosti vode, zastarjele vodoopskrbne infrastrukture i rasta urbanog stanovništva čini učinkovito otkrivanje curenja u vodoopskrbnim mrežama jednim od ključnih izazova suvremenog upravljanja vodnim sustavima.

Suvremeni pristupi otkrivanju i lokalizaciji curenja u urbanim vodoopskrbnim mrežama obuhvaćaju širok spektar metoda, od kojih svaka ima specifične prednosti i operativna obilježja. Ovisno o primijenjenoj tehnici, metode se mogu podijeliti na hardverske i računalne. Hardverske metode temelje se na ugradnji fizičkih senzora i mjernih uređaja u vodoopskrbnu mrežu. Jedan od najčešćih pristupa jest akustička detekcija, pri kojoj se piezoelektrični senzori koriste za registriranje vibracija i zvučnih valova nastalih istjecanjem vode [5]. Ti su senzori vrlo osjetljivi te u kombinaciji sa suvremenim metodama obrade signala poput logaritamskih spektrograma i konvolucijskih neuronskih mreža (engl. *Convolutional Neural Networks* – CNN) mogu postići točnost detekcije veću od 99 % [6]. Metode koje se temelje na akustičkim vibracijama, koristeći kontaktne mikrofone ili vibroakustične senzore, također ostvaruju visoku osjetljivost, osobito kada su povezane sa sustavima za nadzor u stvarnome vremenu [7]. Ostali uređaji uključuju mjerače protoka i senzore tlaka koji registriraju nagle padove ili anomalije koje mogu upućivati na pojavu curenja. Elektromagnetski mjerači protoka postižu točnost od $\pm 0,2$ % te mogu detektirati pozadinska curenja protoka već od 0,2 l/s [8]. Međutim, te metode imaju određena ograničenja: njihova je ugradnja često invazivna, postavljanje senzora zahtijeva znatan radni angažman, a učinkovitost detekcije može se smanjiti zbog utjecaja okolišnog šuma ili dugotrajnog rada senzora [9]. Zbog

navedenih nedostataka, kao i visokih troškova i ograničene skalabilnosti, hardverske metode manje su prikladne za velike ili zastarjele vodoopskrbne sustave.

Nasuprot tome, računalne metode, uključujući modele temeljene na hidrauličkome modeliranju, statističke pristupe i metode utemeljene na podacima, izbjegavaju većinu navedenih ograničenja. Računalno otkrivanje curenja primjenjuje hidrauličke modele i algoritme strojnog učenja (engl. *Machine Learning* – ML) za prepoznavanje anomalija u podacima o tlaku, protoku i brzini strujanja. Simulacije hidrauličkog modela omogućuju određivanje reziduala tlaka i protoka u čvorovima i cjevovodima za različite scenarije curenja te usporedbu s referentnim stanjem bez curenja, čime se omogućuje vrlo precizno otkrivanje curenja [11]. U kombinaciji s algoritmima strojnog učenja poput umjetnih neuronskih mreža (engl. *Artificial Neural Networks* – ANN), konvolucijskih neuronskih mreža (CNN), metoda potpornih vektora (engl. *Support Vector Machines* – SVM) ili ansamblskog (kombiniranog) učenja (engl. *Ensemble Learning* – EL) takvi sustavi mogu učinkovito klasificirati događaje curenja i odrediti njihovu lokaciju [10]. Visoka točnost detekcije i lokalizacije može se postići uz dobro kalibrirane modele mreže [6]. Nadalje, kontrastivno učenje [11] i vremensko-frekvencijske konvolucijske neuronske mreže [12] dodatno poboljšavaju uspješnost rada u uvjetima prisutnosti šuma. Modeli dubokog učenja poput CNN-a primijenjenih na prostorne prikaze tlaka dobivene iz senzorskih podataka ostvaruju stopu istinitih pozitivnih detekcija do 98 % te znatno nadmašuju tradicionalne ručne ili isključivo akustičke metode pregleda [13]. Analiza signala i fuzija podataka temeljena na CNN-u [6, 11] pruža skalabilna, neinvazivna i kontinuirano unaprijeđena rješenja s velikim potencijalom za automatizaciju. Istodobno hardverske strategije rasporeda senzora poput lokaliziranih vibracijskih senzora ili bežičnih senzorskih mreža dodatno povećavaju pokrivenost metalnih i nemetalnih cjevovoda, čime senzorski sustavi postaju nezaobilazan dio suvremenih sustava za detekciju curenja. Takve senzorske mreže ne samo da skraćuju vrijeme reakcije na curenje i smanjuju gubitke vode, nego povećavaju operativnu učinkovitost te ekonomičnost sustava [14]. Za razliku od hardverskih metoda, računalni pristupi nisu invazivni, troškovno su učinkovitiji i lako se mogu primijeniti na velike sustave, što ih čini posebno pogodnima za nadzor u stvarnome vremenu i razvoj budućih pametnih vodoopskrbnih mreža.

Nedavna istraživanja primjene strojnog učenja u detekciji curenja u vodoopskrbnim mrežama pokazuju raznolikost primjene algoritama, ali istodobno otkrivaju velike nedostatke u optimizaciji arhitekture neuronskih mreža [11, 15, 16]. Metode potpornih vektora (engl. *Support Vector Machines* – SVM), uključujući hibridne modele SVM-CNN te pristupe temeljene na modelu MLT-KSVC unaprijeđenome metodom maksimalne entropije (engl. *Maximum Entropy version of Least Square Twin K-Class Support Vector Machine*), postižu obećavajuće rezultate u klasifikaciji, no često ne uključuju sustavno podešavanje hiperparametara, čime se ograničava njihov puni potencijal [17].

Grafikon neuronske mreže (engl. *Graph Neural Networks* – GNN) iskorištava topološku strukturu vodoopskrbnih mreža radi bolje sposobnosti generalizacije i dinamičkog usmjeravanja mreže, čime povećavaju otpornost modela. Međutim, istraživanja primjene GNN-a uglavnom zanemaruju procjenu veličine curenja te se pretežno usredotočuju na detekciju i lokalizaciju curenja.

Računalne metode za otkrivanje curenja uglavnom se temelje na pristupima vođenima podacima koji primjenjuju statističku analizu i obradu signala kako bi usporedbom abnormalnih i uobičajenih vrijednosti podataka prepoznali pojavu curenja u cjevovodnim sustavima. Metode strojnog učenja, uključujući konvolucijske neuronske mreže (CNN) i mreže s dugotrajnom kratkoročnom memorijom (engl. *Long Short-Term Memory* – LSTM), pokazale su veliku učinkovitost u analizi složenih obrazaca unutar vodoopskrbnih mreža [18–20]. Ti modeli upotrebljavaju povijesne podatke za prepoznavanje zakonitosti i obrazaca, čime se znatno smanjuje potreba za velikom količinom ulaznih informacija koja je svojstvena za klasične modele temeljene na fizikalnim zakonima [21]. Zahvaljujući sposobnosti razlikovanja skupova podataka koji odgovaraju stanjima s curenjem i bez njega, algoritmi strojnog učenja iz ulaznih podataka razvijaju prediktivne modele. Točnost i učinkovitost detekcije dodatno su povećane upotrebom velikih količina senzorskih i operativnih podataka, osobito podataka o tlaku i protoku prikupljenih na mjernim postajama za potrebe treniranja modela strojnog učenja. Istraživanja [22, 23] pokazala su da modeli CNN i LSTM mogu postići točnost detekcije između 90,56 % i 98,23 %, čime nadmašuju tradicionalne statističke metode. Napredni modeli kodera-dekoderu poput LSTM autoenkodera posebno su učinkoviti u obradi vremenskih nizova podataka o tlaku te ostvaruju manju stopu lažno pozitivnih detekcija [13]. Nadalje, integracija različitih vrsta podataka, uključujući akustične zapise i hidrauličke parametre, omogućuje prilagodljivo otkrivanje curenja u stvarnome vremenu, zbog čega su modeli strojnog učenja prikladni za primjenu u suvremenim sustavima pametne vodne infrastrukture [20]. Hibridni modeli koji objedinjuju hidrauličke simulacije i metode strojnog učenja pružaju veću robusnost zahvaljujući mogućnosti korekcije pogrešaka, ali se pritom suočavaju s izazovima povećane računalne složenosti i ograničene skalabilnosti u velikim mrežama [24, 25]. Automatizacijom analize senzorskih podataka strojno učenje skraćuje vrijeme i smanjuje troškove upravljanja curenjima te istodobno povećava preciznost njihove detekcije [14, 20, 26, 27]. Iako njegova učinkovitost uvelike ovisi o kvaliteti raspoloživih podataka i pravilnome podešavanju modela, sve veća uloga strojnog učenja u optimiranju rada vodoopskrbnih mreža važan je doprinos održivome upravljanju vodnim resursima.

Tlak ima ključnu ulogu u detekciji curenja u vodoopskrbnim mrežama jer čak i malo curenje može uzrokovati mjerljivu promjenu tlaka, dok se protok i potrošnja prirodno mijenjaju tijekom dana zbog uobičajenih obrazaca potrošnje vode [28]. Točna procjena rada vodoopskrbne mreže zahtijeva istodobno razmatranje hidrauličkih parametara i vjerojatnosti otkaza pojedinih komponenti, što opravdava primjenu metoda

temeljenih na podacima koje mogu opisati odnose između tlaka i protoka u mrežnim čvorovima [29]. Tlak odražava hidrauličko stanje cijele mreže jer reagira na promjene uzrokovane curenjem čak i kada je senzor udaljen od mjesta njegova nastanka [30]. Zbog toga je tlak u čvorovima stabilniji, kontinuirani i prostorno raspodijeljeni signal, što omogućuje pouzdanu procjenu približne lokacije curenja [31]. Budući da intenzitet curenja ovisi o tlaku, analiza ovisna o tlaku (engl. *Pressure-Driven Analysis* – PDA) realističniji je pristup hidrauličkome modeliranju vodoopskrbnih mreža u uvjetima nedostatnog tlaka u odnosu na tradicionalnu analizu vođenu potrošnjom (engl. *Demand-Driven Analysis* – DDA) [32]. PDA dinamički prilagođava istjecanje vode stvarnome raspoloživom tlaku te vjernije simulira pojave poput curenja, puknuća cjevovoda ili naglog povećanja potrošnje [33], pri čemu omogućuje detekciju curenja prikazom smanjenja potrošnje uzrokovanog padom tlaka. Osim toga, PDA sprječava nerealne procjene protoka, uključujući negativne tlakove koji se često pojavljuju pri primjeni DDA-e u uvjetima opterećenja mreže [34, 35], poboljšava modeliranje kakvoće vode tijekom događaja s niskim tlakom te omogućuje preciznije procjene protoka u udaljenim čvorovima kada dolazi do pada tlaka [36, 37]. Nadalje, PDA čini fizikalno utemeljenu osnovu za razvoj modela strojnog učenja jer osigurava hidraulički konzistentne skupove podataka. Time se znatno povećavaju točnost i sposobnost generalizacije modela poput umjetnih neuronskih mreža pri procjeni veličine i lokalizaciji curenja u uvjetima promjenjivog tlaka [38, 39].

