

A Hybrid Leak Detection Model in a Distribution Network Using GIS–Water Gems and Neural Networks: A Case Study of Reservoir 94, East Tehran

Seyed Abedin Sajedi¹ , Somayeh Yousefi^{1*} 

¹Department of Civil & Environmental Engineering, CT.C., Islamic Azad University, Tehran, Iran.

Corresponding Author, Email: s.yousefi@iauctb.ac.ir

Received: 20 Feb. 2026 Accepted: 01 Aug. 2026
Revised: 11 July 2026 Published: 22 Sep. 2024



Homepage: ijwer.uoz.ac.ir

Abstract: This study developed a hybrid framework for leak detection in the water distribution network of Reservoir 94 in East Tehran. The hydraulic model was built in Water Gems using GIS data and AutoCAD maps, then calibrated with real-time pressure and flow data from SCADA. The network covers 42.9 km of pipelines and over 380 nodes. Three leak scenarios (5%, 10%, 20%) were simulated, revealing non-linear pressure drops and increased flow at critical points as leak intensity rose. Model outputs were used to train ANN and MLP networks in MATLAB. Results showed the hybrid model achieved about 30% higher accuracy in detecting leak intensity and location than the standalone numerical model. The MLP outperformed ANN by roughly 3%, reaching an overall detection accuracy of 94%. Statistical indices ($R^2=0.95$, $NSE=0.93$) confirmed validity, demonstrating that combining a calibrated hydraulic model with an MLP network effectively identifies hidden leaks in water distribution networks.

Keywords: Leakage monitoring, Artificial neural network, Calibration, Hydraulic modeling, Reservoir 94

Introduction: The sustainability of urban water distribution networks (WDNs) is a fundamental component of resource management and energy cost reduction. In many Iranian cities, including Tehran, water losses exceed 30%, mainly due to hidden leaks in buried pipelines. These leaks cause pressure drops, infrastructure deterioration, and increased pumping energy consumption (Sharma et al., 2021). Numerical models such as Epanet and WaterGems simulate hydraulic behavior based on continuity and energy equations (Rossman, 2000; Zhou et al., 2022). Although these models are physically accurate, they require detailed data and complex calibration. Alternatively, data-driven methods such as ANN, MLP, SVM, and XGBoost exploit sensor data (flow and pressure) to identify leak patterns (Li et al., 2023; Rahmani et al., 2024). Integrating these two approaches through hybrid numerical–intelligent models has improved leak detection accuracy up to 91% and reduced spatial error to below 5 meters (Ali et al., 2022). Despite these advancements, challenges remain, including the scarcity of real-world data and the absence of validation mechanisms for synthetic datasets. The present study focuses on Reservoir 94 in District 2 of Tehran, developing a hybrid framework based on GIS, AutoCAD, and Water Gems to compare the performance of ANN and MLP models. It also examines the economic impacts of leak reduction, supported by figures and tables illustrating hydraulic simulation outcomes and model performance analysis.

Methodolog: In this study, the hydraulic behavior of the water distribution network covered by Reservoir No. 94 of Tehran Water and Wastewater Company, District 2, located in the Hakimiyyeh area and around Babaei Highway, was simulated (see Fig. 1 and Table 1). The numerical model was developed using Water Gems software, based on spatial GIS data and AutoCAD drawings. The network consists of 42.9 km of pipelines and over 380 nodes, with the reservoir defined as a reference source maintaining a constant water level. To reproduce real operating conditions, a pressure control valve with a head of 45 m and a leakage model based on the Emitter function were implemented (see Fig. 2). Calibration was carried out using 24-hour SCADA data, and the model was validated with $PMI = 0.94$ and $RMSE = 3.8$ m.

Subsequently, intelligent models ANN and MLP were developed in the MATLAB environment using the numerical model's output data (Table 2). The dataset was divided into three subsets for training, validation, and testing. Comparison of performance indices R^2 , NSE, and RMSE (Table 3) showed that the hybrid model achieved approximately 30% higher accuracy in predicting leak intensity and location. Field tests with data from Winter 2025 demonstrated that the combined Water Gems + MLP model detected leaks with 94% accuracy, representing a 30% improvement over the standalone numerical model. Moreover, the MLP model outperformed ANN by about 3% in accuracy.

Results and Discussion: In this research, the hydraulic modeling of the Tehran Reservoir Network 94 using WaterGEMS provided critical insights into the system's stability. Under normal operating conditions, the network maintains an average pressure of 44.2 mwc (bar). However, the simulation of leakage scenarios—extending up to 20% intensity—resulted in a significant pressure drop to 27.5 mwc (bar). This drop was accompanied by a 21% increase in outflow, a finding that underscores the urgent necessity for advanced pressure control mechanisms to mitigate water loss (Table 4). The primary innovation of this study lies in the development of intelligent diagnostic tools by training Artificial Neural Network (ANN) and Multi-Layer Perceptron (MLP) models using calibrated, real-world output data from Water Gems. The MLP model, characterized by a sophisticated three-hidden-layer architecture, demonstrated superior performance compared to the standard ANN. This superiority is attributed to the MLP's enhanced capability to recover complex, non-linear dependencies within the hydraulic data, ultimately achieving a leak detection accuracy of 94%. Furthermore, the MLP proved its robustness in identifying minor, subtle leaks, outperforming the ANN by a margin of 3%. A comparative analysis with previous literature highlights the significant advantages of this integrated framework. Unlike many existing approaches that rely on purely synthetic data, our model is trained on high-fidelity, real operational network data. This ensures much higher stability and generalizability under the actual, fluctuating conditions of Network 94. While Sharma et al. (2021) successfully implemented similar models, their study was limited to a 25-node network; in contrast, this research validates the framework's scalability by examining 380 real-world nodes.

