



Integration of artificial neural networks with hydraulic modeling for leak detection in water distribution networks

Seyed Abedin Sajedi¹ | Somayeh Yousefi^{2✉} | Babak Bayat³

1. Department of Civil & Environmental Engineering, CT.C., Islamic Azad University, Tehran, Iran. E-mail: a.sajedi.civil@iau.ac.ir
2. Corresponding Author, Department of Civil & Environmental Engineering, CT.C., Islamic Azad University, Tehran, Iran. E-mail: s.yousefi@iauctb.ac.ir
3. Department of Civil Engineering, Pa.C., Islamic Azad University, Parand, Iran. E-mail: babak.bayat@iau.ac.ir

Article Info	ABSTRACT
Article type: Research Article Article history: Received 25 February 2026 Received in revised form 1 July 2026 Accepted 4 July 2026 Published online 22 August 2026 Keywords: <i>Hydraulic simulation</i> <i>Integrated model</i> <i>Neural network (ANN)</i> <i>Water leakage</i>	Excessive water losses due to leakage have become a major concern for national water authorities. In fact, the Tehran Water and Wastewater Company has been forced to implement complete nightly shutdowns in the city's water distribution networks to conserve water, causing public dissatisfaction and increasing the risk of contaminant intrusion into the system. This study adopts a data-driven hybrid approach, combining numerical modeling of Reservoir 43—located in northeastern Tehran—using Water GEMS software, and training an Artificial Neural Network (ANN) with pressure and flow outputs from the hydraulic model under leak conditions to predict both location and magnitude of leaks. Model performance and accuracy were evaluated based on RMSE, MSE, and R^2 criteria. Numerical simulations showed that, after applying leak conditions, the average pressure decreased by approximately 0.9 bar, while flow rates in main pipelines increased by around 35%. The results indicated that the probability of detecting leaks ranged between 67% and 88%. Following full training, the integrated model estimated pressure drops and flow increases caused by leaks with very high precision, reducing the prediction error to 4% by the end of the training period. This high accuracy confirms the model's reliability for rapid and targeted leak identification under real operational conditions. The success of this method depends on the accuracy of hydraulic model calibration and the quality of measured data. In this research, calibration was performed based on engineering knowledge, adjusting pipe roughness, local losses, and minor loss coefficients until the difference between modeled and field data was less than 5%.

Cite this article: Sajedi, S. A., Yousefi, S., & Bayat, B. (2026). Integration of artificial neural networks with hydraulic modeling for leak detection in water distribution networks. *Journal of Water and Irrigation Management*, 16 (2), 411-425. DOI: <https://doi.org/10.22059/jwim.2026.411988.1292>





تلفیق شبکه عصبی مصنوعی با مدل سازی هیدرولیکی برای تشخیص نشت در شبکه توزیع آب

سیدعابدین ساجدی^۱ | سمیه یوسفی^۲ | بابک بیات^۳

۱. گروه مهندسی عمران و محیط زیست، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: a.sajedi.civil@iau.ac.ir

۲. نویسنده مسئول، گروه مهندسی عمران و محیط زیست، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: s.yousefi@iauctb.ac.ir

۳. گروه مهندسی عمران، واحد پرند، دانشگاه آزاد اسلامی، پرند، ایران. رایانامه: babak.bayat@iau.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	تلفات زیاد نشت آب موجب نگرانی مسئولین آب کشور شده است تا جایی که آبفای تهران به ناچار در سال جاری برای ذخیره آب اقدام به قطع کامل شبانه در شبکه های توزیع آب نمود که موجب نارضایتی مشترکین و افزایش خطر ورود آلاینده به داخل شبکه شد. این پژوهش با رویکرد ترکیبی داده محور، شامل مدل سازی عددی مخزن ۴۳ واقع در شمال شرق تهران با نرم افزار Water Gems و آموزش شبکه عصبی ANN با خروجی های فشار و دبی مدل عددی برای حالات نشت، به پیش بینی محل و مقدار نشت ها پرداخت. برای سنجش عملکرد و دقت مدل ها از معیارهای RMSE، MSE، R^2 بهره گرفته شد. در مدل سازی عددی بعد از اعمال نشت، میزان فشار به طور متوسط حدود ۰/۹ بار کاهش و مقدار دبی در خطوط اصلی حدود ۳۵ درصد افزایش یافت. نتایج نشان داد احتمال تشخیص نشت در بازه ۶۷ تا ۸۸ درصد قرار داشته است. مدل تلفیقی، بعد از آموزش کامل افت فشار و افزایش دبی ناشی از نشت را با دقت بسیار بالایی تخمین زد، طوری که خطای پیش بینی در پایان دوره آموزش به چهار درصد کاهش یافت. این دقت بالا، قابلیت اطمینان مدل را برای شناسایی سریع و هدفمند محل نشت در شرایط واقعی تایید می کند. موفقیت این روش وابسته به صحت کالیبراسیون مدل هیدرولیکی و کیفیت داده های اندازه گیری شده است که در این پژوهش کالیبراسیون براساس دانش مهندسی برای زبری لوله ها، تلفات موضعی و ضرایب افت جزئی تا زمانی تنظیم شدند که اختلاف بین مقادیر مدل و داده های میدانی کمتر از ۵ درصد باشد.
کلیدواژه ها: شبیه سازی هیدرولیکی شبکه عصبی (ANN) مدل تلفیقی مدل عددی	

استناد: ساجدی، سید عابدین؛ یوسفی، سمیه و بیات، بابک (۱۴۰۵). تلفیق شبکه عصبی مصنوعی با مدل سازی هیدرولیکی برای تشخیص نشت در شبکه توزیع آب. نشریه مدیریت آب و آبیاری، ۱۶ (۲)، ۴۱۱-۴۲۵. DOI: <https://doi.org/10.22059/jwim.2026.411988.1292>



۱. مقدمه

بعد از مدیریت فشار در شبکه های توزیع شهری، کاهش تلفات آب به عنوان یکی از راهبردی ترین و اقتصادی ترین اقدامات در مدیریت منابع آب و مقابله با چالش کم آبی در کشور مطرح شده است. شبکه های توزیع آب (WDNs) سیستم های پیچیده ای هستند که مستعد از دست دادن قابل توجهی از منابع آبی کشور می باشند، تلفاتی که عمدتاً ناشی از نشت لوله ها و اتصالات است آب به حساب نیامده (NRW) از اختلاف بین مقدار آب تزریقی به شبکه و آب فروش رفته به دست می آید که بخش قابل توجهی از آن مربوط به نشت های نامرئی و شناسایی نشده است. فشار بالا موجب افزایش چشم گیر نشت می شود، در حالی که کاهش فشار نیز خطرات زیست محیطی ناشی از ورود آلاینده ها به شبکه را در پی دارد، بنابراین، شناخت دقیق از وضعیت هیدرولیکی شبکه و کنترل تغییرات فشار اولین اقدام جهت پایداری سیستم آبرسانی است (Tabesh *et al.*, 2003).