U ovome radu razvijen je klasifikacijski model za identifikaciju čvorova s curenjem u vodoopskrbnoj mreži primjenom hibridnog modela umjetne neuronske mreže i metode potpornih vektora (ANN-SVM). Predloženi pristup objedinjuje prednosti obje metode predviđanja, pri čemu se posebna pozornost posvećuje aktivacijskim funkcijama, algoritmima učenja i skaliranju podataka. Hibridni okvir učenja temelji se na izdvajanju značajki primjenom umjetne neuronske mreže te na njihovoj klasifikaciji pomoću metode potpornih vektora. Takav pristup omogućuje učinkovitije opisivanje složenih obilježja curenja te povećava učinkovitost njegove detekcije. Iskorištavanjem sposobnosti umjetne neuronske mreže da prepozna složene obrasce raspodjele tlaka i sposobnosti SVM-a da pouzdano razlikuje međusobno slične klase postiže se veća točnost lokalizacije i bolja prediktivna stabilnost modela, čime se osigurava robusniji proces donošenja odluka unatoč pojedinačnim ograničenjima svake od metoda.

Umjetne neuronske mreže (engl. *Artificial Neural Networks* – ANN) računalni su modeli inspirirani strukturom i načinom funkcioniranja ljudskog mozga. ANN sastoji se od međusobno povezanih procesnih jedinica, odnosno neurona, organiziranih u ulazni, jedan ili više skrivenih, te izlazni sloj. Svaki neuron izračunava ponderirani zbroj ulaznih vrijednosti, dodaje odstupanje (*bias*) te primjenjuje aktivacijsku funkciju poput sigmoidne funkcije, hiperboličkog tangensa ili funkcije ispravljenih linearnih jedinica (engl. *Rectified Linear Unit* – ReLU) kako bi se u model uvela nelinearnost. Umjetne neuronske mreže razvijene su za prepoznavanje obrazaca, učenje iz

podataka te za predviđanja ili donošenje odluka [40]. Njihova široka primjena proizlazi iz sposobnosti modeliranja složenih i nelinearnih odnosa između ulaznih i izlaznih varijabli bez potrebe za eksplicitnim matematičkim opisom tih odnosa [41, 42].

Umjetne neuronske mreže najčešće se primjenjuju u zadacima klasifikacije i regresije. U klasifikacijskim problemima model svrstava ulazne podatke u unaprijed definirane kategorije primjenom aktivacijskih funkcija poput sigmoidne funkcije ili funkcije *softmax* te funkcija gubitka kao što je unakrsna entropija (engl. *cross-entropy*) [43]. U regresijskim problemima mreža predviđa kontinuirane vrijednosti, pri čemu se za treniranje najčešće primjenjuju srednja kvadratna pogreška (engl. *Mean Squared Error* – MSE) ili srednja apsolutna pogreška (engl. *Mean Absolute Error* – MAE). Učenje teče propagacijom podataka prema naprijed kroz mrežu (engl. *forward propagation*) te povratnim širenjem pogreške (engl. *backpropagation*) uz optimiranje metodom gradijentnog spusta [44]. Tijekom uzastopnih epoha treniranja težinski koeficijenti iterativno se prilagođavaju kako bi se minimizirala pogreška predviđanja.

Metoda potpornih vektora (engl. *Support Vector Machine* – SVM) nadzirani je algoritam strojnog učenja koji se primjenjuje u klasifikacijskim i regresijskim problemima te se temelji na teoriji statističkog učenja. Posebno je učinkovit u rješavanju višedimenzionalnih problema (višeparametarski problemi) te se najčešće koristi kao binarni klasifikator, iako se može proširiti i na višeklasne probleme [45]. Temeljno načelo rada SVM-a jest određivanje optimalne granice odlučivanja, odnosno hiperravnine, koja razdvaja podatke različitih klasa. Od svih mogućih hiperravnina odabire se ona koja maksimizira marginu, odnosno udaljenost između granice razdvajanja i najbližih podataka iz svake klase [46]. Ti podaci nazivaju se potpornim vektorima (engl. *support vectors*) te upravo oni određuju položaj granice odlučivanja i omogućuju bolju sposobnost generalizacije modela uz smanjenje pretreniranosti (engl. *overfitting*).

Nakon što umjetna neuronska mreža izdvoji značajke iz ulaznih podataka, SVM radi s numeričkim vektorima značajki umjesto s izvornim podacima. Ako su izdvojene značajke linearno razdvojive, dovoljna je primjena linearne hiperravnine. Međutim, podaci iz stvarnih sustava najčešće su nelinearni. U takvim slučajevima SVM upotrebljava tzv. trik-jezgre (engl. *kernel trick*), kojima se ulazni podaci implicitno preslikavaju u višedimenzionalni prostor u kojemu linearno razdvajanje postaje moguće. Najčešće korištene funkcije jezgre uključuju radijalnu baznu funkciju (engl. *Radial Basis Function* – RBF) i polinomijalnu jezgru [27]. Za višeklasnu klasifikaciju strategija „jedan protiv jednog“ (engl. *one-against-one*) pokazala se vrlo učinkovitom jer omogućuje visoku razinu točnosti prepoznavanja uz relativno malu računalnu složenost [47].

Među različitim hibridnim modelima strojnog učenja razvijenima za detekciju curenja u vodoopskrbnim mrežama kombinacija umjetne neuronske mreže i metode potpornih vektora pokazala se posebno učinkovitom. Za razliku od drugih hibridnih modela poput kombinacija ANN-a sa slučajnim šumama (engl. *Random Forest*) ili Naïve Bayes klasifikatorom, model ANN–

SVM uspješno objedinjuje dvije komplementarne prednosti: sposobnost umjetne neuronske mreže za modeliranje složenih nelinearnih odnosa u podacima o tlaku te iznimnu sposobnost SVM-a za generalizaciju i precizno određivanje granica između klasa. Sinergijskim djelovanjem tih dvaju pristupa postižu se bolji rezultati u detekciji curenja nego primjenom pojedinačnih modela.

Treniranjem modela na poznatoj strukturi vodoopskrbne mreže korištenjem povijesnih ili simuliranih podataka predloženi hibridni okvir sustavu omogućuje identifikaciju lokacije curenja pri obradi novih, realističnih skupova statičkih podataka. Na taj način uspješno se kombiniraju prepoznavanje obrazaca i klasifikacija, što taj pristup čini praktičnim i skalabilnim rješenjem za nadzor curenja u stvarnim vodoopskrbnim sustavima.

Jedno od glavnih ograničenja dosadašnjih istraživanja vodoopskrbnih mreža jest široko rasprostranjena primjena unaprijed definiranih arhitektura umjetnih neuronskih mreža bez sustavne optimizacije hiperparametara. Brojne studije koriste unaprijed zadane konfiguracije mreže koje su često proizvoljno odabrane, premda optimalna arhitektura uvelike ovisi o svojstvima raspoloživih podataka [24, 48, 49]. Iako su u drugim inženjerskim područjima potvrđene prednosti sustavnih metoda optimizacije poput metodologije odzivne površine (engl. *Response Surface Methodology* – RSM), njihova je primjena u području vodoopskrbnih sustava još uvijek vrlo ograničena [50]. Optimizacija umjetnih neuronskih mreža za detekciju curenja u vodoopskrbnim mrežama najčešće se provodi primjenom algoritma optimiranja roja čestica (engl. *Particle Swarm Optimisation* – PSO), genetskih algoritama (engl. *Genetic Algorithms* – GA) ili Levenberg-Marquardtova algoritma (LM), s ciljem određivanja optimalnih hiperparametara i povećanja točnosti modela [51–53]. Međutim, primjena PSO-a za optimizaciju hiperparametara umjetnih neuronskih mreža u tome području još uvijek nije dovoljno istražena. Premda su umjetne neuronske mreže optimirane algoritmom PSO u brojnim primjenama pokazale bržu konvergenciju i veću točnost [54], cjelovite implementacije PSO-ANN modela za detekciju curenja u vodoopskrbnim mrežama i dalje su rijetke. Taj istraživački nedostatak velika je prilika za unapređenje metoda detekcije curenja primjenom sustavne optimizacije arhitekture neuronskih mreža, iskorištavajući globalne mogućnosti pretraživanja i robusnost algoritma PSO.

PSO se često preferira u odnosu na genetske algoritme i Bayesovu optimizaciju (engl. *Bayesian Optimisation* – BO) pri podešavanju hiperparametara umjetnih neuronskih mreža zbog brže konvergencije i jednostavnije implementacije. Taj algoritam učinkovito optimira kontinuirane hiperparametre poput stope učenja i broja neurona dinamičkim prilagođavanjem položaja čestica na temelju najboljih pojedinačnih i globalnih rješenja [54]. Za razliku od genetskih algoritama, PSO zahtijeva manji broj upravljačkih parametara te izbjegava složene operacije križanja i mutacije. U usporedbi s Bayesovom optimizacijom, PSO postiže bolje rezultate u pretraživanju višedimenzionalnog prostora jer ne zahtijeva izgradnju zamjenskih (surogatnih) modela [55].