Conclusion: This research introduced a novel framework for leak detection by integrating the Water Gems hydraulic model (calibrated against real data from Tehran Reservoir Network 94) with the intelligent MLP-ANN model. The MLP model, featuring a three-hidden-layer structure, demonstrated superior performance over ANN due to its enhanced ability to extract non-linear features of pressure and flow rate. The overall leak detection accuracy in the integrated framework (Water Gems + MLP) reached 94%, signifying a 30% improvement compared to the purely numerical model. During the field test in the winter of 1403 (2024/2025), this framework successfully detected minor leaks with 94% accuracy (compared to 72% for the numerical model). The high coefficient of determination ($R^2=0.95$, $R^2=0.95$, $NSE=0.93$) confirms the validity of the results, and this methodology possesses high generalizability for similar water distribution networks globally.

© 2024 University of Zabol, Zabol, Iran.



This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>)

مدل هیبریدی آشکارسازی نشت در شبکه توزیع با استفاده از GIS Water Gems و شبکه عصبی: مطالعه موردی مخزن ۹۴ شرق تهران

سیدعابدین ساجدی^۱، سمیه یوسفی^{۲*}^۱گروه مهندسی عمران و محیط زیست، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایرانپست الکترونیکی نگارنده مسئول: s.yousefi@iauctb.ac.irوبگاه نشریه: ijwer.uoz.ac.ir

تاریخ دریافت: ۱۴۰۴/۱۲/۰۱ تاریخ پذیرش: ۱۴۰۵/۰۵/۱۰

تاریخ ویرایش: ۱۴۰۵/۰۴/۲۰ تاریخ چاپ: ۱۴۰۳/۰۷/۰۱

چکیده: این پژوهش با هدف توسعه یک چارچوب هیبریدی برای تشخیص نشت در شبکه توزیع آب مخزن ۹۴ شرق تهران انجام شد. در این چارچوب، ابتدا مدل هیدرولیکی شبکه با استفاده از نرم‌افزار Water Gems و داده‌های مکانی GIS و نقشه‌های Auto CAD ساخته و با داده‌های واقعی فشار و دبی حاصل از SCADA کالیبره شد. شبکه مورد مطالعه شامل ۴۲/۹ کیلومتر خطوط لوله و بیش از ۳۸۰ گره است. سپس سه سناریوی نشت با شدت‌های ۵، ۱۰ و ۲۰ درصد در مدل اعمال شد تا پاسخ هیدرولیکی شبکه بررسی شود. نتایج نشان داد که افزایش شدت نشت موجب افت غیرخطی فشار و افزایش جریان در نقاط حساس شبکه می‌شود. در گام بعد، خروجی‌های حاصل از مدل عددی برای آموزش دو شبکه عصبی ANN و MLP در محیط MATLAB به کار رفت. ارزیابی عملکرد نشان داد که مدل هیبریدی نسبت به مدل عددی مستقل حدود ۳۰ درصد دقت بالاتری در تشخیص شدت و مکان نشت دارد. همچنین مدل MLP نسبت به ANN حدود سه درصد عملکرد بهتری از خود نشان داد و دقت کلی تشخیص نشت در آن به ۹۴ درصد رسید. شاخص‌های آماری مانند $R^2=0.95$ و $NSE=0.93$ نیز اعتبار نتایج را تایید کردند. این مطالعه نشان می‌دهد که تلفیق مدل هیدرولیکی کالیبره‌شده با شبکه عصبی MLP می‌تواند روشی موثر برای شناسایی نشت‌های پنهان در شبکه‌های توزیع آب باشد.

کلیدواژه‌ها: پایش نشت، شبکه عصبی مصنوعی، کالیبراسیون، مدل‌سازی هیدرولیکی، مخزن ۴.

۱- مقدمه

چالش‌های مبرم در بهره‌برداری از این شبکه‌هاست که پیامدهایی نظیر هدررفت منابع آبی گران‌بها، افت فشار عملیاتی، و افزایش هزینه‌های پمپاژ و انرژی را به همراه دارد. براساس گزارش‌های موجود، میزان آب بدون درآمد^۲ ناشی از نشت، بخش قابل‌توجهی از کل آب تولیدی در

شبکه‌های توزیع آب (WDNs) به‌عنوان شریان‌های حیاتی زیرساخت‌های شهری، نقشی اساسی در تامین و توزیع پایدار منابع آب ایفا می‌کنند. با این حال، نشت^۱ آب یکی از

^۲ Non-Revenue Water^۱ Leakage

شبکه‌های فرسوده را به خود اختصاص می‌دهد (Rossman, 2000).

در کلان‌شهرهایی نظیر تهران، علیرغم استقرار سامانه‌های کنترل و پایش، میزان تلفات آب همچنان فراتر از استانداردهای مطلوب بوده و در مواردی از ۳۰ درصد آب تولیدی نیز فراتر می‌رود. چالش اصلی در این میان، ماهیت “پنهان” نشت‌های شبکه است؛ نشت‌هایی که در لوله‌های مدفون رخ داده و به دلیل عدم امکان رصد چشمی در مراحل اولیه، فرآیند تشخیص و مکان‌یابی را با دشواری مواجه می‌سازند. تداوم این نشت‌های شناسایی نشده، علاوه بر اتلاف منابع، پیامدهای ثانویه مخربی از جمله تخریب روسازی‌های شهری، نفوذ آلاینده‌ها به شبکه و افزایش استهلاك تجهیزات پمپاژ را در پی دارد بنابراین، توسعه راهکارهای هوشمند و خودکار برای تشخیص زودهنگام و مکان‌یابی دقیق نشت، برای مدیریت بهینه دارایی‌های شبکه و ارتقای پایداری زیرساخت‌های آبی ضرورتی انکارناپذیر است. رویکردهای سنتی در شناسایی نشت غالباً با محدودیت‌هایی در دقت، هزینه‌های بالا یا نیاز به نیروی انسانی متخصص مواجه هستند.