نشت ها اغلب در محل شکستگی لوله ها و اتصالات رخ می دهند و عواملی چون عدم رعایت اجرای صحیح شبکه، استفاده از اجناس غیر استاندارد و سن بالای شبکه در تشدید آن نقش دارند (Sharma *et al.*, 2021). نشت های مخفی ممکن است مدت ها نمایان نشوند و منجر به آب شستگی بستر خاک، نشست و فرسایش زیرساخت ها شوند که هدررفت منابع بارزش آب شیرین را به دنبال دارد. مدیریت فشار از طریق کاهش فشار، راحت ترین اقدام اقتصادی است، اما به دلیل ناترازی در مقدار منابع و مصارف به ویژه در شهر تهران، به تنهایی کافی نیست. برآوردهای جهانی نشان می دهد که نشت می تواند تا ۷۰ درصد از تلفات آب در سیستم های انتقال را به خود اختصاص دهد (Al Zahab, 2019). در برخی کلان شهرها نرخ آب بدون درآمد از مرز ۳۵ درصد فراتر رفته است (Zhou *et al.*, 2022). اهمیت نشت آب فراتر از ابعاد اقتصادی است و جنبه های حیاتی زیست محیطی و اجتماعی را نیز در بر می گیرد، زیرا افت فشار ناشی از نشتی ها می تواند زمینه را برای نفوذ آلاینده ها فراهم آورد و سلامت عمومی را تهدید کند (Yousefi Khoshqalb *et al.*, 2024).

اعمال کاهش فشار در شبکه های توزیع موجب می شود تعداد محل های نشت و همچنین مقدار نشت کاهش پیدا کند، اما کاهش فشار بیش از فشار اقتصادی همانطور که گفته شد علاوه بر مشکلات زیست محیطی موجب رسوب گذاری و مشکلات هیدرولیکی خواهد شد. تأمین پایدار منابع آب شهری، دغدغه ای محوری برای مدیران شهری است. بخش قابل توجهی از این اتلاف، مربوط به سیستم توزیع بوده و ناشی از نشت در لوله ها است. این معضل نه تنها منجر به هدررفت منابع حیاتی می شود، بلکه پیامدهای ثانویه ای نظیر فرسایش زیرساخت ها، افزایش هزینه های انرژی مورد نیاز برای پمپاژ و افت فشار مؤثر در نقطه مصرف نهایی را به دنبال دارد (Zhou *et al.*, 2022) آمارها نشان می دهند که به طور متوسط، حدود ۱۰ تا ۳۰ درصد از آب تولیدی به دلیل نشت از دست می رود (Li *et al.*, 2023) در برخی کلان شهرها، نرخ آب بدون درآمد^۲ (NRW) از مرز ۳۵ درصد نیز فراتر رفته است. مدیریت مؤثر این تلفات به طور مستقیم با بهره وری اقتصادی و ظرفیت پایداری شبکه مرتبط است. اهمیت نشت آب فراتر از ابعاد صرفاً اقتصادی است و جنبه های حیاتی زیست محیطی و اجتماعی را نیز در بر می گیرد. افت فشار ناشی از نشتی ها می تواند زمینه را برای نفوذ آلاینده ها به درون شبکه فراهم آورد، که تهدیدی جدی برای بهداشت عمومی محسوب می شود و از لحاظ کیفی قابل بحث می باشد. لذا، توسعه راه کارهای شناسایی نشت امری ضروری است (Ali *et al.*, 2022) در مقابل، روش های مرسوم مانند پایش صوتی یا ثبت محلی پارامترها، به دلیل محدودیت های منابع انسانی و گستردگی جغرافیایی شبکه، آلودگی های صوتی، کارایی لازم را ندارند (Rossman, 2000)، از این رو، توجهات به سمت استفاده از رویکردهای نوین داده محور (Data-driven) و مبتنی بر مدل های فیزیکی (Model-based) معطوف شده است.

تأمین پایدار منابع آب شهری، دغدغه ای محوری برای مدیران شهری است. بخش قابل توجهی از اتلاف،

مربوط به سیستم توزیع بوده و ناشی از نشت در لوله‌ها و اتصالات است. این معضل نه تنها منجر به هدررفت منابع حیاتی می‌شود، بلکه پیامدهای ثانویه‌ای نظیر فرسایش زیرساخت‌ها، افزایش هزینه‌های انرژی موردنیاز برای پمپاژ و افت فشار مؤثر در نقطه مصرف نهایی را به دنبال دارد. در مقیاس کلان شهری مانند تهران، این مسئله تا حدی جدی است که مدیریت بحران گاهی به قطع شبانه توزیع آب منجر می‌شود که این امر خود تهدیدی جدی برای بهداشت عمومی به دلیل احتمال نفوذ آلاینده‌ها به شبکه است. در مقابل، روش‌های مرسوم نشت‌یابی (مانند پایش صوتی یا ثبت محلی) به دلیل محدودیت‌های منابع انسانی و گستردگی جغرافیایی، کارایی لازم برای پایش مستمر را ندارند.

رویکرد تلفیقی (هیبرید) با پیوند مدل عددی و هوشمند، راه‌کاری قدرتمند برای غلبه بر محدودیت‌های هر دو روش به صورت مجزا می‌باشد. مدل عددی با تولید داده‌های آموزشی استاندارد شده، بستر لازم برای آموزش مدل هوشمند را مهیا می‌سازد (Zhang & Wang, 2024). با وجود مزایای الگوریتم‌های شبکه عصبی مصنوعی، گاهی این الگوریتم‌ها در نقاط کمینه محلی و سراسری گیر می‌کنند و نمی‌توانند به خوبی عمل تخمین را انجام دهند. به همین دلیل، پژوهش‌گران به استفاده از الگوریتم‌های بهینه‌سازی و تکاملی برای بهبود نتایج مدل‌های منفرد مانند ANN روی آورده‌اند (Azar et al., 2022). در مقابل، روش‌های مرسوم مانند پایش صوتی یا ثبت محلی پارامترها، به دلیل محدودیت‌های منابع انسانی و گستردگی جغرافیایی شبکه، کارایی لازم برای پایش مستمر را ندارند (Rossman, 2000). از این رو، توجهات به سمت استفاده از رویکردهای نوین داده‌محور (Data-driven) و مبتنی بر مدل‌های فیزیکی (Model-based) معطوف شده است. مدل‌های مبتنی بر شبیه‌سازی هیدرولیکی (مانند Water Gems) در تولید داده‌های آموزشی استاندارد شده برای سناریوهای نشت کارآمد هستند، اما به تنهایی برای تخمین دقیق و سریع در زمان واقعی نیاز به کالیبراسیون‌های مکرر دارند. در مقابل، الگوریتم‌های یادگیری ماشین مانند شبکه عصبی مصنوعی (ANN) در تخمین سریع عملکرد خوبی دارند، اما عملکرد آن‌ها به شدت وابسته به کیفیت و تنوع داده‌های آموزشی است. رویکرد تلفیقی (هیبرید) با پیوند مدل عددی و هوشمند، راه‌کاری قدرتمند برای غلبه بر محدودیت‌های هر دو روش به صورت مجزا می‌باشد (Misarjani et al., 2024).

نوآوری این پژوهش، غلبه بر این محدودیت‌ها از طریق توسعه یک الگوریتم تشخیصی عملیاتی نشت است که به صورت کاربردی، مدل هیدرولیکی مخزن ۴۳ شمال شرق تهران (به دلیل تنوع ساختاری بالا) را با توانایی یادگیری سریع ANN تلفیق کرده و یک ساختار واحد برای پایش فراهم می‌آورد. این الگوریتم با تلفیق مدل هیدرولیکی توسط نرم‌افزار قدرتمند Water Gems و آموزش شبکه عصبی بر خروجی‌های آن، نه تنها نشت را با دقت بالا تخمین می‌زند، بلکه با استفاده از داده‌های واقعی پس از کالیبراسیون، استفاده از این الگوریتم را برای شناسایی نشت‌ها در محدوده تحت پوشش مخزن ۴۳ فراهم می‌کند و قابل تعمیم به تمام مخازن شرکت‌های آب و فاضلاب می‌باشد. این پژوهش در پاسخ به این چالش، دو پرسش اصلی را هدف قرار می‌دهد.