Tablica 1. Usporedba različitih metoda optimizacije

Aspekt	PSO (optimiranje roja čestica)	GA (genetski algoritam)	Bayesova optimizacija
Brzina konvergencije	Brzo	Umjereno	Umjereno
Lokalna profinjenost	Dobro	Umjereno	Snažno
Računalno opterećenje	Nisko do umjereno	Visoko	Umjereno
Najbolji slučaj upotrebe	Kontinuirano podešavanje	Diskretni parametri	Mali prostor za pretraživanje

Ravnoteža između istraživanja prostora rješenja i iskorištavanja već pronađenih kvalitetnih rješenja čini PSO robusnim i računalno učinkovitim algoritmom za optimizaciju arhitekture umjetnih neuronskih mreža. Zbog male računalne složenosti, brzog konvergiranja i izvrsnih svojstava u kontinuiranim prostorima parametara kao što su stopa učenja i broj neurona PSO posebno je prikladan izbor. Kao što je to prikazano u tablici 1., genetski algoritmi zahtijevaju znatna računalna sredstva za izvođenje operacija križanja i mutacije, dok PSO uz manji broj evaluacija učinkovitije pretražuje prostor mogućih rješenja. Iako Bayesova optimizacija postiže izvrsne rezultate u manjim i računalno zahtjevnim prostorima pretraživanja primjenom surogatnih modela, PSO omogućuje preciznije lokalno usavršavanje rješenja uz manji broj iteracija [55-57].

Sve izraženiji problem gubitaka vode u urbanim vodoopskrbnim mrežama zahtijeva razvoj preciznih i računalno učinkovitih metoda za detekciju curenja. U ovome radu taj se problem rješava predlaganjem ugrađenoga dvostupanjskog okvira za lokalizaciju curenja koji integrira umjetnu neuronsku mrežu i metodu potpornih vektora (engl. *Support Vector Machine* – SVM). Model umjetne neuronske mreže optimiran je algoritmom optimizacije roja čestica (engl. *Particle Swarm Optimisation* – PSO) radi povećanja razine točnosti učenja sustavnim podešavanjem parametara mreže. Za određivanje najosjetljivijih mjernih čvorova (senzorskih čvorova), pogodnih za učinkovitu detekciju curenja, primijenjena je srednja apsolutna razlika (engl. *Mean Absolute Difference* – MAD). Budući da umjetna neuronska mreža učinkovito opisuje složene nelinearne odnose između tlaka i protoka, dok metoda potpornih vektora pokazuje izvrsnu sposobnost generalizacije na skupovima podataka s prisutnim šumom ili ograničenim brojem uzoraka, dodjeljivanje veće težine predviđanjima ANN-a omogućuje pouzdanije donošenje odluka u uvjetima stvarne eksploatacije sustava [58, 59].

U prvome stupnju predloženi hibridni model ANN-SVM određuje točnu lokaciju curenja, odnosno čvor u kojemu se ono pojavljuje, dok se u drugome stupnju procjenjuje veličina curenja primjenom podataka o tlaku i protoku dobivenih analizom ovisnom o tlaku (engl. *Pressure-Driven Analysis* – PDA). Predložena metodologija usmjerena je na povećanje točnosti detekcije, pouzdanosti lokalizacije i preciznosti procjene veličine curenja, čime pridonosi učinkovitijemu ublažavanju posljedica curenja i upravljanju vodoopskrbnim sustavima.


Procjena veličine curenja u vodoopskrbnim mrežama provodi se primjenom više etabliranih metodologija, prilagođenih različitim radnim uvjetima sustava. Hidraulički modeli temeljeni

na simulacijama, koje su prvi razvili autori rada [60], primjenjuju Bayesovo zaključivanje u kombinaciji s analizom reziduala tlaka kako bi kalibrirali sve moguće unaprijed simulirane scenarije curenja. Takvim pristupom istodobno se procjenjuju lokacija i veličina curenja uz uvažavanje nesigurnosti mjerenja i varijabilnosti potrošnje. Metode fuzije senzorskih podataka, prikazane u radu [61], integriraju mjerenja ulaznog protoka, podatke senzora u stvarnome vremenu i modele prognoziranih potrošnje radi utvrđivanja prisutnosti curenja. U radu [62] predložena je integracija umjetne inteligencije za prepoznavanje obrazaca, modeliranja prostora stanja za identifikaciju curenja te proširenoga Kalmanova filtra za preciznu procjenu njegove lokacije. S druge strane, autori rada [1] identificirali su curenje u cjevovodu primjenom inverznoga matematičkog pristupa kojim se analiziraju promjene amplitude odziva tlaka u rezonantnim uvjetima, koristeći izmjerene frekvencijski odziv prolaznih tlakova kako bi se odredili lokacija i veličina curenja.

Pojava curenja u vodoopskrbnoj mreži uzrokuje lokalizirani pad tlaka koji utječe i na okolne potrošne čvorove i na čvor u kojemu je došlo do curenja. Analiza ovisna o tlaku (PDA) opisuje takvo ponašanje prilagodbom istjecanja vode iz potrošnih mjesta i samog curenja raspoloživome tlaku u svakome čvoru mreže. Time se vjerno opisuje odnos između tlaka i istjecanja, koji se uobičajeno modelira jednadžbom otvora (engl. *orifice equation*), prema kojoj veće curenje uzrokuje izraženiji pad tlaka. Posljedica toga je smanjenje protoka kroz mjesto curenja, ali i smanjenje opskrbe povezanih potrošača. Nadalje, skupovi podataka generirani analizom ovisnom o tlaku, koji uključuju nelinearnu dinamiku odnosa između tlaka i protoka tijekom pojave curenja, kvalitetniji su ulazni podaci za treniranje modela strojnog učenja poput umjetnih neuronskih mreža. Time se povećavaju njihova točnost i sposobnost generalizacije pri detekciji i procjeni veličine curenja u stvarnim vodoopskrbnim sustavima.

2. Metodologija

Primarni cilj ovog istraživanja jest identifikacija pojedinačnog curenja u vodoopskrbnoj mreži (engl. *Water Distribution Network* – WDN). Na slici 1. prikazan je dijagram tijeka predložene metodologije. Postupak se sastoji od sljedećih uzastopnih koraka: I. simulacije curenja i hidrauličke analize – za zadanu vodoopskrbnu mrežu u model se učitava ulazna datoteka programa EPANET. Curenje se simulira nasumičnim odabirom koeficijenta istjecanja, tj. curenja (engl. *emitter coefficient*), nakon čega se provodi hidraulička analiza mreže.



Slika 1. Dijagram toka metodologije

- II. određivanja optimalnog broja senzorskih čvorova
- III. optimizacije arhitekture umjetne neuronske mreže i provedbe njezine hibridizacije s metodom potpornih vektora (SVM)
- IV. identifikacije čvora koji curi i procjene veličine curenja.

Simulacija podataka razvijena je u programskome okruženju MATLAB, koji je povezan s programom EPANET radi provođenja hidrauličke analize. Hibridni model ANN-SVM implementiran je u programski jezik Python. Detaljan opis pojedinih koraka metodologije prikazan je u nastavku.


3. Primjena metodologije na mrežu Hanoi

3.1. Generiranje podataka

Proširena vodoopskrbna mreža Hanoi (*Extended Hanoi WDM*) referentna je mreža koja je prvi put predstavljena u radu [63], a temelji se na planiranoj magistralnoj vodoopskrbnoj mreži grada Hanoijsa u Vijetnamu. Mreža se sastoji od 34 cjevovoda povezana sa spremnikom te 31 potrošnog čvora. Raspored elemenata vodoopskrbne mreže Hanoi prikazan je na slici 2. Program MATLAB simulira različite scenarije pojedinačnih curenja u mreži modeliranoj u programu EPANET 2.2. Pretpostavlja se da se curenja pojavljuju u čvorovima mreže. Za svaki od ukupno 10.000 uzoraka nasumično se odabire jedan čvor u kojemu se curenje simulira dodjeljivanjem slučajno odabranoga koeficijenta istjecanja u rasponu od 0,2 do 0,7. Rezultati simulacije, odnosno tlakovi u svim čvorovima za scenarije bez curenja i sa simuliranim curenjem, pohranjuju se u matricu podataka. Vrijednosti tlakova u svim čvorovima, indeks čvora u kojemu je simulirano curenje te pripadajući koeficijent istjecanja korišteni su za izradu označenih (engl. *labelled*) skupova podataka za treniranje modela za detekciju curenja. Čvor kojemu je dodijeljen nasumično odabrani koeficijent istjecanja jest scenarij curenja. Takav pristup zadržava fizikalni odnos između tlaka i protoka primjenom eksponencijalne jednadžbe istjecanja (1), čime se osigurava realistična simulacija ponašanja curenja:

$$Q_{\text{Leak}} = C \cdot P^r \quad (1)$$

Modeliranje curenja u čvorovima ujedno pojednostavljuje generiranje podataka za potrebe strojnog učenja. U izrazu (1) Q_{Leak} predstavlja volumen vode koji istječe u jedinici vremena, C koeficijent istjecanja, a P raspoloživi tlak u odabranome čvoru mreže.



Slika 2. Mreža za distribuciju vode proširene mreže Hanoi

3.2. Postavljanje senzora

Senzori imaju ključnu ulogu u učinkovitoj detekciji i lokalizaciji curenja u vodoopskrbnim mrežama jer omogućuju nadzor sustava u stvarnome vremenu i brzo otkrivanje događaja curenja. Optimalno raspoređeni senzori tlaka osiguravaju prostorno raspodijeljena mjerenja unutar mreže, čime se omogućuju statistička analiza tlakova u čvorovima te precizna detekcija i lokalizacija curenja.

Razvijeni pseudokod MATLAB provodi niz postupaka za određivanje čvorova najveće osjetljivosti na pojavu curenja primjenom diferencijalnih tlakova, slika 3. Broj senzora tlaka u mreži određen je u skladu s preporukama iz rada [64]. Program učitava podatke o tlakovima iz dviju Excelovih datoteka, referentnog stanja bez curenja i različitih scenarija curenja, nakon čega se za svaki scenarij izračunava razlika u tlakovima oduzimanjem odgovarajućih redaka. Na taj se način formira matrica diferencijalnih tlakova koja se potom pohranjuje za daljnju analizu.