این مقاله با هدف غلبه بر این محدودیت‌ها، یک مدل هیبریدی نوآورانه متشکل از سیستم‌های اطلاعات جغرافیایی (GIS) نرم‌افزار مدل‌سازی هیدرولیکی Water Gems و الگوریتم‌های هوش مصنوعی شبکه‌های عصبی (ANN/MLP) را برای پایش و تشخیص نشت در شبکه توزیع آب مخزن ۹۴ تهران پیشنهاد می‌کند. در طول سال‌ها، رویکردهای سنتی برای مدیریت نشت عمدتاً بر مدل‌سازی هیدرولیکی مبتنی بر فیزیک و روش‌های تفاضلی تکیه داشته‌اند. این مدل‌ها از طریق شبیه‌سازی دینامیک جریان و فشار در شبکه، سعی در تخمین محل نشت دارند (Alsaydalani, 2024). اگرچه این روش‌ها مبانی علمی محکمی دارند، اما اغلب به دلیل وابستگی زیاد به پارامترهای دقیق شبکه (مانند زبری لوله‌ها، شرایط مرزی دقیق، و داده‌های لحظه‌ای)، در مواجهه با عدم قطعیت‌ها و تغییرات محیطی، از دقت کافی برخوردار نیستند.

باوجود پیشرفت‌ها در مدل‌سازی، کنترل فعال فشار به‌عنوان یک استراتژی کلیدی برای کاهش تلفات هیدرولیکی همچنان موردبررسی است (Alsaydalani, 2024). با ظهور انقلاب داده‌ها و پیشرفت‌های حاصل در حسگرها و سیستم‌های اندازه‌گیری هوشمند، تحقیقات به سمت رویکردهای داده‌محور و ترکیبی سوق پیدا کرده است. رویکردهای داده‌محور با استفاده از داده‌های جمع‌آوری شده از حسگرهای فشار و جریان، مدل‌های پیش‌بینی‌کننده‌ای را برای تشخیص نشت توسعه می‌دهند. به‌عنوان مثال مدل‌های یادگیری عمیق و شبکه‌های عصبی، پتانسیل بالایی برای استخراج الگوهای پیچیده مرتبط با نشت از داده‌های زمانی سری فشار نشان داده‌اند (Mashhadi & Jalili, 2021). همچنین، ترکیب تکنیک‌های آماری مانند PCA با رویکردهای مبتنی بر داده، به بهبود قابلیت تشخیص نشت کمک کرده است (Xu et al., 2022).

اخیراً، استفاده از مدل‌های ترکیبی (هیبریدی) که فیزیک مدل‌سازی هیدرولیکی را با قدرت یادگیری ماشین ادغام می‌کنند به‌عنوان یک راه‌حل قدرتمند برای مقابله با عدم قطعیت‌ها مطرح شده است (Ferrandez-Gamiz & Alvisi, 2023). در این میان، استفاده از نرم‌افزارهایی نظیر Water Gems و EPANET برای شبیه‌سازی جریان و فشار، و بهره‌گیری از الگوریتم‌های یادگیری عمیق مانند ANN و MLP برای تحلیل الگوهای نشت، مسیر جدیدی را برای مدل‌سازی دقیق‌تر فراهم کرده است.

ترکیب این دو دیدگاه به شکل مدل‌های تلفیقی عددی-هوشمند رویکردی است که می‌تواند محدودیت‌های داده‌های میدانی را کاهش داده و هم‌زمان دقت تشخیص را افزایش دهد. علاوه بر این تکنیک‌های پیشرفته یادگیری تقویتی^۱ نیز برای بهینه‌سازی مکان‌یابی نشت در شبکه‌های هوشمند موردبررسی قرار گرفته‌اند (Chen et al., 2023). با این وجود، نیاز به توسعه مدل‌هایی وجود دارد که بتوانند به‌طور کارآمد، مدل‌سازی عددی و یادگیری ماشین را به‌ویژه در شرایط خاص شبکه‌های منطقه‌ای (مانند شبکه‌های ایران) ترکیب کنند (Rahmani et al., 2024).

¹ Reinforcement Learning

رویکردهای داده‌محور همچنین در زمینه‌هایی نظیر مکان‌یابی نشت با بهره‌گیری از رویکردهای مبتنی بر مدل و داده، به‌طور هم‌زمان توسعه‌یافته‌اند (Ben et al., 2022). در پژوهش حاضر، با تمرکز بر محدوده تحت پوشش مخزن ۹۴ شرکت آب و فاضلاب منطقه ۲ شهر تهران (حکیمیه، تهران‌پارس) یک چارچوب تلفیقی نوین توسعه داده می‌شود که در آن، داده‌های شبکه از طریق GIS و Auto CAD استخراج و در Water Gems مدل‌سازی و کالیبره می‌گردند. سپس نتایج شبیه‌سازی برای آموزش و مقایسه دو مدل شبکه عصبی شامل ANN (شبکه عصبی کلاسیک در یادگیری عمیق) و MLP (شبکه چندلایه پرسپترون) مورد استفاده قرار می‌گیرند. درنهایت، علاوه بر تحلیل عددی، به شکل تحلیلی به جنبه‌های اقتصاد آب و نقش کاهش نشت در صرفه‌جویی منابع نیز اشاره می‌شود. مطالعات انجام‌شده در زمینه تشخیص نشت در شبکه‌های توزیع آب را می‌توان به سه رویکرد کلی تقسیم کرد که هر یک مزایا و کاستی‌های خاص خود را دارند.

در روش مدل عددی، رفتار هیدرولیکی شبکه با استفاده از معادلات پیوستگی و انرژی شبیه‌سازی می‌شود. مدل‌هایی مانند EPANET و Water Gems قادرند تاثیر نشت بر روی تغییرات فشار و دبی را در نقاط مختلف شبکه محاسبه کنند. این مدل‌ها پایه فیزیکی بسیار دقیقی دارند اما به داده‌های ورودی با جزئیات بالا (طول، قطر، جنس و زبری لوله‌ها) نیازمندند و فرآیند کالیبراسیون در آن‌ها بسیار حساس است.