آیا تلفیق مدل دقیق هیدرولیکی شبکه مخزن ۴۳ با شبکه عصبی مصنوعی قادر است نشت را با دقت قابل قبول پیش‌بینی کند؟

آیا چارچوب توسعه یافته می‌تواند ابزاری عملیاتی و قابل اعتماد برای بهره‌برداران شبکه توزیع فراهم آورد و جایگزین روش‌های سنتی پرهزینه و پرخطا باشد؟

بدین منظور، هدف اصلی این پژوهش، توسعه و اعتبارسنجی یک الگوریتم تشخیصی عملیاتی نشت مبتنی بر مدل ترکیبی است و اهداف فرعی آن، مدل‌سازی دقیق شبکه با در نظر گرفتن زون‌های فشاری و تنوع اجناس؛ تولید سناریوهای نشت مبتنی بر مدل کالیبره شده برای آموزش و ارزیابی کمی عملکرد مدل نهایی که نشان داد خطای پیش‌بینی به ۳/۸ درصد کاهش می‌یابد.

۲. روش شناسی پژوهش

این پژوهش بر مبنای یک رویکرد تلفیقی (Hybrid) داده محور بنا شده است که مدل سازی هیدرولیکی پیشرفته را با قابلیت های یادگیری عمیق (شبکه عصبی مصنوعی - ANN) ادغام می کند. هدف اصلی، توسعه یک الگوریتم تشخیصی نشت است که بتواند محل و مقدار نشت را در شرایط واقعی شبکه مخزن ۴۳ با دقت بالا پیش بینی کند. برای شناخت بهتر از متدولوژی پژوهش، روش شناسی کلی تحقیق در (شکل ۱) نمایش داده شده است و گام های اجرایی آن در ادامه تشریح می گردد.

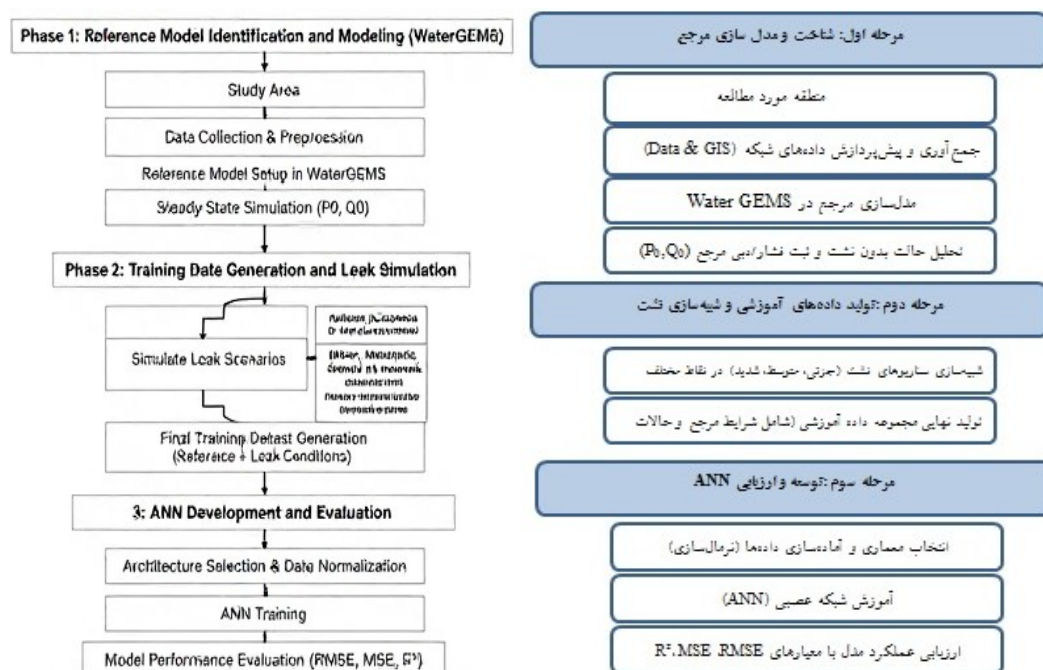


Figure 1. Research Steps

۱.۲. شناخت و مدل سازی مرجع

۱.۱.۲. منطقه مورد مطالعه

مخزن ۴۳ شرکت آب و فاضلاب منطقه دو شهر تهران واقع در شمال شرق تهران در ارتفاع ۱۴۸۲ متر از سطح دریا قرار دارد و از خطوط انتقال آب تصفیه خانه شماره سه و چهار تهرانپارس (سد لتیان) آبگیری می کند و دارای دو کمپارتمان با ظرفیت فوق العاده ۷۴ هزار مترمکعب است این مخزن از لحاظ گستردگی بزرگترین محدوده تحت پوشش را به خود اختصاص داده است جمعیتی حدود ۴۰۰۰۰ نفر را آبدهی می نماید. مخزن ۴۳ یک مخزن بالا دست را به صورت پمپاژ و بخشی از محدوده آبفای منطقه چهار را توسط یک شیر فشارشکن ۲۵۰ تأمین می کند شبکه توزیع تحت پوشش این مخزن از لوله های پلی اتیلن و چدن داکتیل از اقطار ۶۰ تا ۷۰۰ میلی متر، با تنوع سنی مختلف تشکیل شده است. فشار در این محدوده توسط سه لایه و زون فشاری توزیع می گردد. لایه های فشاری با استفاده از شیرهای فشارشکن از قطر ۱۵۰ تا ۳۰۰ میلی متر لایه های فشاری را کنترل می نمایند این محدوده به دلیل تنوع و گستردگی به عنوان منطقه مورد مطالعه انتخاب شده است (شکل ۲). محدوده تحت پوشش مخزن ۴۳ و موقعیت قرارگیری این مخزن در محدوده

شرکت‌های آب و فاضلاب تهران را نمایش می‌دهد. این محدوده دارای ۴۶۰ شیر قطع و وصل و ۲۶۰ شیر آتش‌نشانی زمینی فعال می‌باشد و با مخازن ۷۱،۹۴ و تصفیه‌خانه هم مرز است که توسط شیرهای حد ایزوله شده است.





Figure 2. Location of the area covered by Reservoir 43 Tehran City

در شکل (۲) ابتدا مرز بندی شرکت‌های شش گانه آب و فاضلاب تهران توسط لایه مناطق در نرم‌افزار Arc GIS ساخته شد و مخزن ۴۳ در شمال شرق و در محدوده شرکت آب و فاضلاب منطقه دو با رنگ قرمز متمایز شد، برای شناخت بهتر از محدوده تحت پوشش مخزن لایه فوق بر نقشه گوگل‌ارث شهر تهران اعمال و نمایش داده شد.