Kako bi se kvantificirala prosječna promjena tlaka u svakome čvoru za sve simulirane scenarije curenja, algoritam učitava podatke o diferencijalnim tlakovima iz prethodno generirane datoteke te za svaki čvor (odnosno svaki stupac matrice) izračunava srednju apsolutnu razliku (engl. *Mean Absolute Difference* – MAD). Osjetljivost čvorova određuje se njihovim rangiranjem prema silaznome redoslijedu vrijednosti MAD-a. Za raspored senzora odabran je stupanj pokrivenosti od 20 % mreže, odnosno sedam senzorskih čvorova, čime se osigurava odgovarajuća prostorna pokrivenost uz izbjegavanje nepotrebno visokih troškova ugradnje.

```

STORE in "difference_result.xlsx" = leak_pressure - no_leak_
pressure"
READ data from file "difference_result.xlsx"
STORE it in RESULT_MATRIX
(Rows = leak_scenarios, Columns = nodes)

FOR each node (each column in RESULT_MATRIX)
  CALCULATE absolute value of all differences
  COMPUTE mean of those absolute values
  STORE this in MEAN_DIFF for that node
END FOR
SORT MEAN_DIFF in descending order
STORE sorted values in SORTED_DIFF
STORE corresponding node numbers in SORTED_NODES

SET TOTAL_NODES = number of columns in RESULT_MATRIX

CALCULATE N = 20% of TOTAL_NODES
ROUND N up to nearest whole number

SELECT first N elements from SORTED_NODES → TOP_NODES
SELECT first N elements from SORTED_DIFF → TOP_DIFF_
VALUES

PRINT "Top N nodes (20% of total) with highest average
differential pressure"

FOR i = 1 to N
  PRINT TOP_NODES[i], TOP_DIFF_VALUES[i]
END FOR

```

Slika 3. Program za određivanje čvorova najveće osjetljivosti na pojavu curenja

Takav udio omogućuje strateško postavljanje senzora u hidraulički najosjetljivije i najutjecajnije čvorove, čime se osigurava pouzdana detekcija curenja i drugih anomalija uz istodobno očuvanje računalne i operativne učinkovitosti sustava [64]. Nakon toga izdvajaju se vrijednosti srednjih apsolutnih razlika za najbolje rangirane čvorove, čime se korisniku omogućuje identifikacija čvorova koji su najosjetljiviji na promjene tlaka uzrokovane pojavom curenja.

3.3. Hibridni model strojnog učenja

Predloženi hibridni model ANN-SVM objedinjuje sposobnost umjetne neuronske mreže za izdvajanje nelinearnih značajki sa sposobnošću metode potpornih vektora za preciznu klasifikaciju. Taj dvostupanjski model lokalizacije curenja povećava točnost, sposobnost generalizacije i robusnost sustava, omogućuje učinkovito modeliranje složenih hidrauličkih obrazaca te poboljšava identifikaciju curenja u velikim i nelinearnim vodoopskrbnim mrežama.

3.3.1. Optimizacija modela umjetne neuronske mreže


Kod umjetnih neuronskih mreža konfiguracija modela i ključni hiperparametri, uključujući broj skrivenih slojeva, broj neurona u svakome sloju i stopu učenja, često se određuju metodom pokušaja i pogreške (engl. *trial-and-error*) [40, 54, 65], što je dugotrajan i računalno neučinkovit postupak. Sustavna optimizacija od ključne je važnosti zbog složenosti prilagodbe velikog broja težinskih koeficijenata unutar nekonveksnog prostora funkcije gubitka višedimenzionalnosti, koji sadržava velik broj lokalnih minimuma i sedlastih točaka. Zbog toga treba primijeniti iterativne optimizacijske postupke poput gradijentnog spusta, pri kojima se težinski koeficijenti ažuriraju postupkom povratnog širenja pogreške (engl. *backpropagation*), kako bi se postigla učinkovita konvergencija modela i dobra sposobnost generalizacije. Nasuprot tome, treniranje metodom potpornih vektora problem je konveksne optimizacije, pri kojemu postoji jedinstveni globalni minimum, čime se izbjegava potreba za složenim iterativnim prilagođavanjem težinskih koeficijenata svojstvenima za umjetne neuronske mreže.

Za optimizaciju arhitekture umjetne neuronske mreže razvijen je prilagođeni algoritam optimizacije roja čestica (engl. *Particle Swarm Optimisation* – PSO). Algoritam je konfiguriran s brojem od 20 čestica te je izveden tijekom 30 iteracija. Svaka je čestica jedno moguće rješenje, odnosno konfiguracija umjetne neuronske mreže definirana trima hiperparametrima: brojem skrivenih slojeva (u rasponu od 1 do 3), brojem neurona u svakome sloju (od 5 do 100) te stopom učenja (od 0,001 do 0,1). U svakoj iteraciji kvaliteta pojedinog rješenja procjenjuje se na temelju srednje kvadratne pogreške (engl. *Mean Squared Error* – MSE), nakon čega se najbolje pronađena konfiguracija odabire za konačno treniranje modela.

3.3.2. Hibridni model

Umjetne neuronske mreže vrlo su učinkovite u modeliranju složenih nelinearnih odnosa poput međudjelovanja tlaka i protoka, osobito kada su dostupni veliki skupovi podataka [40]. Međutim, sklone su pretreniranosti (engl. *overfitting*) te zahtijevaju pažljivo podešavanje hiperparametara. S druge strane, metoda potpornih vektora odlikuje se izraženom sposobnošću generalizacije i postiže robusne rezultate čak i na manjim skupovima podataka optimiranjem margine između klasa u skladu s načelima teorije statističkog učenja [66, 67]. Njihovo ograničenje očituje se u slabijoj sposobnosti učenja složenih nelinearnih ovisnosti kada izdvojene značajke nisu dovoljno reprezentativne.

Predloženi hibridni okvir ANN-SVM ublažava navedena ograničenja tako što umjetnu neuronsku mrežu koristi za izdvajanje značajki, dok se metodom potpornih vektora provodi završna klasifikacija. Na taj se način povećavaju točnost, stabilnost i pouzdanost modela u različitim radnim uvjetima vodoopskrbnog sustava [68]. Na slici 4. prikazan je predloženi hibridni model. Predloženi hibridni okvir temelji se na dvostupanjskome sekvencijalnom postupku. U prvome koraku umjetna neuronska



Slika 4. Dvostupanjski model lokalizacije curenja

mreža trenirana je na vrijednostima tlaka izmjerenima u odabranim mjernim čvorovima kako bi naučila nelinearne hidrauličke obrasce povezane s različitim scenarijima curenja. Izlazni sloj mreže generira reprezentaciju značajki koja opisuje odnose između tlaka i protoka u vodoopskrbnoj mreži. Tako dobiveni vektori značajki izravno se proslijeđuju metodi potpornih vektora, koji određuje optimalnu hiperravninu razdvajanja radi klasifikacije lokacije curenja među 31 mogućim čvorom mreže.

Prije treniranja modela ulazni podaci o tlaku normalizirani su primjenom min-max normalizacije, pri čemu su sve vrijednosti skalirane u raspon od 0 do 1. Time je osigurano da sve ulazne značajke jednako doprinose procesu učenja umjetne neuronske mreže.

Skup podataka podijeljen je u tri podskupa: 70 % podataka korišteno je za treniranje modela, 10 % za validaciju, a preostalih 20 % za testiranje, čime je omogućena pouzdana procjena uspješnosti razvijenog modela.

Simulacije i treniranje modela provedeni su u programskome okružju MATLAB R2023b na računalu s operacijskim sustavom Windows 11, procesorom Intel Core i7, 16 GB radne memorije

te instaliranim paketima Neural Network Toolbox i Global Optimization Toolbox. Po završetku treniranja i validacije hibridni model ispitivan je na prethodno nekorištenim podacima, pri čemu je njegova klasifikacijska točnost korištena kao osnovni pokazatelj uspješnosti modela.

U tablici 2. prikazani su glavni parametri koji određuju rad hibridnog modela ANN-SVM. Predloženi dvostupanjski model lokalizacije curenja temelji se na pristupu prilagodljivo ostvarenim performansama modela. Takav pristup smanjuje broj lažno pozitivnih detekcija te omogućuje jednostavnu skalabilnu

primjenu na vodoopskrbnim mrežama različitih veličina, zbog čega predstavlja učinkovito rješenje za nadzor vodoopskrbnih sustava u stvarnome vremenu i za dijagnostiku kvarova primjenom metoda temeljenih na podacima.

3.4. Procjena veličine curenja

Analiza ovisna o tlaku (engl. *Pressure-Driven Analysis* – PDA) procjenjuje hidrauličko ponašanje vodoopskrbne mreže na temelju stvarno raspoloživog tlaka u svakome čvoru. Kada je tlak u čvoru niži od potrebnog tlaka, zahtijevana potrošnja ne može se u cijelosti zadovoljiti te više nije konstantna vrijednost, nego postaje funkcija tlaka. Definiranjem veličina Q_{req} (potrošnja pri referentnome tlaku u normalnim uvjetima, bez curenja), P_{req} (referentni tlak u promatranome čvoru u scenariju bez curenja), P_{act} (trenutačni tlak u čvoru u kojemu je predviđeno curenje) i Q_{act} (stvarna potrošnja u čvoru, koja uključuje redovitu potrošnju i gubitke uslijed curenja) njihov se međusobni odnos može opisati izrazom:

$$Q_{act} = Q_{req} (P_{act}/P_{req})^\alpha \tag{2}$$

Tablica 2. Detalji hibridnog okvira učenja

Parametri	ANN	SVM	
Vrsta mreže	Prepoznavanje uzoraka s povratnom vezom	Funkcija jezgre	Radikalna bazna funkcija (RBF)
	Broj skrivenih slojeva: 3	Broj binarnih	Klasifikatori : 465 (31×30/2)
	1. Relu – 34	Strategija	Jedan protiv jednog
	2. Relu – 50	Bias:	-0,197
	3. Softmax – 85		
Veličina ulaza	7 x 310000		
Veličina izlaza	1 x 310000		
Funkcija gubitka	Unakrsna entropija		
Trening: Validacija: Test	70 : 10 : 20		
Odabrani čvorovi	(NS-8, NS-12, NS-15, NS-21, NS-24, NS-28 i NS-31)		
Brzina učenja	0,04	Faktor skaliranja	0,1

Izraz (2) omogućuje da se potrošnja i intenzitet curenja prilagođavaju promjenama tlaka, čime se postiže preciznija procjena veličine curenja. Eksponent tlaka, α , postavljen je na univerzalnu vrijednost 0,5 [38]. Takav dinamički odnos od velike je važnosti pri analizi curenja jer količina vode koja istječe izravno ovisi o raspoloživoj tlačnoj visini na mjestu curenja.