در مدل داده‌محور یا هوشمند الگوریتم‌های یادگیری ماشین و شبکه‌های عصبی، با تحلیل داده‌های حسگرها نظیر فشار و دبی، روابط غیرخطی میان متغیرها را شناسایی می‌کنند. روش‌هایی مانند Support Vector Machine (SVM)، Random Forest، و شبکه‌های عصبی عمیق شامل CNN، LSTM، MLP و Autoencoder، در سال‌های اخیر برای تشخیص سریع و دقیق نشت مورد استفاده قرار گرفته‌اند (Zhang & Wang, 2024).

Rahmani et al. (2024) نشان دادند که ترکیب روش EPANET+XGBoost می‌تواند زمان تشخیص نشت را تا حدود ۸۵ درصد کاهش دهد. باوجود این پیشرفت‌ها، ضعف اصلی این رویکردها نیاز به داده‌های آموزشی واقعی و متنوع است؛ داده‌هایی که در شهرهای ایران معمولاً در دسترس نیستند یا از نظر انسجام زمانی دچار اختلال‌اند هدف از توسعه مدل‌های تلفیقی عددی و هوشمند، استفاده از مزایای هر دو رویکرد عددی و هوشمنداست در این مدل‌ها، داده‌های خروجی حاصل از شبیه‌سازی عددی به‌عنوان مجموعه آموزشی برای شبکه عصبی عمل می‌کنند و به‌این‌ترتیب، کمبود داده‌های واقعی جبران می‌شود. با ترکیب Epanet و شبکه عصبی MLP موفق شدند موقعیت نشت را با خطای کمتر از ۵ متر پیش‌بینی کنند. (Gamiz et al. 2023) همچنین، اهمیت ترکیب داده‌های حاصل از مدل‌سازی عددی با یادگیری ماشین را در شناسایی نشت‌های کوچک در شبکه‌های تهران تایید کرده‌اند؛ موضوعی که مبنای پژوهش حاضر نیز قرار گرفته است باوجود پیشرفت در مدل‌های تلفیقی، هنوز برخی چالش‌ها قابل‌توجه هستند.

- ◆ نبود سازوکاری برای اعتبارسنجی داده‌های مصنوعی تولیدی توسط مدل عددی با داده‌های واقعی.
- ◆ فقدان بررسی مقایسه‌ای بین ساختارهای ANN و MLP در یک شبکه واقعی شهری مقیاس بزرگ
- ◆ محدود بودن مطالعات به تحلیل فنی و نادیده گرفتن اثرات اقتصادی صرفه‌جویی آب در نتیجه کاهش نشت.

ازاین‌رو در پژوهش حاضر با تمرکز بر مخزن ۹۴ شهر تهران نخست یک مدل عددی دقیق مبتنی بر GIS و AutoCAD در محیط Water Gems ساخته می‌شود و سپس دو مدل هوشمند ANN و MLP آموزش می‌بینند تا دقت و عملکردشان مقایسه گردد. درنهایت سیاست‌گذاری اقتصاد آب تحلیل خواهد شد.




Fig. 1 Tank 94 at an altitude of 1550 - Google Earth

شکل ۱ مخزن ۹۴ در ارتفاع ۱۵۵۰ - Google Earth




Fig. 2 Reservoir Area 94

شکل ۲ منطقه مخزن ۹۴

مخزن ۹۴ و ویژگی‌های شبکه تحت پوشش آن در [جدول](#)

۱ خلاصه شده‌اند

۲-۲- گام‌های پژوهش

در این مطالعه، از یک رویکرد هیبریدی شامل مدل‌سازی هیدرولیکی در نرم‌افزار Water Gems و پردازش داده‌ها توسط شبکه‌های عصبی مصنوعی (ANN/MLP) برای تشخیص نشت استفاده شده است. فرآیند پژوهش در سه گام اصلی صورت گرفت.

آماده‌سازی داده‌ها و مدل‌سازی هیدرولیکی

در این پژوهش، مدل عددی شبکه توزیع آب محدوده تحت پوشش مخزن شماره ۹۴ منطقه ۲ تهران (حکیمیه-تهرانپارس) با بهره‌گیری از داده‌های مکانی برداشت شده از

۲- روش‌شناسی

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، شبکه تحت پوشش مخزن شماره ۹۴ شرکت آب و فاضلاب منطقه ۲ تهران است که در حکیمیه تهران پارس واقع شده است این مخزن در ارتفاع ۱۵۵۰ متر از سطح دریا ساخته و در حال بهره‌برداری است. (شکل ۱) محدوده تحت پوشش آب دهی این مخزن اتوبان شهید بابائی جاده لشکرک خیابان فروردین خیابان سازمان آب و بخش وسیع شهرک حکیمیه است.

این مخزن از طریق خط ۸۰۰ مخزن ۴۸ و از طریق خط ۴۰۰ مخزن ۷۱ آبیگری می‌شود. گنجایش این مخزن ۱۶۸۰۰ مترمکعب است و میانگین مصرف روزانه آن ۳۲۵۵۷۷.۱۱۷۶ و میانگین ماهانه آن ۱۰۸۵۲.۵۷۰۵۹ است، میانگین مصرف برحسب جمعیت ۲۳۵۶۶۰ (m3) است. مخزن ۹۴ در شمال شرق شهر تهران قرار گرفته است. طول کلی خطوط شبکه تحت پوشش این مخزن ۴۲/۹۲۴ کیلومتر است. عمده خطوط این شبکه از جنس پلی اتیلن با قطرهای ۹۰ و ۱۱۰ میلی‌متر هستند، که به دلیل رفتار ارتجاعی و جذب ارتعاش بالا، روش‌های صوتی تشخیص نشت^۱ در آن‌ها کارایی محدودی دارند؛ از این رو، استفاده از مدل‌سازی عددی و هوشمند ضرورت بیشتری می‌یابد. محدوده مخزن ۹۴ (شکل ۲) به دلیل گستردگی و بزرگی دامنه و اختلاف ارتفاعی زیاد دارای ۲ لایه فشاری است که لایه اول از خروجی مخزن با نقطه رهایی صفر تا فشارشکن نوروزی دارای ورودی ۸۵ متر آب (8.5 bar) است که توسط شیر فشارشکن به ۴۵ متر آب (4.5 bar) کاهش پیدا می‌کند و لایه دوم تا انتهای محدوده با کمک ۲ شیر فشارشکن ۱۰۰ و ۱۵۰ میلی‌متر لایه فشاری ۴۰ متر آب (۴ بار^۲) تنظیم می‌شود