۲.۱.۲. جمع‌آوری و پیش‌پردازش داده‌های شبکه (GIS & Data)

استفاده از داده‌های واقعی ثبت‌شده شرکت آب و فاضلاب منطقه ۲ شهر تهران به‌عنوان یک نقطه قوت محوری این

تحقیق، صحت و قابلیت اطمینان مدل‌سازی‌های آبی را تضمین می‌کند. داده‌های هندسی و توپولوژیکی شامل مختصات دقیق گر‌ها و تجهیزات، مشخصات لوله‌ها (طول، قطر و جنس) و ساختار کلی شبکه، به‌طورمستقیم از GIS شرکت آب و فاضلاب منطقه ۲ تهران و پارامترهای هیدرولیکی مانند ضریب زبری هیزن-ویلیامز (C) و منحنی‌های تقاضای آب (Demand) در نقاط مصرف، از سوابق عملیاتی واحد مصرف شرکت جمع‌آوری شدند. تمامی داده‌های استخراج شده تحت فرایند پیش‌پردازش دقیق قرار گرفتند تا خطاهای توپولوژیکی، ناسازگاری مختصات و داده‌های غیرواقعی حذف شوند. این پالایش داده‌ها، اطمینان از صحت فیزیکی و هیدرولیکی مدل شبیه‌سازی (Water GEMS) را تضمین می‌کند.

۳.۱.۲. مدل‌سازی مرجع در Water GEMS

مدل‌سازی هیدرولیکی شبکه توزیع تحت پوشش مخزن ۴۳، به‌عنوان پایه و اساس تولید داده‌های آموزشی موردنیاز برای مدل یادگیری با استفاده از نرم‌افزار Water GEMS انجام پذیرفت این فرایند به دو مرحله متمایز و متوالی تقسیم می‌شود تا ابتدا وضعیت پایه شبکه تعیین شده و سپس اثر سناریوهای نشت مورد ارزیابی قرار گیرد (Li et al., 2023). مدل ساخته‌شده متشکل از ۸۶/۲ کیلومتر لوله و بیش از ۷۰۰ گر-ه است.

نتایج اولیه مدل (فشارها و دبی‌های محاسبه‌شده) با داده‌های واقعی اندازه‌گیری‌شده میدانی مقایسه می‌شود. تنظیمات پارامترهای ورودی مدل (مانند زبری لوله‌ها یا مقادیر تقاضا) تکرار می‌شود تا زمانی که نتایج شبیه‌سازی انحراف کمی (معمولاً کمتر از ۵ تا ۱۰ درصد) با داده‌های واقعی داشته باشند. در این پژوهش کالیبراسیون براساس دانش مهندسی تا اختلاف کمتر از ۵ درصد انجام شد تا یک مدل Water GEMS کاملاً شبیه‌سازی شده که فشار و دبی را در هر نقطه از شبکه در شرایط ایده‌آل (بدون نشت) به‌طور دقیق پیش‌بینی کند. این مدل، مدل کالیبره‌شده مرجع ماست.

۴.۱.۲. تحلیل حالت بدون نشت و ثبت فشار/دبی (P_0, Q_0)

هدف این مرحله، استخراج مجموعه داده ایده‌آل و بدون خطای فشار (P_0) و دبی (Q_0) شبکه در شرایط عملیاتی نرمال (Baseline) با استفاده از مدل کالیبره‌شده Water GEMS است. این داده‌ها به‌عنوان برچسب‌های صحیح (Ground Truth Labels) برای آموزش مدل ANN به‌کار خواهند رفت. شبیه‌سازی Baseline (شرایط بدون نشت) برای یک دوره عملیاتی کامل (مثلاً ۲۴ ساعت پیوسته) اجرا گردید تا اثر تغییرات تقاضای روزانه و تراز مخزن لحاظ شود. مقادیر فشار در تمامی اتصالات (Junctions) با فواصل زمانی مشخص (مثلاً ۱۵ دقیقه‌ای) ثبت گردید تا توزیع فشار اسمی شبکه (P) به‌دست آید.

این مقادیر با داده‌های حسگر واقعی مورد اعتبارسنجی قرار گرفتند. مقادیر تئوری دبی در تمامی لوله‌ها (Q) و همچنین دبی ورودی از مخزن به شبکه، مستندسازی شدند. تمامی بردارهای زمانی فشار و دبی استخراج‌شده در قالب فرمت‌های استاندارد (مانند CSV) ذخیره‌سازی شدند تا به‌عنوان مجموعه داده آموزشی برای مدل ANN آماده شوند.

۲.۲. تولید داده‌های آموزشی و شبیه‌سازی نشت

۲.۲.۱. شبیه‌سازی سناریوهای نشت (جزئی، متوسط و شدید)

برای شبیه‌سازی دقیق اثرات نشت در شبکه توزیع آب، از قابلیت Emitter در نرم‌افزار Water GEMS بهره گرفته شد. این قابلیت امکان مدل‌سازی جریان خروجی از یک گر-ه یا بخش لوله (به‌عنوان نماینده محل نشت) را براساس یک رابطه فشار-دبی فراهم می‌آورد. رابطه تجربی مورداستفاده در این پژوهش به‌صورت زیر است:

$$Q_{Leak} = C * P^n$$

رابطه (۱)

در این رابطه، Q_{leak} دبی نشت (مثلاً به لیتر بر ثانیه L/s) است. C ضریب جریان نشتی (Emitter Coefficient) است که میزان شدت نشت را در شرایط مرجع تعیین می‌کند. P فشار هیدرولیکی در نقطه نشت مثلاً برحسب متر آب (mWC) یا (bar) است. n نمای فشار (Leakage Exponent) است که بیانگر وابستگی دبی نشت به فشار می‌باشد. براساس یافته‌های تجربی و مطالعات پیشین در زمینه مدل‌سازی نشت در شبکه‌های توزیع، پارامترهای C و n به‌صورت تجربی و در طی فرایند کالیبراسیون مدل هیدرولیکی شبکه به مقادیر مناسب تنظیم گردیدند. به‌طور خاص، نمای فشار (n) در بازه ۰/۵ تا ۱ تنظیم شد تا رفتار فیزیکی نشت در لوله‌ها و اتصالات با دقت بیش‌تری شبیه‌سازی شود. مقدار ضریب C نیز متناسب با شدت نشت موردنظر (جزئی، متوسط و شدید) در گره‌های مختلف شبکه اعمال گردید. پس از ایجاد و کالیبراسیون مدل هیدرولیکی پایه شبکه، قابلیت Emitter برای تعریف سناریوهای مختلف نشت فعال شد. در این مرحله، مقادیر فشار در گره‌های مختلف شبکه که از تحلیل هیدرولیکی حالت پایه (بدون نشت) به‌دست آمده بود، به‌عنوان ورودی در رابطه بالا مورد استفاده قرار گرفت. سپس، نشت در گره‌های انتخاب‌شده با سطوح شدت متفاوت (جزئی، متوسط و شدید) شبیه‌سازی شد. خروجی این شبیه‌سازی‌ها شامل تغییرات در مقادیر دبی و فشار در سراسر شبکه بود که این داده‌ها به‌عنوان مجموعه داده‌های آموزشی برای مدل شبکه عصبی (ANN) مورد استفاده قرار گرفتند.