Dinamičko međudjelovanje tlaka i protoka omogućuje realističniji prikaz hidrauličkog stanja vodoopskrbne mreže tijekom pojave curenja. Posljedično, analiza ovisna o tlaku omogućuje precizniju procjenu veličine curenja uzimajući u obzir činjenicu da su gubici vode izravno ovisni o tlaku u sustavu. Istodobno, PDA poboljšava lokalizaciju curenja simuliranjem širenja promjena tlaka kroz mrežu, pri čemu se formiraju prostorne raspodjele (konture) tlaka koje predstavljaju pouzdanu osnovu za primjenu metoda inverznog modeliranja.

4. Rezultati i rasprava


Analizom podataka o tlaku ili protoku prikupljenih u stvarnome vremenu pomoću senzora raspoređenih u vodoopskrbnoj mreži moguće je odrediti prisutnost, količinu i lokaciju curenja. Hidraulički odziv sustava na padove tlaka ili anomalije protoka korišten je za utvrđivanje mjesta nastanka i intenziteta curenja. Takav je pristup temelj brojnih suvremenih metoda detekcije curenja [40, 69, 70] te čini osnovu za raspravu o rezultatima prikazanim u ovome istraživanju.

4.1. Optimalna konfiguracija umjetne neuronske mreže određena primjenom algoritma PSO

Optimalna arhitektura umjetne neuronske mreže određena je primjenom algoritma optimizacije roja čestica (engl. *Particle Swarm Optimisation* – PSO), kojim su optimirani broj skrivenih slojeva, broj neurona u svakome sloju i stopa učenja. Na slici 5. prikazana je promjena srednje kvadratne pogreške (engl. *Mean Squared Error* – MSE) tijekom treniranja optimalno konfigurirane umjetne neuronske mreže. Vrijednost MSE smanjila se s približno 0,0012 na 0,0009 u prvih deset iteracija, nakon čega se stabilizirala. Takav trend upućuje na uspješnu konvergenciju modela, odnosno na postizanje minimuma funkcije gubitka uz zanemariva daljnja poboljšanja u nastavku procesa optimizacije.



Slika 5. MSE u odnosu na broj epoha za optimalnu arhitekturu u arhitekturi umjetne neuronske mreže



Slika 6. Krivulja treniranja ekstraktora značajki umjetne neuronske mreže tijekom 50 epoha

4.2. Usporedba hibridnog modela ANN-SVM i pojedinačnih modela

Umjetna neuronska mreža razvijena je za prepoznavanje i učenje obrazaca raspodjele tlaka karakterističnih za lokalizaciju curenja. Kao ulazne varijable korišteni su podaci o tlaku prikupljeni sa sedam senzorskih čvorova. Za prepoznavanje obrazaca implementirana je unaprijedna neuronska mreža (engl. *feedforward neural network*) trenirana algoritmom povratnog širenja pogreške (engl. *backpropagation*) uz optimizaciju gradijentnim spustom. Na slici 6. prikazana je krivulja treniranja umjetne neuronske mreže tijekom procesa izdvajanja značajki. Krivulja treniranja pokazuje stabilnu konvergenciju tijekom 50 epoha, pri čemu nije uočena pojava pretreniranosti (engl. *overfitting*). Točnost na skupu za treniranje i skupu za validaciju

Tablica 3. Ukupne metrike performansi ANN-a, SVM-a i hibridnog ANN-SVM-a

Model	Makropreciznost	Makroodziv	Makro F1	Ponderirana preciznost	Ponderirani odziv	Ponderirani F1
ANN	0,812	0,673	0,775	0,944	0,918	0,926
SVM	0,694	0,548	0,673	0,875	0,842	0,851
ANN+SVM	0,950	0,966	0,956	0,951	0,967	0,957

konvergirala je prema vrijednosti od približno 0,97 te je tijekom cijelog procesa ostala gotovo podudarna. Svi rezultati dobiveni su izvođenjem cjelokupnog postupka uz unaprijed definirano početno stanje generatora slučajnih brojeva (engl. *fixed random seed*), čime je osigurana potpuna ponovljivost rezultata. Visok stupanj podudarnosti između krivulja točnosti za treniranje i validaciju potvrđuje da je model uspješno naučio opće hidrauličke obrasce raspodjele tlaka koji se mogu primijeniti na nove podatke, umjesto da je zapamtio pojedinačne primjere iz skupa za treniranje. Model umjetne neuronske mreže dodatno je validiran primjenom neovisnog skupa podataka kako bi se spriječila pojava pretreniranosti.

Značajke izdvojene umjetnom neuronskom mrežom zatim su proslijeđene nadziranome višeklasnom klasifikacijskom modelu s metodom potpornih vektora, koji razlikuje ukupno 31 klasu, odnosno 31 mogući čvor curenja, te omogućuje preciznu identifikaciju čvora u kojemu se curenje pojavilo. Uspješnost razvijenoga hibridnog modela procijenjena je primjenom pokazatelja preciznosti, odziva i F1 mjere (engl. *F1-score*), čije su vrijednosti prikazane u tablici 3. Radi objektivne procjene učinkovitosti predloženog pristupa, isti je problem riješen i primjenom pojedinačnih modela ANN i SVM.

Rezultati prikazani u tablici 3. omogućuju jasnu usporedbu klasifikacijskih svojstava svih triju modela te pokazuju da hibridni model ostvaruje dosljedno bolje rezultate u odnosu na pojedinačne modele.


Za procjenu i usporedbu klasifikacijske uspješnosti svih triju modela korištene su matrice zabune (*confusion matrices*), prikazane na slikama od 7.a do 7.c. Matrica zabune jedno je od temeljnih sredstava za analizu klasifikacijskih modela jer

omogućuje detaljan uvid u njihovu uspješnost prikazujući koliko je puta pojedina klasa ispravno ili pogrešno klasificirana. Svaka ćelija matrice prikazuje broj predviđanja za određenu klasu, dok elementi na glavnoj dijagonali predstavljaju ispravno klasificirane primjere.


Radi procjene sposobnosti svih triju modela u identifikaciji pojedinačnog curenja konstruirane su ROC krivulje (engl. *Receiver Operating Characteristic*), prikazane na slici 8. ROC krivulja prikazuje odnos između stope istinitih pozitivnih klasifikacija (engl. *True Positive Rate* – TPR) i stope lažno pozitivnih klasifikacija (engl. *False Positive Rate* – FPR) za različite pragove odlučivanja. Površina ispod ROC krivulje (engl. *Area Under the Curve* – AUC) jedinstveni je pokazatelj kvalitete klasifikacijskog modela, pri čemu veće vrijednosti AUC-a upućuju na bolju sposobnost razlikovanja stanja s curenjem i bez njega. Dijagonalna linija prikazuje uspješnost slučajne klasifikacije, dok krivulje koje se nalaze iznad nje upućuju na bolju klasifikacijsku učinkovitost modela.

Poboljšane performanse hibridnog modela ANN-SVM rezultat su njegove komplementarne strukture, u kojoj umjetna neuronska mreža učinkovito izdvaja složene nelinearne obrasce raspodjele tlaka, dok metoda potpornih vektora provodi robusnu klasifikaciju na temelju optimalnih granica između klasa. Takva sinergija omogućuje bolje rezultate prikazane ROC krivuljom te znatno strmiji porast stope istinitih pozitivnih klasifikacija (TPR) u odnosu na pojedinačne modele ANN i SVM.


Vrijednost AUC-a izračunana je primjenom makrousprednjene strategije jedan protiv svih (engl. *macro-averaged one-versus-rest*) za svaki 31 čvor mreže na ispitnome skupu podataka. ROC krivulja hibridnog modela vrlo brzo doseže gotovo maksimalnu



Slika 7. Matrica konfuzije za: a) ANN model; b) SVM model; c) hibridni ANN-SVM model



Slika 8. Krivulja radnih karakteristika prijemnika za ANN, SVM i hibridne modele



Slika 9. Gubitak u odnosu na broj epoha za hibridnu metodologiju

vrijednost stope istinitih pozitivnih klasifikacija pri stopi lažno pozitivnih klasifikacija od približno 0,01, što potvrđuje da taj model ostvaruje najbolju razlučivost klasa među svih triju ispitanih pristupa. Hibridni model ostvario je vrijednost AUC = 0,9983 te makroprosječni odziv (engl. *macro-recall*) od 0,9662, što dodatno potvrđuje njegovu visoku učinkovitost u lokalizaciji curenja.

Na slici 9. prikazana je promjena vrijednosti funkcije gubitka po epohi za hibridni model, čime se prikaz točnosti modela nadopunjuje prikazom procesa minimizacije pogreške

tijekom treniranja. Funkcija gubitka mjeri odstupanje između predviđenih i stvarnih izlaznih vrijednosti modela, pri čemu manje vrijednosti funkcije gubitka upućuju na bolje performanse modela. U početnim fazama treniranja vrijednosti funkcije gubitka za skupove podataka za treniranje i validaciju bile su relativno visoke, ali su se tijekom prvih deset epoha naglo smanjile te su nastavkom treniranja dosegnule vrlo niske, gotovo zanemarive vrijednosti. Tako izražen pad upućuje na učinkovitu optimizaciju težinskih koeficijenata postupkom povratnog širenja pogreške (engl. *backpropagation*) uz prilagodljivo podešavanje stope učenja. Stabilizacija funkcije gubitka nakon približno 40 epoha pokazuje da je model postigao konvergenciju, pri čemu daljnje treniranje više ne doprinosi znatnijemu poboljšanju performansi. Nadalje, gotovo paralelan tijek krivulja funkcije gubitka za skupove za treniranje i validaciju potvrđuje da model nije pokazivao sklonost ni pretreniranosti (engl. *overfitting*) ni nedovoljnime treniranju (engl. *underfitting*). Njihova međusobna podudarnost potvrđuje dosljedan proces učenja i stabilne performanse modela na različitim skupovima podataka.