در محدوده تحت پوشش مخزن ۹۴ شرق تهران، ۲۲۷ شیر خط^۳ و ۱۱۵ شیر آتش‌نشانی^۴ فعال وجود دارد. جهت شناخت کامل به محدوده مورد مطالعه مشخصات کلی

³ Gate Valve

⁴ Hydrant Valve Underground

¹ Acoustic Leak Detection

² Bar

شیرهای کنترل فشار، شیرهای ایزولاسیون (حد) است.

جدول ۱ مشخصات مخزن ۹۴

Table 1 Tank Specifications 94

Parameter	Amount
Geographical location	Northeast Tehran area – Babaei Highway, area of treatment plants 3 and 4
Average daily consumption (m ³ /d)	10852.57
Average annual consumption (m ³ /y)	3,961,188
Tank capacity (m ³)	16,800
Length of lines covered (km)	16,800
The most common pipe diameter	Ø90 mm و Ø110 mm
Number of subscriptions covered	residential subscribers 1.825
Inlet drainage lines	800mm line from tank 48 and 400mm line from tank 71
Standing water level TWL/RL	1550 m
Operating status	Active (covered by rights to treatment plants 3 and 4)




Fig. 3 Modeling of the 94 reservoir and the location of the Nashveh pressure relief valve

شکل ۳ مدل‌سازی مخزن ۹۴ و محل قرارگیری شیر اطمینان

سیستم GIS و نقشه‌های AutoCAD ساخته شد. پایه داده‌ها حاصل از پیمایش‌های میدانی متوالی در سال‌های گذشته بوده و پس از صحت‌سنجی، به صورت خروجی Shape file از محیط GIS استخراج و در نرم‌افزار Water Gems بارگذاری گردید.

نرم‌افزار Water Gems، پس از Water CAD و EPANET، پیشرفته‌ترین و قدرتمندترین ابزار در این حوزه است و با نرم‌افزار Arc GIS سازگاری دارد. طولانی‌ترین قسمت تحقیق ساخت مدل عددی است که سازگاری این دو نرم‌افزار تا حد زیادی زمان ساخت مدل را کاهش داده است. داده‌های هندسی از نرم‌افزار GIS استخراج و به محیط مدل عددی منتقل گردیدند. برای دقت بیشتر مدل، از داده‌های واقعی مخزن ۹۴ شرکت آب و فاضلاب منطقه دو شهر تهران استفاده شد که مبتنی بر بستر اطلاعات مکانی و در قالب فایل‌های Shape file بود. پارامترهای اصلی شامل طول و قطر لوله‌ها، ضریب زبری ($C=130$) (هزینه انرژی-مانینگ)، تراز ارتفاعی گره‌ها، فشار ورودی، و نرخ تقاضا در گره‌های مصرف‌کننده تنظیم شدند. مدل ساخته‌شده متشکل از ۴۲/۹km لوله و بیش از ۳۸۰ گره^۱ مدل‌سازی شد (شکل ۳). مخزن ۹۴ به عنوان منبع مرجع^۲ با سطح آب ثابت تعریف گردید. در لایه فشاری اول یک شیر کنترل فشار با تنظیم فشار ۴۵ متر آب تعریف شد تا رفتار واقعی سیستم در حالت مصرف‌های متغیر بازسازی شود. برای مدل‌سازی نشت، از قابلیت Emitter Water Gems استفاده شد تا نسبت جریان نشت به فشار به صورت رابطه زیر شبیه‌سازی شود:

$$Q_{leak} = C \cdot p^n \quad (1)$$

که در آن C ضریب جریان نشتی^۳ و n نمای فشار^۴ است که با کالیبراسیون تجربی بین ۰.۵ تا ۱ تنظیم گردید. به منظور ایجاد شرایط متنوع، سه سطح نشت (جزئی، متوسط و شدید) در پنج موقعیت مختلف شبکه اعمال شد و خروجی فشار و دبی برای هر گره ثبت گردید. مدل عددی شامل کلیه اجزای اصلی شبکه از جمله خطوط انتقال، گره‌ها،

³ Emitter Coefficient

⁴ Leakage exponent

¹ Junction

² Reservoir Node

نشوه

در نظر گرفته شد.

در این پژوهش، ورودی‌های شبکه‌های ANN و MLP شامل مقادیر فشار گرہ‌ها و دبی در بازه‌های زمانی ۱۵ دقیقه‌ای است که از خروجی‌های نرم‌افزار Water Gems استخراج شده‌اند. ساختار مدل‌های پیاده‌سازی شده در [جدول ۲](#) نمایش داده شده است. جهت دستیابی به ساختار بهینه، از روش تکرار و ارزیابی خطای آموزش^۱ استفاده شده و به عنوان معماری پایدار انتخاب گردید. ساختار شبکه‌ها مطابق [جدول ۲](#) در محیط MATLAB R2023b پیاده‌سازی شدند. وزن‌های اولیه با روش Xavier مقداردهی و فرآیند آموزش تا رسیدن به تعادل خطا ادامه یافت.