۲.۲.۲. تولید نهایی مجموعه داده آموزشی (شامل شرایط مرجع و حالات نشت)

داده‌های شرایط مرجع (بدون نشت) و سناریوهای نشت شبیه‌سازی‌شده با هدف ایجاد یک مجموعه داده جامع برای آموزش مدل شبکه عصبی مصنوعی (ANN) تلفیق و نهایی می‌شوند. ابتدا داده‌های حالت پایه به‌عنوان کلاس نشت صفر (No Leak) به داده‌های نشت افزوده شده تا مدل توانایی تشخیص شرایط نرمال شبکه را به‌دست آورد. سپس ساختار مجموعه داده به‌صورت یک ماتریس ویژگی-برچسب سازماندهی می‌شود؛ در آن، ویژگی‌ها شامل مقادیر فشار و دبی در نقاط نمونه‌برداری شبکه و برچسب‌ها نمایانگر مکان، شدت یا احتمال وقوع نشت هستند. برای هماهنگی مقیاس داده‌ها، مقادیر ورودی تحت نرمال‌سازی یا استانداردسازی قرار می‌گیرند (با روش‌هایی مانند Min-Max یا Z-Score)، تا تمامی متغیرها در دامنه آماری یک‌نواخت قرار گیرند و کارایی آموزش مدل افزایش یابد. در صورت هدف‌گذاری بر شناسایی مکانی نشت، شناسه‌های مکانی با استفاده از One-Hot Encoding به بردارهای عددی قابل فهم برای ANN تبدیل می‌شوند. در پایان، مجموعه داده نهایی به سه بخش آموزشی، اعتبارسنجی و آزمون با نسبت‌های معمول (۷۰، ۱۵ و ۱۵ درصد) تفکیک شده و سه پایگاه داده آماده و استاندارد برای آموزش مدل هوش مصنوعی در فاز بعدی شکل می‌گیرد.

۳.۲. توسعه و ارزیابی ANN

۳.۲.۱. انتخاب معماری و آماده‌سازی داده‌ها (نرمال‌سازی)

برای مدل‌سازی رابطه پیچیده بین داده‌های ورودی (فشار و دبی) و وضعیت نشت، رویکرد شبکه عصبی مصنوعی (ANN) انتخاب شد. این انتخاب براساس توانایی ذاتی ANN‌ها در یادگیری توابع نگاشت غیرخطی پیچیده و مقاومت نسبی آن‌ها در برابر نویز داده‌ها که در شبکه‌های توزیع آب رایج است، صورت پذیرفته است (Apaydin et al., 2020). شبکه عصبی مصنوعی (ANN) توسعه و آموزش یک مدل یادگیری عمیق (Deep Learning) برای شناسایی خودکار موقعیت و شدت نشت، با استفاده از الگوهای فشار و دبی استخراج‌شده از شبیه‌سازی‌های هیدرولیکی برای نگاشت رابطه پیچیده بین خروجی‌های دینامیکی شبکه (فشار و دبی) و برچسب‌های نشت (موقعیت و شدت)، یک معماری شبکه عصبی پیشخور (Feedforward Neural Network - FFNN) با ساختار زیر توسعه داده شد.

لایه ورودی (Input Layer) تعداد نورون های این لایه برابر با تعداد متغیرهای مشاهده پذیر استخراج شده از شبیه سازی های Water GEMS. این ورودی ها شامل مقادیر فشار در تمامی گره های شبکه و مقادیر دبی در خطوط انتقال اصلی در فواصل زمانی معین ۲۴ ساعته هستند.

لایه های پنهان (Hidden Layers) برای استخراج ویژگی های سطح بالاتر و برقراری ارتباط غیرخطی بین ورودی و خروجی، از دو لایه پنهان استفاده گردید. انتخاب معماری دو لایه ای براساس مطالعات اخیر در حوزه مدل سازی سری های زمانی هیدرولیکی صورت گرفت که کارایی این ساختار را در حل مسائل پیچیده تشخیص الگو اثبات کرده اند (Li et al., 2023). تعداد نورون ها در هر لایه پنهان (مثلاً ۶۴ و ۳۲ نورون) براساس تکنیک های بهینه سازی معماری (Heuristic Tuning) و براساس دستیابی به کمترین خطای اعتبارسنجی (Validation Error) تعیین گردید. فرایند Heuristic Tuning در این پژوهش شامل ارزیابی تکراری معماری های مختلف (مانند ۱ لایه با ۱۲۸ نورون، ۲ لایه با ۸۰ و ۴۰ نورون و ساختار نهایی ۶۴ و ۳۲) بود. هدف از این آزمایش ها، یافتن تعادلی بهینه بین ظرفیت مدل (Model Capacity) برای یادگیری الگوهای پیچیده نشت (که نیازمند نورون های بیش تر است) و جلوگیری از بیش برآزش (Overfitting) بر روی داده های آموزشی مخزن ۴۳ بود. معماری (۶۴، ۳۲) به دلیل ارائه بهترین عملکرد پایدار بر روی مجموعه داده اعتبارسنجی - (Validation Set) یعنی کمترین میزان واگرایی بین عملکرد مجموعه آموزش و اعتبارسنجی - به عنوان ساختار نهایی انتخاب شد و نشان داد که این تعداد نورون برای نمایش روابط غیرخطی بین تغییرات فشار/دبی و موقعیت نشت کافی است. تابع فعال سازی: در لایه های پنهان از تابع فعال سازی (ReLU (Rectified Linear Unit)) استفاده شد که به دلیل جلوگیری از مشکل گردادیان ناپدیدشونده (Vanishing Gradient) در شبکه های عمیق، برای این کاربرد مناسب است. ReLU به دلیل خطی بودن در ناحیه مثبت، باعث همگرایی سریع تر فرایند آموزش با بهینه ساز Adam می شود که در داده های سری زمانی هیدرولیکی (که ممکن است نوسان داشته باشند) مزیت بزرگی است. لایه خروجی (Output Layer) تعداد نورون های این لایه به طور مستقیم متناسب با اهداف آموزشی است. در این پژوهش، خروجی شامل مختصات گره دارای نشت و ضریب نشت (C) مرتبط است.

۲.۳.۲. آموزش شبکه عصبی (ANN)

مدل ANN با استفاده از ۷۰ درصد از داده های شبیه سازی شده (تولید شده از Water Gems) آموزش داده شد. برای تعیین وزن ها و بایاس های بهینه نورون ها، از الگوریتم پس انتشار خطا (Backpropagation) با استفاده از بهینه ساز Adam (Adaptive Moment Estimation) استفاده شد که کارایی بالایی در همگرایی سریع دارد (Rahmani et al., 2024).

۲.۳.۳. ارزیابی عملکرد مدل بر روی مجموعه آزمون (Test Set)

معیار ارزیابی عملکرد مدل براساس خطای بین مقادیر واقعی نشت و مقادیر پیش بینی شده مدل تنظیم گردید. در این پژوهش، از معیارهای استاندارد ارزیابی مدل های رگرسیون استفاده شده است.

- میانگین مربعات خطا (MSE)، برای سنجش اندازه خطاها؛
 - ریشه میانگین مربعات خطا (RMSE)، برای ارائه خطا در واحد اصلی داده ها؛
 - ضریب تعیین (R^2)، که نشان دهنده میزان انطباق مدل با داده ها است. مقدار $R^2=1$ بیانگر انطباق کامل است.
- این معیارها به طور کلی برای ارزیابی مدل های یادگیری ماشین در مسائل مهندسی توصیه شده اند (Ali et al., 2022). این فرایند تکرار شد تا زمانی که خطا بر روی مجموعه داده اعتبارسنجی به زیر آستانه از پیش تعیین شده برسد، که در نهایت منجر به دقت نهایی ۹۶/۲ درصد (خطای ۳/۸ درصد) در مجموعه داده تست گردید.