Prikazi točnosti po epohi (slika 6.) i funkcije gubitka po epohi (slika 9.) zajedno opisuju proces učenja i ponašanje razvijenoga hibridnog modela ANN-SVM tijekom treniranja i validacije.

Postupno smanjenje srednje kvadratne pogreške (engl. *Mean Squared Error* – MSE) potvrđuje uspješnu konvergenciju modela, dok ROC krivulja potvrđuje njegovu visoku klasifikacijsku sposobnost. Kombinacija niske vrijednosti MSE-a, male funkcije gubitka po epohi i vrlo velike površine ispod

ROC krivulje (engl. *Area Under the Curve* – AUC) upućuje na dobro istreniran, stabilan i vrlo diskriminativan hibridni model sposoban razlikovati i vrlo male promjene hidrauličkih uvjeta uzrokovane pojavom curenja. Dobiveni rezultati potvrđuju da umjetna neuronska mreža optimirana algoritmom optimizacije roja čestica (engl. *Particle Swarm Optimisation* – PSO) učinkovito minimizira pogrešku predviđanja, dok komponenta metode potpornih vektora povećava pouzdanost odlučivanja i sposobnost generalizacije modela. Tijekom ispitivanja model je pokazao stabilnu sposobnost generalizacije, što

je karakteristično za dobro reguliran klasifikacijski sustav. Sveukupno, kombinacija visoke razine točnosti i vrlo male vrijednosti funkcije gubitka potvrđuje učinkovitost hibridnog modela ANN-SVM, uspješnost optimizacije njegovih parametara te njegovu visoku prediktivnu sposobnost pri određivanju lokacije i veličine curenja u vodoopskrbnoj mreži. Dobiveni rezultati potvrđuju pouzdanost i stabilnost predloženoga hibridnog pristupa za primjenu u stvarnim sustavima za detekciju curenja.

4.3. Procjena veličine curenja

Analiza ovisna o tlaku (engl. *Pressure-Driven Analysis* – PDA) omogućuje realističan prikaz hidrauličkog ponašanja vodoopskrbne mreže u uvjetima curenja ili smanjenog tlaka. Primjenom raspoloživog tlaka i stvarnog protoka u promatranome čvoru veličina curenja određena je primjenom izraza (2).

Kao primjer prikazana je procjena veličine curenja u čvoru 30 primjenom PDA metode. Nakon što model predviđi čvor u kojemu se pojavilo curenje (naprimjer, čvor 30), u izraz PDA metode uključuju se trenutačni tlak izmjeren u uvjetima curenja te referentni tlak koji odgovara normalnome pogonskom stanju bez curenja. Budući da je raspodjela tlakova u mreži pri normalnim radnim uvjetima unaprijed poznata, ona prikazuje referentno stanje bez gubitaka vode. Tlakovi izmjereni u stvarnome vremenu zatim se uspoređuju s referentnim tlakovima dobivenima PDA analizom kako bi se utvrdila odstupanja svojstvena za potencijalna curenja.

Referentna potrošnja prikazuje protok pri punome pogonskom tlaku u uvjetima normalnog rada, dok stvarna potrošnja obuhvaća ukupni izlazni protok iz čvora, odnosno redovitu potrošnju i protok izgubljen uslijed curenja. Veličina curenja određuje se kao razlika između referentne i stvarne potrošnje. Procijenjena veličina curenja vrlo se dobro podudarala s vrijednošću koeficijenta istjecanja korištenog u simulacijama provedenima u programu EPANET, čime je potvrđena visoka točnost procjene temeljene na PDA metodi.

Predviđeni broj čvora curenja je: 30


Unesite trenutni tlak na čvoru 30 (s curenjem): 1,28637

Unesite referentni tlak na čvoru 30 (bez curenja): 1,34

Unesite referentnu potražnju na čvoru 30 (bez curenja): 29,17

Unesite eksponent tlaka "n" (tipično = 0,5): 0,5

Procijenjena stvarna potražnja na čvoru 30 (stvarno + curenje): 29,7719 l/s



Slika 10. Točnost predviđanja curenja u odnosu na stvarnu veličinu curenja

Uspješnost modela za procjenu veličine curenja, prikazanog na slici 10., procijenjena je primjenom srednje apsolutne pogreške (engl. *Mean Absolute Error* – MAE), korijena srednje kvadratne pogreške (engl. *Root Mean Square Error* – RMSE) i koeficijenta determinacije (R^2). Usporedba procijenjenih i stvarnih veličina curenja, prikazana na slici 10., pokazuje izraženu linearnu povezanost potvrđenu visokom vrijednošću koeficijenta determinacije. Model je ostvario vrijednosti MAE = 0,0502, RMSE = 0,0544 i R^2 = 0,9076, što upućuje na malu pogrešku u predviđanju i veliku sposobnost objašnjenja varijabilnosti podataka. Niske vrijednosti pokazatelja MAE i RMSE potvrđuju da PDA metoda omogućuje preciznu procjenu veličine curenja te da su dobivene procjene u vrlo dobrome skladu sa simulacijama curenja temeljenima na koeficijentu istjecanja u programu EPANET. Sveukupno, dobiveni rezultati potvrđuju pouzdanost i učinkovitost predloženog modela za procjenu veličine curenja u uvjetima primjene analize ovisne o tlaku.

4.4. Rasprava

Predloženi hibridni model ANN-SVM pokazao je znatno poboljšanje u odnosu na samostalne ANN i SVM modele u detekciji curenja u hanojskoj mreži. Optimizacijom ključnih hiperparametara ANN modela primjenom algoritma rojenja čestica (PSO) postignuti su brža konvergencija, smanjenje pogrešaka tijekom učenja te poboljšana sposobnost generalizacije modela. Hibridni ANN-SVM model ostvario je samo tri pogreške klasifikacije na ukupno 2000 testnih uzoraka. Nasuprot tome, samostalni ANN model imao je 22 pogreške klasifikacije, koncentrirane između susjednih čvorova 13 i 14,

dok je SVM pokazao širu konfuziju između klasa čvorova, što odražava ograničenja klasifikacije izravnih vrijednosti tlaka bez prethodno naučenih reprezentacija značajki.

Krivulja učenja ANN modela pokazala je povećanje točnosti s 0,156 u prvoj epohi na 0,970 u desetoj epohi, pri čemu su krivulje točnosti za skup podataka za učenje i validaciju ostale međusobno vrlo bliske tijekom svih 50 epoha, bez pokazatelja prenaučivosti (engl. *overfittinga*). ROC krivulje pokazale su vrijednost površine ispod krivulje (AUC) od 0,9983 za hibridni model, dok su oba samostalna modela ostvarila niže vrijednosti. Za procjenu veličine curenja primijenjen je PDA pristup (engl. *Pressure-Driven Analysis*), jer realističnije opisuje hidrauličko ponašanje sustava pri promjenjivim uvjetima tlaka. Za razliku od DDA pristupa (engl. *Demand-Driven Analysis*), PDA uzima u obzir izlazne protoke koji ovise o tlaku, zbog čega je prikladniji za preciznu kvantifikaciju curenja. Iako model pokazuje visoku učinkovitost predikcije, ograničen je na scenarij s jednim mjestom curenja. U slučaju višestrukih curenja može doći do smanjenja performansi modela, preklapanja tlačnih odziva te nedostatka izraženih hidrauličkih interakcija između čvorova, što otežava razlikovanje obrazaca. To ograničenje upućuje na potrebu za daljnjim istraživanjima radi povećanja razine pouzdanosti modela i proširenja njegove primjene na složenije scenarije s više istodobnih curenja.

5. Zaključak

Detekcija curenja u vodovodnim distribucijskim mrežama (WDN) ključna je za smanjenje gubitaka vode koja ne donosi prihod (engl. *non-revenue water*), osiguravanje pouzdanosti sustava i održivo upravljanje vodnim resursima. Precizna identifikacija lokacije curenja jako je važna, osobito u stvarnim sustavima u kojima je raspoloživ ograničen broj statičkih senzora tlaka. Učinkovito postavljanje senzora znatno je poboljšalo mogućnost detekcije curenja u ovome istraživanju. Konkretno, primjenom

metode apsolutne srednje razlike tlaka između stanja s curenjem i bez curenja identificirano je sedam čvorova visoke osjetljivosti. Taj pristup temeljen na podacima pokazao se praktičnim za stvarne mreže s unaprijed definiranim rasporedom senzora jer omogućuje optimalno prikupljanje informacija potrebnih za učenje modela.

Hibridni dvostupanjski model za lokalizaciju curenja ANN-SVM-SVM pokazao je visoku učinkovitost klasifikacije koristeći nelinearnu sposobnost preslikavanja ANN-a i preciznije definiranje granica odlučivanja pomoću SVM-a. Ta integracija poboljšala je robusnost i točnost pojedinačnih modela. Nadalje, ANN optimiran pomoću PSO algoritma dodatno je poboljšao performanse podešavanjem hiperparametara, čime je omogućena brža konvergencija i bolja sposobnost generalizacije. Nakon faze učenja hibridni model postigao je visoku točnost u identifikaciji čvorova s curenjem te je pokazao stabilne performanse pri unosu novih skupova podataka za scenarije s jednim curenjem. Time je potvrđena njegova pouzdanost u praktičnim primjenama u kojima su modeli prethodno obučeni i testirani na stvarnim statičkim podacima.

Za procjenu veličine curenja korištena je PDA metoda, koja omogućuje realističan prikaz potražnje ovisne o tlaku. Model je pokazao visoku točnost i fizičku konzistentnost pri izračunu veličine curenja, uz male vrijednosti pogrešaka i snažno podudaranje između predviđenih i stvarnih vrijednosti. Time je potvrđeno da je predloženi pristup istodobno računalno učinkovit i hidraulički opravdan.