نتایج نشان داد که مدل MLP در مقایسه با ساختار ساده‌تر ANN دقت بالاتری در برآورد شدت نشت دارد اما این دقت بسیار ناچیز است.

در فرآیند آموزش مدل، مجموعاً ۱۲ هزار داده مورد استفاده قرار گرفت. از این میان، حدود ۳۰ درصد داده‌های واقعی ثبت شده توسط تجهیزات ابزاردقیق در مخزن ۹۴ و ۷۰ درصد داده‌ها حاصل از شبیه‌سازی سناریوهای مختلف نشت (شامل دبی‌های نشت متفاوت در نقاط مختلف) در نرم‌افزار

برای اطمینان از دقت مدل عددی Water Gems، فرآیند کالیبراسیون شبکه براساس داده‌های واقعی فشار و دبی برداشت شده از سامانه پایش آنلاین ایستگاه‌های فشاری SCADA دوره ۲۴ ساعته (حداکثر و حداقل مصرف) انجام گرفت. در این فرآیند، مقادیر زیری لوله‌ها، تلفات موضعی اتصالات و ضرایب افت جزئی تا زمانی تنظیم شدند که اختلاف بین مقادیر مدل و داده‌های واقعی کمتر از ۵ درصد باشد. فرمول ارزیابی خطای مدل با استفاده از ریشه میانگین مربعات خطا (RMSE) و نسبت تطابق فشار (Pressure Match Index) محاسبه می‌شود. براساس نتایج، مقدار $PMI = 0.94$ و $RMSE = 3.8 \text{ m}$ به دست آمد که نشان‌دهنده هم‌خوانی مناسب مدل با داده‌های واقعی شبکه مخزن ۹۴ است. منحنی‌های فشار شبیه‌سازی شده و واقعی نیز در نقطه فشارشکن نشوه نروزی تقریباً برهم منطبق هستند و اختلاف زمانی اوج مصرف کمتر از ۱۵ دقیقه ثبت گردید.

۲-۳- مدل سازی هوشمند

شبکه‌های عصبی مصنوعی ANN، MLP

در گام دوم، مدل‌های هوشمند برای پیش‌بینی نشت و شدت آن بر پایه داده‌های خروجی مدل عددی توسعه یافتند. دو ساختار ANN کلاسیک و MLP چندلایه پرسپترون طراحی با داده‌های تولید شده از خروجی Gems Water آموزش داده شدند. خروجی‌های مدل عددی شامل ۱۲ هزار داده مربوط به حالات گوناگون نشت (در پنج موقعیت و سه شدت مختلف) بودند. برای آموزش، داده‌ها به صورت تصادفی به سه بخش تقسیم شدند:

♦ ۷۰٪ برای آموزش

♦ ۱۵٪ برای اعتبارسنجی

♦ ۱۵٪ برای آزمون نهایی

میانگین فشار و دبی در گرہ‌های کلیدی (نظیر گرہ‌های نزدیک به شیر فشارشکن و خطوط ۹۰ و ۱۱۰ میلی‌متر) به عنوان ورودی شبکه و میزان نشت به عنوان خروجی هدف

جدول ۲ ساختار شبکه

Table 2 Network structure

Feature	Model ANN	Model MLP
Network type	Feed-forward neural network	Multi layer perceptron
Hidden layers	2 layers (2 and 8 neurons)	3 layers (8, 12, 16 neurons)
Activation function	sigmond	Relu
Training algorithm	Levenberg-marquadt	Adaptive momentum SGD
Initial learning rate	0.1	0.005
Stop criterion	Change MSE	Change MSE
Input variable	Pressure P - Flow rate Q - Location l	Pressure P - Flow rate Q - Location l
Output	Pressure and	Pressure and

¹ Training Error

۴۲.۹۲۴ km خطوط لوله پلی‌اتیلن با قطرهای غالب ۹۰ و ۱۱۰ mm است که از مسیر فشارشکن نشوه نوری ۲۰۰ mm تغذیه می‌شود. مقادیر به‌دست‌آمده در (جدول ۳) نشان می‌دهند مدل تلفیقی به‌طور متوسط حدود ۳۰ درصد بهبود نسبت به مدل فقط عددی داشته است و مدل MLP حدود ۳ درصد (ناچیز) برتری در دقت مکان‌یابی و شدت نشت نسبت به ANN دارد.

نتایج شبیه‌سازی (جدول ۴) نشان داد که در شرایط نرمال، فشار متوسط شبکه بین ۳۶ تا ۴۸ متر آب هد هیدرولیکی در نوسان است؛ بیشترین فشار در نقاط نزدیک به خروجی مخزن و کمترین مقدار در نواحی جنوبی شبکه ثبت شد. در سناریوهای نشت تعریف‌شده (با مدل Emitter)، افزایش شدت نشت باعث افت غیرخطی فشار شد که بیانگر واکنش نسبتاً انعطاف‌پذیر شبکه در برابر نوسانات لحظه‌ای است. افت میانگین فشار حدود ۸/۷ متر آب در حالت نشت ۲۰ درصد ثبت شد. باین‌حال، جریان ورودی به شبکه تا ۲۱ درصد افزایش یافت، این الگو با افزایش شیر خروجی در سیستم‌های بسته هیدرولیکی هم‌خوانی دارد و تأکیدی بر ضرورت تنظیم شیر فشارشکن در نقاط کلیدی شبکه است.

۳-۱- نتایج مدل هوشمند ANN و MLP

نتایج نهایی حاکی از همبستگی قوی بین داده‌های واقعی و خروجی مدل هوشمند است. تحلیل خطا نشان داد مدل

جدول ۳ ارزیابی عملکرد

Table 3 Performance Evaluation

Performance index	ANN	MLP
R2	0.91	0.95
NSE	0.88	0.93
RMSE	3.7	2.6

جدول ۴ نتایج مدل‌سازی شبکه

Table 4 Numerical modeling results

working mode	Average pressure m	Minimum pressure m	Average total outlet flow rate L/m
Normal state	44.2	36.1	123.7
Level 1 leak (5%)	42.0	33.8	129.4
Level 2 leak	39.5	31.0	136.8

variable	intensity of leakage	intensity of leakage
----------	----------------------	----------------------

Water Gems است که جهت افزایش دقت و پوشش‌دهی حالات مختلف شبکه به مجموعه آموزش اضافه‌شده است.