۳. یافته‌های پژوهش

این بخش به ارائه یافته‌های حاصل از اجرای مدل تلفیقی بر روی محدوده تحت پوشش مخزن شماره ۴۳ تهران می‌پردازد و نتایج شبیه‌سازی هیدرولیکی در نرم‌افزار Water Gems و عملکرد نهایی مدل ANN را با تمرکز بر جنبه‌های قابل‌استفاده برای بهره‌برداران از شبکه‌های توزیع آب شهری می‌پردازد.

۳.۱. تحلیل رفتار هیدرولیکی محدوده ۴۳ (داده‌های شبیه‌سازی)

همانطور که در منطقه مورد مطالعه ذکر شد، محدوده تحت پوشش مخزن ۴۳ (تهرانپارس) به دلیل برخورداری از انواع لوله با جنس‌ها با مصالح مختلف و اقطار متفاوت در شبکه تحت پوشش خود، یک بستر عالی و همه جانبه برای ارزیابی آشکارسازی نشت می‌باشد. نتایج شبیه‌سازی هیدرولیکی پس از اعمال سناریوی نشت، واکنش فوری شبکه را به نشت نشان داد، بعد از نشت فشار در سراسر شبکه تحت پوشش به‌طور متوسط حدود $0.9/0$ بار افت کرد و دبی در خطوط اصلی به میزان ۳۵ درصد افزایش یافت.

تقریباً در تمام محدوده تحت پوشش مخزن ۴۳، نقاط حساسیت بالا غالب هستند. این وضعیت ناشی از طول کوتاه خطوط انتقال (خط اصلی ۲۰۰ متری) و تراکم بالای مصرف‌کنندگان و ارتباطات نزدیک بین گرہ‌ها می‌باشد. این ساختار باعث می‌شود که تغییرات فشار و دبی ناشی از نشت، تقریباً به‌صورت هم‌زمان در تمام نقاط شبکه آشکار گردد و امکان آشکارسازی فوری (Real-Time Detection) فراهم شود.

سیر تغییرات فشار در یک دوره ۲۴ ساعته قبل و بعد از نشت برای محدوده تحت پوشش مخزن ۴۳ در شکل (۳) و تغییرات دبی در شکل (۴) مقایسه و تفسیر شده است. نوسانات فشار در شرایط عادی (خط آبی) بسیار محدود و پایدار، در محدوده ۴/۹۳ تا ۵/۰۵ بار قرار دارد و در شرایط نشت (خط چین نارنجی) وقوع نشت بلافاصله فشار را به محدوده ۴/۴۵ تا ۴/۵۵ بار کاهش می‌دهد (شکل ۳). این افت فشار قابل‌توجه و هم‌زمان در تمام نقاط، یک امضای هیدرولیکی قوی برای تشخیص نشت در این محدوده را فراهم می‌سازد. برای دبی در شرایط عادی، بین ۶۵ تا ۷۵ لیتر بر ثانیه در نوسان است و پس از نشت، دبی به محدوده ۷۵ تا ۸۵ لیتر بر ثانیه افزایش می‌یابد (شکل ۴) این افزایش ۳۵ درصدی تأیید می‌کند که سیستم برای جبران این فقدان، دبی بیش‌تری را از منابع خود (مخزن) می‌کشد که این پارامتر برای آموزش مدل‌های هوشمند بسیار مهم است.




Figure 3. 24-hour pressure variations in Reservoir 43




Figure 4. 24-hour flow rate variations in Reservoir 43

۲.۳. دقت مدل ANN در تعیین نشت

خروجی داده‌های مدل سازی (دینامیک هیدرولیکی) در نرم‌افزار Water Gems بعد از سناریوهای نشت به‌عنوان داده‌های ورودی به مدل شبکه عصبی ANN آموزش داده شد. از آنجایی که ارائه تمام نتایج حاصل از سری اطلاعات مورد استفاده برای آموزش شبکه امکان‌پذیر نیست به از مقایسه بخشی از نتایج سری اطلاعات اکتفا شده است. هدف این بخش، ارزیابی توانایی مدل در تخمین مقدار واقعی نشت (L/s) بود.

Table 1. Results of the artificial neural network in estimating leakage in Reservoir 43

ID	Leak Probability (%)	Leak Predicted (L/s)	Leak Actual (L/s)	Error (%)
J1	67	7.2	6.5	10.8
J2	70	8.0	7.1	12.7
J3	74	9.1	8.3	9.6
J4	78	10.3	9.5	8.4
J5	81	11.2	10.6	5.7
J6	85	12.0	11.4	5.3
J7	88	13.0	12.5	3.8

عملکرد مدل در نقاط گرهی مختلف محدوده تحت پوشش مخزن شماره ۴۳ در جدول (۱) خلاصه شده است. برجسته‌ترین یافته‌ها عبارتند از احتمال تشخیص نشت (Leak Probability) در نقاط مختلف از ۶۷ درصد در نقطه J1 شروع شده در نقاط میانی به ۷۸ درصد و در نهایت به ۸۸ درصد در نقطه J7 رسیده است. خطای پیش‌بینی، از حدود ۱۱ درصد در گره‌های اولیه در گره‌های میانی به ۸/۴ درصد و در نهایت به ۳/۸ درصد در گره J7 کاهش یافته است. عملکرد مدل ANN در نهایت با مقایسه نتایج پیش‌بینی‌شده در مقابل مقادیر واقعی نشت برای محدوده تحت پوشش مخزن ۴۳ ارزیابی شد، همانطور که در پایان مشاهده شد، مدل توانست خطای پیش‌بینی را به‌طور پیوسته از حدود ۱۱ درصد در ابتدای آموزش به خطای ۳/۸ درصد با دقت ۹۶/۲ درصد برساند. این نتایج، صحت و پایداری داده‌های آموزشی تولیدشده توسط مدل هیدرولیکی کالیبره‌شده را اثبات می‌کند و مبنای قابل‌اعتمادی برای استفاده در سامانه‌های پایش عملیاتی فراهم می‌سازد.

در مجموع، دقت نهایی ۹۶/۲ درصد به‌عنوان یک معیار رگرسیونی (تخمین کمی مقدار نشت برحسب L/s) محاسبه شده است، درحالی‌که Leak Probability بیش‌تر ماهیت طبقه‌بندی (آیا نشت در این نقطه وجود دارد؟) را دارد و به‌عنوان یک شاخص کیفی برای سنجش اطمینان مدل در نواحی مختلف شبکه به کار می‌رود.




Figure 5. Comparison of actual and predicted leakage for Reservoir 43

مقایسه نشت واقعی و پیش‌بینی‌شده در شکل (۵) ارائه شده است که همگرایی را به‌وضوح نمایش می‌دهد؛ منحنی پیش‌بینی‌شده پس از گذار اولیه کاملاً بر منحنی نشت واقعی منطبق می‌شود. این همسویی نهایی، نشان‌دهنده کالیبراسیون بسیار دقیق مدل در محیطی با واکنش سریع هیدرولیکی است و پایداری مدل در تشخیص نشت‌های کوچک‌تر را اثبات می‌کند.