U području detekcije curenja, gdje su heterogenost podataka i promjenjivi radni uvjeti sustava uobičajeni, ponderirani ansambl modela mogu povećati pouzdanost, smanjiti broj lažno pozitivnih detekcija i omogućiti prilagodbu specifičnim svojstvima pojedinih mreža. Istraživanja hibridnih metoda detekcije temeljenih na umjetnoj inteligenciji potvrđuju da ansambl-pristupi, posebno ponderirani modeli, kontinuirano postižu veću klasifikacijsku točnost i veću robusnost.

LITERATURA

- [1] Lambert, M.F., Simpson, A.R., Vítkovský, J.P., Wang, X.J., Lee, P.J.: A Review of Leading-Edge Leak Detection Techniques for Water Distribution Systems, Proceedings of the 20th AWA Ozwater Conference, 2003.
- [2] Kingdom, B., Liemberger, R., Marin, P.: The Challenge of Reducing Non-Revenue Water (NRW) in Developing Countries: How the Private Sector Can Help: A Look at Performance-Based Service Contracting, Water Supply and Sanitation Sector Board Discussion Paper Series, No. 8, 2006.
- [3] Halkijević, I., et al.: Damage assessment of water supply networks due to seismic events using vulnerability functions, 73 (2021), pp. 737–749.
- [4] Chan, T.K., Chin, C.S., Zhong, X.: Review of Current Technologies and Proposed Intelligent Methodologies for Water Distributed Network Leakage Detection, IEEE Access, 6 (2018), pp. 78846–78867, <https://doi.org/10.1109/ACCESS.2018.2885444>.
- [5] Adedeji, K.B., Hamam, Y., Abe, B.T., Abu-Mahfouz, A.M.: Leakage detection and estimation algorithm for loss reduction in water piping networks, Water, 9 (2017) 10, pp. 1–21, <https://doi.org/10.3390/w9100773>.
- [6] Peng, H., Xu, Z., Huang, Q., Qi, L., Wang, H.: Leakage Detection in Water Distribution Systems Based on Logarithmic Spectrogram CNN for Continuous Monitoring, Journal of Water Resources Planning and Management, 150 (2024) 6, pp. 1–12, <https://doi.org/10.1061/JWRMD5.WRENG-6276>.
- [7] Bykerk, L.: Vibro-Acoustic Distributed Sensing for Large-Scale Leak Detection of Mains, 2022.
- [8] Yu, T.T., Peng, W.F., Chen, H.M., Hsu, C.L., Deng, S.L.: Applying Electrical Magnetic Coil and In-Pipe INS to Map Underground Pipeline Track, Journal of Pipeline Systems Engineering and Practice, 15 (2024) 1, pp. 1–11, <https://doi.org/10.1061/JPSEA2.PSENG-1530>.

- [9] Joseph, K., et al.: Leak and Burst Detection in Water Distribution Network Using Logic- and Machine Learning-Based Approaches, *Water*, 16 (2024) 14, <https://doi.org/10.3390/w16141935>.
- [10] Kammoun, M., Kammoun, A., Abid, M.: Leak Detection Methods in Water Distribution Networks: A Comparative Survey on Artificial Intelligence Applications, *Journal of Pipeline Systems Engineering and Practice*, 13 (2022) 3, pp. 1–15, [https://doi.org/10.1061/\(ASCE\)PS.1949-1204.0000646](https://doi.org/10.1061/(ASCE)PS.1949-1204.0000646).
- [11] Wu, Y., et al.: Advancing deep learning-based acoustic leak detection methods towards application for water distribution systems from a data-centric perspective, *Water Research*, 261 (2024), Article 121999, <https://doi.org/10.1016/j.watres.2024.121999>.
- [12] Guo, G., et al.: Leakage Detection in Water Distribution Systems Based on Time–Frequency Convolutional Neural Network, *Journal of Water Resources Planning and Management*, 147 (2021) 2, pp. 1–11, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001317](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001317).
- [13] Karimanzira, D.: Simultaneous Pipe Leak Detection and Localization Using Attention-Based Deep Learning Autoencoder, *Electronics*, 12 (2023) 22, <https://doi.org/10.3390/electronics12224665>.
- [14] Rajan, G., Li, S.: A Systematic Literature Review on Flow Data-Based Techniques for Automated Leak Management in Water Distribution Systems, *Smart Cities*, 8 (2025) 3, <https://doi.org/10.3390/smartcities8030078>.
- [15] Li, J., Zheng, W., Lu, C.: An Accurate Leakage Localization Method for Water Supply Network Based on Deep Learning Network, *Water Resources Management*, 36 (2022) 7, pp. 2309–2325, <https://doi.org/10.1007/s11269-022-03144-x>.
- [16] Zaman, D., Tiwari, M.K., Gupta, A.K., Sen, D.: A review of leakage detection strategies for pressurised pipeline in steady-state, *Engineering Failure Analysis*, 109 (2020), Article 104264, <https://doi.org/10.1016/j.engfailanal.2019.104264>.
- [17] Leak, N., Algorithm, D., Distribution, W., Giresse, N., Mathonsi, T.E., Owolawi, P. A.: *The Indonesian Journal of Computer Science*, 14 (2025) 2, pp. 2589–2609.
- [18] Tornyeiadzi, H.M., Mohammed, H., Seidu, R.: Semi-supervised anomaly detection methods for leakage identification in water distribution networks: A comparative study, *Machine Learning with Applications*, 14 (2023), Article 100501, <https://doi.org/10.1016/j.mlwa.2023.100501>.
- [19] Islam, M.R., Azam, S., Shanmugam, B., Mathur, D.: A Review on Current Technologies and Future Direction of Water Leakage Detection in Water Distribution Network, *IEEE Access*, 10 (2022), pp. 107177–107201, <https://doi.org/10.1109/ACCESS.2022.3212769>.
- [20] Mounce, S.R., Mounce, R.B., Boxall, J.B.: Novelty detection for time series data analysis in water distribution systems using support vector machines, *Journal of Hydroinformatics*, 13 (2011) 4, pp. 672–686, <https://doi.org/10.2166/hydro.2010.144>.
- [21] Hu, X., Zhang, H., Ma, D., Wang, R.: Status detection from spatial-temporal data in pipeline network using data transformation convolutional neural network, *Neurocomputing*, 358 (2019), pp. 401–413, <https://doi.org/10.1016/j.neucom.2019.05.020>.
- [22] Lee, C.W., Yoo, D.G.: Development of leakage detection model and its application for water distribution networks using RNN-LSTM, *Sustainability*, 13 (2021) 16, <https://doi.org/10.3390/su13169262>.
- [23] Zhang, A.H., et al.: Anomaly Localization by Applying Data-Driven Analysis and Parallel Optimization of Hydraulic Model Calibration, 2024, p. 6, <https://doi.org/10.3390/engproc2024069006>.
- [24] Schaller, M., Steininger, M., Dulny, A., Schlör, D., Hotho, A.: Liquor-HGNN: A heterogeneous graph neural network for leakage detection in water distribution networks, *CEUR Workshop Proceedings*, 3630 (2023), pp. 454–469.
- [25] Yang, G., Wang, H.: Optimal Pressure Sensor Deployment for Leak Identification in Water Distribution Networks, *Sensors*, 23 (2023) 12, <https://doi.org/10.3390/s23125691>.
- [26] Mashford, J., De Silva, D., Burn, S., Marney, D.: Leak detection in simulated water pipe networks using SVM, *Applied Artificial Intelligence*, 26 (2012) 5, pp. 429–444, <https://doi.org/10.1080/08839514.2012.670974>.
- [27] Mazaev, G., Weyns, M., Vancoillie, F., Vaes, G., Ongenaes, F., Van Hoecke, S.: Probabilistic leak localization in water distribution networks using a hybrid data-driven and model-based approach, *Water Supply*, 23 (2023) 1, pp. 162–178, <https://doi.org/10.2166/ws.2022.416>.
- [28] Kashani, M.G., Hosseini, M., Aziminejad, M.: Reliability assessment of water distribution network using informational entropy considering design/hydraulic parameters, 69 (2017), pp. 547–559.
- [29] Romero-Ben, L., Alves, D., Blesa, J., Cembrano, G., Puig, V., Duviella, E.: Leak Localization in Water Distribution Networks Using Data-Driven and Model-Based Approaches, *Journal of Water Resources Planning and Management*, 148 (2022) 5, pp. 1–14, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001542](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001542).
- [30] Pérez, R., Puig, V., Pascual, J., Quevedo, J., Landeros, E., Peralta, A.: Methodology for leakage isolation using pressure sensitivity analysis in water distribution networks, *Control Engineering Practice*, 19 (2011) 10, pp. 1157–1167, <https://doi.org/10.1016/j.conengprac.2011.06.004>.
- [31] Pandya, N.C., Popawala, R., Yadav, S.M.: Effect of leakage location on pressure deficiency index of water distribution network, *ISH Journal of Hydraulic Engineering*, 29 (2023) 4, pp. 427–436, <https://doi.org/10.1080/09715010.2022.2094731>.
- [32] Neelakantan, T.R., Rohini, K.: Simplified Pressure-Driven Analysis of Water Distribution Network and Resilience Estimation, *Journal of Water Resources Planning and Management*, 147 (2021) 3, pp. 1–5, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001349](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001349).
- [33] Yoo, D.G., Suh, M.Y., Kim, J.H., Jun, H., Chung, G.: Subsystem-Based Pressure Dependent Demand Analysis in Water Distribution Systems Using Effective Supply, *KSCSE Journal of Civil Engineering*, 16 (2012), pp. 457–464, <https://doi.org/10.1007/s12205-012-1448-1>.
- [34] Ravi, S.C., Renganathan, N.T., Perumal, S., Paez, D.: Analysis of water distribution network under pressure-deficient conditions through emitter setting, 2019, pp. 1–13.
- [35] Alberti, A.R., Cavalcante, C.A.V., Scarf, P., Silva, A.L.O.: Modelling inspection and replacement quality for a protection system, *Reliability Engineering & System Safety*, 176 (2018), pp. 145–153, <https://doi.org/10.1016/j.res.2018.04.002>.
- [36] Tabesh, M., Tanyimboh, T.T., Burrows, R.: Pressure dependent stochastic reliability analysis of water distribution networks, 2002, pp. 81–90.
- [37] Vaidya, D.R., Gupta, R.: Pressure Dependent Analysis of Water Distribution Network Having Different Required Pressure Values at Different Nodes, *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 48 (2024) 2, pp. 1009–1019, <https://doi.org/10.1007/s40996-023-01183-x>.
- [38] Sousa, J., Martinho, N., Muranho, J., Marques, A. S.: Leakage Calibration in Water Distribution Networks with Pressure-Driven Analysis: A Real Case Study, 2020, pp. 1–8, <https://doi.org/10.3390/environsciproc2020002059>.
- [39] Rahmati, M., Yazdizadeh, H., Yazdizadeh, A.: Leakage detection in a gas pipeline using artificial neural networks based on wireless sensor network and Internet of Things, *Proceedings of the IEEE 15th International Conference on Industrial Informatics (INDIN 2017)*, pp. 659–664, 2017, <https://doi.org/10.1109/INDIN.2017.8104850>.
- [40] Barradas, I., Garza, L.E., Morales-Menendez, R., Vargas-Martínez, A.: Leaks detection in a pipeline using artificial neural networks, *Lecture Notes in Computer Science*, 5856 (2009), pp. 637–644, https://doi.org/10.1007/978-3-642-10268-4_75.