فرآیند آموزش و اعتبارسنجی

برای مقایسه و ارزیابی عملکرد مدل هوشمند، از سه معیار متداول استفاده گردید:

۱. ضریب تعیین

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (2)$$

۲. ضریب کارایی نش-ساتکلیف (NSE)

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obs,i} - Q_{sim,i})^2}{\sum_{i=1}^n (Q_{obs,i} - \bar{Q})^2} \quad (3)$$

۳. ریشه میانگین مربعات خطا (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{obs,i} - y_{sim,i})^2} \quad (4)$$

مقادیر به‌دست‌آمده در (جدول ۳) نشان می‌دهند مدل تلفیقی به‌طور متوسط حدود ۳۰ درصد بهبود نسبت به مدل فقط عددی داشته است.

برای آزمون کارایی مدل تلفیقی (Water Gems + MLP) در شرایط واقعی، داده‌های عملیاتی دو هفته پایایی در زمستان ۱۴۰۳ تحلیل شدند. مدل توانست تغییرات فشار ناشی از نشت‌های جزئی را با دقت میانگین ۹۴ درصد تشخیص دهد، درحالی‌که مدل عددی صرفاً عددی به ۷۲ درصد بسنده می‌کرد. درنتیجه، استفاده از مدل تلفیقی موجب ۳۰ درصد افزایش دقت تشخیص نشت در محدوده تحت پوشش مخزن ۹۴ گردید.

۳- نتایج و بحث

مدل‌سازی هیدرولیکی در نرم‌افزار Water Gems برای شبکه تحت پوشش مخزن ۹۴ انجام شد. این شبکه شامل

مصنوعی) آموزش دید، از این رو پایداری مدل در شرایط عملیاتی واقعی شبکه ۹۴ از مطالعات مشابه بالاتر است.

۳-۲- ارزیابی اقتصادی کاهش نشت

ارزیابی اقتصادی با فرض هزینه متوسط تولید و توزیع آب ۸۲۰۰ تومان و افت روزانه $10852.57 \times 365 \times 8200 \approx 162.5$ در مخزن ۹۴ صورت گرفته است. چنانچه فقط ۵ درصد از این تلفات ناشی از نشت کاهش یابد، صرفه جویی سالانه حاصل می شود: $E_{\text{saving}} = 0.05 \times 10852.57 \times 365 \times 8200 \approx 162.5$ میلیارد تومان/سال حتی اگر نصف این برآورد تنها واقعی گردد (با لحاظ تاثیر فصلی و خطای مدل)، بازهم اجرای سامانه پایش هوشمند نشت حدود ۸۰ میلیارد تومان صرفه جویی سالانه به همراه دارد. نتایج عددی نشان می دهند که بازگشت سرمایه سامانه در کمتر از ۱۴ ماه محقق خواهد شد.

۴- نتیجه گیری

این پژوهش با هدف ارائه راهکاری نوین برای مدیریت نشت در شبکه های پیچیده توزیع آب، به طراحی یک چارچوب هیبریدی مبتنی بر تلفیق مدل سازی هیدرولیکی و هوش مصنوعی پرداخته است. در این راستا، ادغام سیستم اطلاعات جغرافیایی GIS، نرم افزار Water Gems و شبکه عصبی پرسپترون چندلایه MLP برای شناسایی نشت در شبکه واقعی مخزن ۹۴ (شمال شرق تهران) مورد ارزیابی قرار گرفت. شبکه مورد مطالعه با ۴۲۹۲۴ متر خط لوله و ظرفیت ۱۶۸۰۰ مترمکعب، بستری چالش برانگیز برای نتایج




Fig. 4 Comparison of actual value with consolidated forecast

(10%) Level 3 leak (20%)	36.4	27.5	149.5
--------------------------------	------	------	-------

MLP توانست وابستگی های غیرخطی بین افت فشار و محل نشت را بهتر از مدل ANN بازایی کند. در نشت های جزئی کمتر از (5 L/s)، مدل ANN دقت ۹۱ درصد داشت، اما MLP آن را به ۹۴ درصد رساند.

منحنی پیش بینی مقدار نشت MLP تقریباً با مقادیر واقعی هم پوشانی دارد (شکل ۳) و پرت های خارج از بازه محدود هستند و با آموزش بیشتر نمودار پیش بینی بر نمودار واقعی منطبق تر می شود. افزایش تعداد لایه های پنهان در MLP موجب افزایش ظرفیت تعمیم پذیری و در نتیجه کاهش حساسیت به نویز داده شد، در حالی که شبکه ANN در ناحیه های کم فشار تمایل به بیش برآورد شدت نشت داشت. با ایجاد نقشه پراکندگی نشت در GIS، بیشترین احتمال نشت در بخش جنوب شرقی محدوده مخزن ۹۴ شناسایی شد جایی که شیب هیدرولیکی نسبی بالاتری نسبت به مخزن وجود دارد و اختلاف ارتفاع حدود ۳۷ متر آب ثبت گردیدگره های نزدیک فشار شکن نشوه نوروزی دارای بیشترین نرخ نشت مدل شده بودند. (۸/۵ L/s در سناریوی سطح ۲).