۴. بحث

با وجود تعریف الگوهای مصرف شبانه (Night Pattern) در سیستم اسکادا برای مدیریت فشار در شبکه توزیع آب شهری، تنش آبی سال جاری در تهران باعث شد تا مدیران شرکت‌های آب و فاضلاب برای جلوگیری از هدررفت آب در نشت‌های شبانه اقدام به قطع کامل شبکه توزیع در ساعات پایانی شب (از ۲۲ تا ۰۶ صبح) نمایند. این سیاست و تصمیم اضطراری اگرچه در کوتاه‌مدت به ذخیره منابع آب کمک می‌کند و تأیید وجود نشت‌های قابل‌توجه در شبکه توزیع شهر تهران می‌باشد، اما علاوه بر ایجاد نوسانات شدید هیدرولیکی در شبکه و مخاطرات زیاد برای بهره‌برداران، موجب افزایش میزان حوادث و شکست درپایداری مجدد جریان در شبکه توزیع و فرسودگی تجهیزات قطع و وصل خواهد شد و خطرات جدی زیست‌محیطی را به‌دلیل افزایش ریسک نفوذ آلودگی از نقاط شکستگی (نشت) به داخل شبکه تحت فشار منفی به‌همراه دارد. به‌روشنی می‌توان گفت قطع و وصل کردن شبکه، راه‌کار اساسی مدیریت نشت نیست. در این راستا، چارچوب تلفیقی (Hybrid) پیشنهادی ما به‌دلیل قابلیت پایش روزانه و کم‌هزینه‌بودن، می‌تواند به شناسایی دقیق‌تر و سریع‌تر نشت‌ها کمک کرده و به‌طور مؤثری با این چالش بزرگ مدیریتی مقابله نماید. نتایج عملکردی مدل ANN در محدوده مخزن ۴۳ نشان داد که چارچوب تلفیقی می‌تواند به‌عنوان یک ابزار پایش پیشگیرانه عمل کند. خطای نهایی زیر چهار درصد، دقت کافی برای شناسایی را فراهم می‌کند. در یک سناریوی عملیاتی واقعی، تیم‌های تعمیرات می‌توانند با تکیه بر خروجی مدل تلفیقی، منابع خود را به‌جای بررسی ریسکی و پر خطا، بر موقعیت‌هایی متمرکز سازند که مدل، کم‌ترین خطا و بیش‌ترین احتمال نشت را گزارش می‌دهد. این رویکرد به‌طورمستقیم منجر به کاهش زمان پاسخ و در نهایت، کاهش سطح آب بدون درآمد (NRW) می‌شود که هدف اصلی مدیریت منابع آب شهری است و موجب جلوگیری از هدررفت منابع آبی کشور خواهد شد. نشت در شبکه‌های توزیع آب علاوه بر هدررفت منابع، خطر آلودگی شبکه را نیز

به دنبال دارد. روش های سنتی نشت یابی به دلیل هزینه بالا و زمان بردن پایش کارایی لازم را ندارند. به همین دلیل، رویکردهای مدل سازی جامع شبکه برای تعیین نقاط مستعد نشت مورد توجه قرار گرفته اند. این مقاله با استفاده از حل معکوس معادلات نشت و بهره گیری از کارایی شبکه های عصبی مصنوعی، موقعیت نشت های موجود در شبکه را تعیین می نماید. آموزش موفق شبکه های عصبی مستلزم حجم بالایی از داده های آموزشی با برچسب های دقیق (نتایج از پیش تعیین شده) است که تهیه آن در شرایط واقعی نشت شبکه توزیع آب عملاً غیرممکن است. این نیاز با شبیه سازی هیدرولیکی شبکه توسط نرم افزارهایی مانند Water Gems برطرف شده است. با این حال، از آنجایی که شبیه سازی های هیدرولیکی هرگز کاملاً دقیق نیستند، نتایج حاصل از شبکه عصبی آموزش دیده، حتی در بهترین حالت عملکردی، همواره حاوی یک درصد خطای اجتناب ناپذیر خواهند بود. انتخاب معماری و پارامترهای بهینه برای شبکه عصبی، به طور چشم گیری قابلیت اطمینان شبکه را در تخمین دقیق موقعیت نشت در گرهای متنوع شبکه، تحت سناریوهای مختلف نشت در محیط عملیاتی واقعی، افزایش خواهد داد. پژوهش حاضر با توسعه و ارزیابی یک مدل تلفیقی مبتنی بر Water Gems و شبکه عصبی ANN، کارایی این رویکرد ترکیبی را در تشخیص نشت در شبکه توزیع آب تهران (مخزن شماره ۴۳) به اثبات رساند. نتایج به دست آمده از مقایسه تطبیقی بین میزان نشت تخمین زده شده توسط شبکه عصبی و میزان نشت شبیه سازی شده توسط نرم افزار تخصصی Water Gems، به وضوح کارایی مطلوب شبکه های عصبی با آموزش داده های مدل سازی عدد را در حل موفقیت آمیز این نوع مسائل پیچیده تأیید و اثبات می نماید. نتایج نشان دادند که مدل تلفیقی برتری قابل توجهی نسبت به روش های صرفاً هیدرولیکی دارد و توانایی تخمین نشت با خطای نهایی کمتر از چهار درصد را داراست. این دقت بالا، مدل را به ابزاری عملیاتی برای سیستم های پایش هوشمند تبدیل می کند که می تواند تأثیر مستقیمی بر بهینه سازی فرایندهای مدیریت نگهداری و کاهش اتلاف آب (NRW) داشته باشد. در شبکه های دفنی و غیرقابل مشاهده انجام تعمیرات و حفاری به دلیل احتیاج به اخذ مجوز از راهنمایی و رانندگی، شهرداری و هزینه های نیروی انسانی و تجهیزات بسیار پرهزینه است، لذا روش های سنتی نشت یابی خود نیز پرهزینه است و خطای بالایی دارد و هیچ توجیهی ندارد، اما این مدل تلفیقی با خطای کمتر از چهار درصد برای حفظ و سیانت از منابع آب شیرین بسیار موثر می باشد.

پژوهش حاضر نشان داد که شبکه عصبی مصنوعی در پیش بینی نشت ها از دقت عملکردی فوق العاده ای برخوردار است. این ادعا براساس مقایسه نتایج آن با خروجی های مدل هیدرولیکی Water Gems و دست یابی به شاخص های آماری بسیار مطلوب ($R^2=0.981$ ، $RMSE=0.003$ و $MSE=0$) به اثبات رسید.

ضریب تبیین ($R^2=0.981$) این شاخص نشان می دهد که ۹۸/۱ درصد از تغییرات داده های هدف (خروجی واقعی نشت) توسط مدل شبکه عصبی پیش بینی شده است. در واقع، همبستگی بین پیش بینی مدل و واقعیت نزدیک به کامل (عدد ۱) است که نشان دهنده نرخ خطای بسیار پایین در تشخیص موقعیت یا شدت نشت است.

ریشه میانگین توان دوم خطا ($RMSE=0.003$) این پارامتر مقیاسی از میزان انحراف پیش بینی های مدل از مقادیر واقعی است. عدد ۰/۰۰۳ به قدری کوچک است که نشان می دهد تخمین های مدل با واقعیت تقریباً منطبق هستند و نوسانات خطا در کل مجموعه داده ها بسیار ناچیز است.