- [41] Mahdi, N.M., Jassim, A.H., Abulqasim, S.A., Basem, A., Ogaili, A.A.F., Al-Haddad, L.A.: Leak detection and localization in water distribution systems using advanced feature analysis and an Artificial Neural Network, *Desalination and Water Treatment*, 320 (2024), Article 100685, <https://doi.org/10.1016/j.dwt.2024.100685>.
- [42] Caputo, A.C., Pelagagge, P.M.: An inverse approach for piping networks monitoring, *Journal of Loss Prevention in the Process Industries*, 15 (2002) 6, pp. 497–505, [https://doi.org/10.1016/S0950-4230\(02\)00036-0](https://doi.org/10.1016/S0950-4230(02)00036-0).
- [43] Lee, S.J., Lee, G., Suh, J.C., Lee, J.M.: Online Burst Detection and Location of Water Distribution Systems and Its Practical Applications, *Journal of Water Resources Planning and Management*, 142 (2016) 1, pp. 1–11, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000545](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000545).
- [44] Jalal, D., Ezzedine, T.: Decision Tree and Support Vector Machine for Anomaly Detection in Water Distribution Networks, *Proceedings of the 2020 International Wireless Communications and Mobile Computing Conference (IWCMC)*, pp. 1320–1323, 2020, <https://doi.org/10.1109/IWCMC48107.2020.9148431>.
- [45] Rashid, S., Akram, U., Khan, S.A.: WML: Wireless sensor network based machine learning for leakage detection and size estimation, *Procedia Computer Science*, 63 (2015), pp. 171–176, <https://doi.org/10.1016/j.procs.2015.08.329>.
- [46] Hsu, C.W., Lin, C.J.: A Comparison of Methods for Multiclass Support Vector Machines, *IEEE Transactions on Neural Networks*, 13 (2002) 2, pp. 415–425.
- [47] Bello, O., Abu-Mahfouz, A. M., Hamam, Y., Page, P.R., Adedeji, K. B., Pillar, O.: Solving management problems in water distribution networks: A survey of approaches and mathematical models, *Water*, 11 (2019) 3, <https://doi.org/10.3390/w11030562>.
- [48] Rajeswaran, A., Narasimhan, S., Narasimhan, S.: A graph partitioning algorithm for leak detection in water distribution networks, *Computers and Chemical Engineering*, 108 (2018), pp. 11–23, <https://doi.org/10.1016/j.compchemeng.2017.08.007>.
- [49] Sadeghian, M., Sadeghi, M., Hesampour, M., Moheb, A.: Application of response surface methodology (RSM) to optimize operating conditions during ultrafiltration of oil-in-water emulsion, *Desalination and Water Treatment*, 2014, pp. 37–41, <https://doi.org/10.1080/19443994.2014.919607>.
- [50] Antunes, A., Ferreira, B., Marques, N., Carriço, N.: Hyperparameter Optimization of a Convolutional Neural Network Model for Pipe Burst Location in Water Distribution Networks, 2023.
- [51] Romero-Ben, L., Alves, D., Blesa, J., Cembrano, G., Puig, V., Duviella, E.: Leak detection and localization in water distribution networks: Review and challenges, *Annual Reviews in Control*, 55 (2024), pp. 392–419, <https://doi.org/10.1016/j.arcontrol.2023.03.012>.
- [52] Mazharuddin, A., Za, C., Lathifah, A., Ahmad, T., Purwitasari, D.: GA-Sense: Sensor placement strategy for detecting leaks in water distribution networks based on time series flow and genetic algorithm, *MethodsX*, 12 (2024), <https://doi.org/10.1016/j.mex.2024.102612>.
- [53] Momeni, A., Piratla, K.R., Chalil Madathil, K.: Application of Neural Network-Based Modeling for Leak Localization in Water Mains, *Journal of Pipeline Systems Engineering and Practice*, 13 (2022) 4, [https://doi.org/10.1061/\(ASCE\)PS.1949-1204.0000674](https://doi.org/10.1061/(ASCE)PS.1949-1204.0000674).
- [54] Mahmoud, M.B.R., et al.: Optimized AI and IoT-Driven Framework for Intelligent Water Resource Management, *IEEE Access*, 13 (2025), pp. 97628–97646, <https://doi.org/10.1109/ACCESS.2025.3572067>.
- [55] Li, Z., Wang, J., Yan, H., Li, S., Tao, T., Xin, K.: Fast Detection and Localization of Multiple Leaks in Water Distribution Network Jointly Driven by Simulation and Machine Learning, *Journal of Water Resources Planning and Management*, 148 (2022) 9, pp. 1–13, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001574](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001574).
- [56] Park, H. K., Oh, Y. J., Kim, K., Kim, T., Hyung, J., Koo, J.: Optimal leakage detection and classification of the water distribution network based on the machine learning approach, *Water Supply*, 24 (2024) 6, pp. 2158–2171, <https://doi.org/10.2166/ws.2024.122>.
- [57] Komba, G.M.: Optimizing Leak Detection and Location in Water Distribution Networks Using SVM-RF Algorithm, *Proceedings of the 15th International Conference on Mechanical and Intelligent Manufacturing Technologies*, pp. 27–33, 2024, <https://doi.org/10.1109/ICMIMT61937.2024.10585935>.
- [58] Fares, A., Tijani, I.A., Rui, Z., Zayed, T.: Leak detection in real water distribution networks based on acoustic emission and machine learning, *Environmental Technology*, 44 (2023) 25, pp. 3850–3866, <https://doi.org/10.1080/09593330.2022.2074320>.
- [59] Soldevila, A., Blesa, J., Tornil-Sin, S., Duviella, E., Fernandez-Canti, R. M., Puig, V.: Leak localization in water distribution networks using a mixed model-based/data-driven approach, *Control Engineering Practice*, 55 (2016), pp. 162–173, <https://doi.org/10.1016/j.conengprac.2016.07.006>.
- [60] Alves Coelho, J., Glória, A., Sebastião, P.: Precise Water Leak Detection Using Machine Learning and Real-Time Sensor Data, *Internet of Things*, 1 (2020) 2, pp. 474–493, <https://doi.org/10.3390/iot1020026>.
- [61] Tajalli, S.A.M., Moattari, M., Naghavi, S.V., Salehizadeh, M.R.: A Novel Hybrid Internal Pipeline Leak Detection and Location System Based on Modified Real-Time Transient Modelling, *Modelling*, 5 (2024) 3, pp. 1135–1157, <https://doi.org/10.3390/modelling5030059>.
- [62] Fujiwara, O.: A Two-Phase Decomposition Method for Optimal Design of Looped Water Distribution Networks, 26 (1990) 4, pp. 539–549.
- [63] Tabesh, M., Oberascher, M.: Pressure sensor placement for water distribution network calibration based on graph-theoretic approaches, *Journal of Hydroinformatics*, 28 (2026) 3, pp. 311–325, <https://doi.org/10.2166/hydro.2026.176>.
- [64] Bohorquez, J., Lambert, M.F., Alexander, B., Simpson, A.R., Abbott, D.: Stochastic Resonance Enhancement for Leak Detection in Pipelines Using Fluid Transients and Convolutional Neural Networks, *Journal of Water Resources Planning and Management*, 148 (2022) 3, pp. 1–15, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001504](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001504).
- [65] Kanyama, M.N., Bhunu Shava, F., Gamundani, A.M., Hartmann, A.: Machine learning applications for anomaly detection in Smart Water Metering Networks: A systematic review, *Physics and Chemistry of the Earth*, 134 (2024), Article 103558, <https://doi.org/10.1016/j.pce.2024.103558>.
- [66] Aydogdu, M., Firat, M.: Estimation of Failure Rate in Water Distribution Network Using Fuzzy Clustering and LS-SVM Methods, *Water Resources Management*, 29 (2015) 5, pp. 1575–1590, <https://doi.org/10.1007/s11269-014-0895-5>.
- [67] Ahmed, M., Babu, G.R.M.: A Hybrid Support Vector Machine and Artificial Neural Network Based Cyber Security Framework, 11 (2024) 1, pp. 143–149.
- [68] Radzman, M.I.R., et al.: Pipe leakage detection system with artificial neural network, *IAES International Journal of Artificial Intelligence*, 11 (2022) 3, pp. 977–985, <https://doi.org/10.11591/ijai.v11.i3.pp977-985>.
- [69] Bohorquez, J., Alexander, B., Simpson, A.R., Lambert, M.F.: Leak Detection and Topology Identification in Pipelines Using Fluid Transients and Artificial Neural Networks, *Journal of Water Resources Planning and Management*, 146 (2020) 6, pp. 1–11, [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001187](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001187).