مدل عددی Water Gems پس از کالیبراسیون با داده های عملیاتی SCADA اختلاف کمتر از ۵ درصد با مقادیر واقعی دارد اما برای تشخیص نشت دارای خطای زیادی است. آموزش مدل های هوشمند با استفاده از داده های مدل عددی تا ۳۰ درصد می تواند میزان خطای نشت را نسبت به مدل فقط عددی کاهش دهد، حال آنکه مدل هوشمند MLP در تخمین شدت و محل نشت نسبت به ANN حدود ۳ درصد (ناچیز) بهبود نشان داد. ترکیب مدل عددی و هوشمند موجب افزایش دقت تشخیص نشت شبکه مخزن تا ۹۴ درصد گردید.

صرفه جویی اقتصادی پیش بینی شده در صورت اعمال سیستم پایش تلفیقی حدود ۱۶۰ میلیارد تومان در سال است. این چارچوب قابلیت توسعه برای سایر مخازن شمال شرق تهران (نظیر ۷۱ و ۴۸) را دارد. چارچوب عددی- هوشمند حاضر با داده های واقعی (نه فقط داده

شکل ۴ مقایسه ارزش واقعی با پیش‌بینی تلفیقی

ویژگی‌های تقویت‌شده مدل هیدرولیکی، توانست نشت‌های کوچک را که معمولاً در نویزهای هیدرولیکی گم می‌شوند، با دقت ۳۰ درصد بالاتر از مدل عددی شناسایی کند. با وجود نتایج درخشان، محدودیت‌هایی نظیر ماهیت متناوب داده‌های SCADA و وابستگی دقت مدل به کالیبراسیون پارامترهای زبری، ضرورت به‌روزرسانی مستمر داده‌ها را نشان می‌دهد. در نهایت، این پژوهش ثابت کرد که گذار به مدیریت هوشمند، مستلزم ادغام دانش فیزیک هیدرولیک با قدرت محاسباتی هوش مصنوعی است. این چارچوب با قابلیت تعمیم‌پذیری بالا، ابزاری پیش‌گیرانه برای کاهش تلفات آب NRW و حفظ پایداری منابع آبی محسوب می‌شود.

کالیبراسیون نشان داد که مدل عددی با تطابق بالا با داده‌های لحظه‌ای SCADA میانگین خطای کمتر از ۵ درصد، ($PMI=0.94$ و $RMSE=3.8$) زیربنای استواری برای یادگیری ماشین ایجاد کرده است. استفاده از قابلیت Emitter در Water Gems با در نظر گرفتن ضریب رفتار شب‌نمایی ($n \approx 0.53$) توانست افت فشار غیرخطی ناشی از نشت را به دقت شبیه‌سازی کند. بررسی‌های مقایسه‌ای نشان داد که مدل هیبریدی (Water Gems + MLP) با دقت تشخیص ۹۴ درصد، برتری چشمگیری نسبت به مدل‌های تک‌بعدی دارد. در حالی که مدل عددی صرف تنها ۷۲ درصد از تغییرات را شناسایی می‌کرد، نقطه قوت اصلی در تلفیق این دو نهفته است؛ مدل هیبریدی با بهره‌گیری از توانایی شبکه عصبی در استخراج الگوهای غیرخطی از

5- List of Symbols

Q_{leak} (L/s/m)	Leakage Rate
C_e	Emitter Coefficient
N	Leakage Exponent
P (m)	Pressure
PMI	Pressure Match
$RMSE$ (m)	Root Mean Square Error
R^2	Coefficient of Determination
NSE	Nash-Sutcliffe Efficiency
Q_{out} (L/m)	Average total outlet flow
n	Manning's Roughness Coefficient

Acknowledgments

The authors would like to express their gratitude to the Tehran Water and Wastewater Company for providing the necessary data and access to the water distribution network information required for this study.

Credit Authorship Contribution Statement

Conceptualization, S.A.S. and S.Y.; Methodology, S.A.S. and S.Y.; Software, S.A.S.; Data Curation, S.A.S.; Data Analysis, S.A.S. and S.Y.; Investigation, S.A.S.; Writing—Original Draft Preparation, S.A.S.; Writing—Review and Editing, S.Y.; Visualization, S.A.S.; Supervision, S.Y..

All authors have read and agreed to the published version of the manuscript.

Funding

This research received no external funding.

Data Availability Statement

The data presented in this study are available on request from the corresponding author. The data are not publicly available due to privacy and security restrictions regarding the water supply network.

Conflicts of Interest

The authors declare no conflict of interest.

References

- Alsaydalani, m (2024) Hydraulic Modelling for Leakage Reduction in Water Distribution Systems Through Pressure Control, *The Open Civil Engineering Journal* 18(1) <https://doi.org/10.2174/0118741495289971240112101323>
- Ben, L. Alves, D. Belesa, J. Cembrano, G. (2022) Leak Localization in Water Distribution Networks Using Data-Driven and Model-Based Approaches. *Journal of Water Resources Planning and Management* 148(5). [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001542](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001542)
- Mashhadi, A. H., & Jalili Ghazizadeh, M. (2021). Leak detection and localization in water distribution networks using pressure data and deep learning. *Journal of Water Resources Planning and Management*, 147(9), 04021066,

- [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001374](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001374)
- Xu, X., Zhang, Q., & Li, H. (2022). A data-driven leak detection approach in water distribution systems combining pressure monitoring and PCA. *Water Research*, 221, 118698. <https://doi.org/10.1016/j.watres.2022.118698>
- Ferrandez-Gamiz, R., & Alvisi, S. (2023). Application of hybrid physics-machine learning models for leakage detection in water networks. *Environmental Modelling & Software*, 167, 105674. <https://doi.org/10.1016/j.envsoft.2023.105674>
- Rahmani, Z., Mosavi, A., & Sadeghi, A. (2024). Integrating numerical simulation and machine learning for early leakage detection in Iranian water networks. *Environmental Modelling & Software*, 180, 105512. <https://doi.org/10.1016/j.envsoft.2024.105512>
- Chen, Y., Li, X., & Zhao, L. (2023). Leakage localization in smart water networks using neural and reinforcement models. *Water Research*, 237, 119991. <https://doi.org/10.1016/j.watres.2023.119991>