میانگین توان دوم خطا ($MSE=0$) رسیدن به عدد صفر (یا نزدیک به صفر که در رند کردن به صفر رسیده) به این معناست که مجموع مربعات خطاها به حداقل ممکن رسیده است. این یعنی مدل شما دچار (بیش برآزش یا کم برآزش) نشده و رفتاری کاملاً منطبق بر منطق هیدرولیکی شبکه دارد.

مدل های هیدرولیکی سنتی (مثل Water Gems به داده های ورودی بسیار دقیق و به روز (مثل زبری لوله ها) نیاز دارند که همیشه در دسترس نیست، اما شبکه عصبی شما با یادگیری از الگوهای رفتاری، توانسته است همان سطح از دقت را فراهم

کند. این یعنی در زمان بروز بحران یا تنش آبی، می‌توان به جای مدل‌سازی‌های زمان‌بر دستی، به این الگوریتم اعتماد کرد تا به سرعت نقاط آسیب‌پذیر و هدررفت آب را شناسایی کند. دقت خیره‌کننده $R^2=0.981$ در کنار خطای نزدیک به صفر، پیوندی مستحکم میان محاسبات نرم (هوش مصنوعی) و قوانین سخت هیدرولیکی برقرار کرده است. این نتایج ثابت می‌کند که مدل توسعه داده‌شده، نه تنها یک ابزار ریاضی، بلکه یک "دوقلوی دیجیتال" قابل اطمینان است.

۵. نتیجه‌گیری

روش پیشنهادی بر پایه استفاده از یک شبکه عصبی آموزش‌دیده استوار است که مزیت اصلی آن سادگی، عدم نیاز به تجهیزات گران‌قیمت و آزمایش‌هاست. پس از مدل‌سازی اولیه شبکه، این مدل آموزش‌دیده می‌تواند برای پیش‌بینی‌های طولانی‌مدت نشت به کار رود و با اعمال تغییرات جزئی و کم‌هزینه در ورودی‌ها به‌روزرسانی شود. دقت نتایج به‌طورمستقیم به صحت اطلاعات اولیه شبکه و دقت خود مدل عصبی وابسته است و با افزایش دقت هر دو عامل، قابلیت اطمینان بهبود می‌یابد. این در حالی است که مدل‌های شبیه‌سازی سنتی اغلب برای تعیین موقعیت نشت مناسب هستند و در برآورد مقادیر نشت درگره‌ها محدودیت دارند. در مقابل، روش پیشنهادی با هزینه محاسباتی بسیار پایین برای استفاده مستمر در بهره‌برداری شبکه مناسب است.

یکی از مزایای بنیادین رویکرد تلفیقی مورد استفاده، پتانسیل بالای تعمیم‌پذیری آن است. درحالی‌که کالیبراسیون اولیه مدل هیدرولیکی Water Gems به‌طور خاص برای ساختار فیزیکی مخزن ۴۳ انجام شده است، عملکرد برتر شبکه عصبی مصنوعی (ANN) به الگوهای رفتاری عمومی‌تری وابسته است که در کلیه شبکه‌های توزیع آب شهری مشترک هستند (مانند رابطه بین افت فشار و افزایش دبی در اثر نشت). مدل ANN، با یادگیری از این الگوهای اساسی، از وابستگی صرف به پارامترهای فیزیکی بسیار دقیق (مانند زبری لوله‌ها که متغیرترین بخش مدل‌های سنتی است) رها می‌شود. این امر باعث می‌شود تا مدل بتواند با تنظیمات جزئی و کم‌هزینه پارامترهای ورودی (مانند مشخصات عمومی لوله‌کشی یا فشارهای عملیاتی استاندارد)، به سرعت برای سایر مخازن (مانند مخازن مورد اشاره در بخش نتیجه‌گیری) با دقتی مشابه $96/2\%$ درصد بازآموزی (Retrain) و به‌کارگیری شود. این ویژگی، مدل توسعه‌یافته را از یک راه‌حل موردی به یک الگوریتم پایدار و مقیاس‌پذیر برای مدیریت شبکه آب در سطح ملی تبدیل می‌کند.

با توجه به این که تحلیل میزان بارش‌های زمستانی و خروجی مدل‌های هواشناسی برای فصل بهار، نشان‌دهنده تشدید تنش و بحران آبی در سال پیش‌رو نسبت به سال گذشته است، ضرورت مدیریت هوشمند منابع آب بیش از هر زمان دیگری احساس می‌شود. در همین راستا، ما نویسندگان این مقاله صمیمانه امیدواریم که استفاده از این الگوریتم عملیاتی و دقیق، که عملکرد آن با ضریب تعیین $R^2=0.981$ اثبات شده است، در سایر مخازن شهر تهران و سایر شبکه‌های مشابه در سراسر کشور، موجب تشخیص مؤثر نشت، کاهش متعاقب هدررفت شبکه و درنهایت موجب پایداری آب شرب در شبکه‌های توزیع شود و بدین ترتیب رضایت و آرامش شهروندان را تضمین کند.

۶. پی‌نوشت‌ها

1. Water distribution networks (WDNs)
2. Non-Revenue Water (NRW)
3. Pressure Reducing Valve (PRV)
4. Contaminant Intrusion
5. Data-driven Approach
6. Model-based Approach

۷. تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان وجود ندارد.

۸. منابع

- Ali, M., Gupta, S., & Joshi, A. (2022). Hybrid modeling for leakage detection in water distribution systems using hydraulic and data-driven approaches. *Journal of Water Resources Planning and Management*, 148(5), 04022034.
- Apaydin, E., & Gunes, O. (2020). Application of Artificial Neural Networks for Leak Detection in Water Distribution Networks: A Review. *Journal of Water Resources Management*.
- Azar, M., et al. (2022). Evolutionary optimization algorithms for enhancing ANN performance in leakage detection
- Al Zahab, R. (2019). Global water loss statistics in transmission systems: A review.
- Li, X., Chen, Y., & Zhao, L. (2023). Leakage localization in smart water networks using neural and reinforcement models. *Water Research*, 237, 119991.
- Li, S., Wang, S., & Zhang, H. (2023). Performance analysis of urban water distribution networks under various leakage scenarios using WaterGEMS simulation. *Journal of Water Resources Management*, 37(5), 1234-1248.
- Misarjani, P., Sayari, N., & Sayari, S. (2024). Leakage modeling in water supply networks using Water GEMS software and artificial neural network. *Journal of Water and Sustainable Development*, 8(2), 20. Water, Law and Ethics. (In Persian)
- 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.
- Rossman, L. A. (2000). *EPANET 2: Users manual*. U.S. Environmental Protection Agency, Cincinnati, OH.
- Sharma, D., Kumar, S., & Singh, R. (2021). Advances in hydraulic modeling for leak detection in aging water networks. *Applied Water Science*, 11(12), 227.
- Tabesh, M., et al. (2003). Pressure management strategy for urban water distribution networks to control leakage and intrusion.
- Yousefi Khoshqalb, H., et al. (2024). A review of methods for economic analysis of leakage in water distribution networks. *Iranian Water Resources Research*, 17(1), 68-101. SID. <https://sid.ir/paper/954844/fa>. (In Persian).
- Zhou, J., Liu, H., & Wang, M. (2022). Optimization-based leak detection in pipe networks using EPANET and genetic algorithms. *Journal of Hydrology*, 614, 128686.
- Zhang, L., & Wang, J. (2024). Deep hybrid CNN-LSTM model for smart water leak detection. *IEEE Access*, 12, 87309-87318.