



Detection of two simultaneous leakages in water distribution network using hybrid feedforward artificial neural networks

H. Fallahi¹, M. R. Jalili Ghazizadeh^{2*}, B. Aminnejad¹, J. Yazdi²

¹Department of Civil Engineering, Roudehen Branch, Islamic Azad University, Roudehen, Iran

²Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

ABSTRACT: Leakage is one of the main challenges in the operation of water distribution networks. In the present study, leakage is detected using Feedforward Artificial Neural Networks (ANNs). For this purpose, two scenarios are considered for training the ANNs. In the first scenario, two simultaneous leakages with equal values, and in the second scenario, two simultaneous unequal leakages are applied to each pair-node of a network. The training data are analyzed by EPANET2.0 hydraulic simulation software linked with the MATLAB programming language. In both scenarios, first, ANNs are trained using flow rates of total pipes number. Then, sensitivity analysis is performed by Hybrid ANNs for the flow rates of different percent of pipes numbers. The results of the proposed Hybrid ANNs indicate that in the first scenario, by having the flow rates of 10% of the total pipes, the locations of two simultaneous leakages are successfully determined. However, for the second scenario, while the difference between the two leakages is less than 80% of the maximum leakage (up to ratio value of 10 and 90 % leakages), by having 10% of the total pipes flow rates, the locations of the two leakages are still successfully determined. However, for larger differences, only the location of the bigger leak could be detected. Despite the complexities of the second scenario, the proposed ANNs could successfully detect the location of the bigger leakage

Review History:

Received: May, 08, 2021

Revised: Aug. 04, 2021

Accepted: Aug. 26, 2021

Available Online: Sep. 16, 2021

Keywords:

Leakage detection

Feedforward artificial neural network

discharge measurement

EPANET2.0

Water distribution networks

1- Introduction

Reducing the amount of leakage in water distribution networks (WDNs) can be considered one of the main goals of drinking water supply utilities. Some practical methods for detecting the leakage are acoustic sensors, Inverse Transient Analysis methods, numerical methods, and methods based on computational intelligence [1]. The leakage detection is investigated by: Wachala et al. [2] using the group of neuro-fuzzy classifiers, Attari et al. [3] using the combination of pressure and flow metering by ANNs¹, Kang et al. [4] based on convolutional neural network and a support vector machine, and Fallahi et al. [5] using feedforward artificial neural network in 24-hours a day. This study proposes a new methodology to locate up to two simultaneous leakages in WDNs using feedforward ANNs.

2- Methodology

2- 1- ANN Training

Using feedforward neural networks and the WDN proposed by Poulakis et al. [6], the ANNs were trained.

The training parameters were determined by EPANET2.0 hydraulic simulation software using MATLAB programming language. First, two simultaneous leakages were applied to two nodes as the output values of the ANN training dataset. Then, the pipes' flow was obtained by the EPANET2.0 as the inputs of the ANN training dataset. The multi-layer perceptron (MLP) was used for the function fitting of ANN in this study. Trainlm was utilized as the training function that updates weight and bias values according to Levenberg-Marquardt optimization.

2- 2- First scenario: two simultaneous leakages with equal values

The average daily water demand at each node was considered 20 l/s, and the total water demand was 600 l/s. Also, the maximum leakage value was assumed 1% of total water demand (6 l/s). In this scenario, 50% of the maximum leakage is assigned to two selected nodes (each node 3l/s). Finally, the "Leakage matrix (30×435)" was produced as the output of ANN training. By entering this matrix into

*Corresponding author's email: m_jalili@sbu.ac.ir



Table 1. Leakage distribution relative to maximum leakage in both selected nodes

Leak Group	First		Second		Third		Forth	
State	1	2	3	4	5	6	7	8
First Node (%)	60	40	70	30	80	20	90	10
Second Node (%)	40	60	30	70	20	80	10	90
Leakage Matrix (30×870)	40-60		30-70		20-80		10-90	

EPANET2.0 software, “Pipes Flow Matrix (50×435)” was produced as the input of ANN training. After that, the ANN was trained. The steps of ANN training are demonstrated in Figure 1.

2- 3- Second scenario: two simultaneous leakages with unequal values

The main goal in this scenario was the non-uniform distribution of leakage between the two selected nodes, as shown in Table 1. In this scenario, 4 “Leakage Matrix (30×870)” and 4 “Pipes Flow Matrix (50×870)” were produced.

3- Results and Discussion

In the present study, to investigate the ANN’s behavior, the Relative Leakage Error (RLE) is defined as:

$$RLE_i(\%) = \frac{CLD_{ANN_i} - HLD_i}{HLD_i} \times 100 \tag{1}$$

RLE: Relative Leakage Error, CLD_{ANN} : Calculated Leakage and Demand by ANN, *HLD*: a total of leakage and demand, *i*: number of junctions, $i=1,2,\dots,30$. Using Eq. (1), the *RLE* is calculated for the total nodes as the RLE Matrix in both scenarios. The results show that the first maximum (*RLEmax1*) and the second maximum (*RLEmax2*) value of each column of the RLE matrices indicate the position of the two leakages (in both scenarios). The optimal number of neurons in the hidden layer can find based on the maximum of the RLE (MaxRLE). The results illustrate 40 is the optimal neuron number for both scenarios. Figure 2 shows the result of scenario 1.

Considering 40 as the optimal neurons, the *RLEmax1*

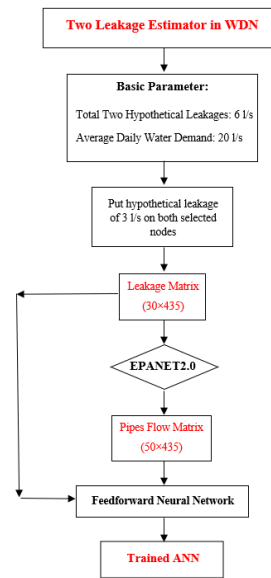


Fig. 1. Proposed flow chart for leakage detection

and *RLEmax2* for one of the leakage groups of the second scenario are shown in Figure 3.

In the previous section, the ANN was trained by considering flow rates of 100% of pipes number (50 pipes). For detecting the leakage location with a minimum number of pipes, the sensitivity analysis is performed by Hybrid ANNs for the flow rates of 2%, 4%, 6%, 8%, 10%, 20%, ...,90% of the number of the total pipe. Figure 4 illustrates the flowchart of constructing the Hybrid ANNs. The results show that the proposed Hybrid ANNs has successfully detected the leakage location for the first scenario and also the leakage group 40-60, 30-70, and 20-80 of the second scenario. These results are obtained by the measured flow rates of 10% of the total pipes (five pipes). While the difference between the two leakages is larger than 80% of the maximum leakage, only the location of the bigger leakage could be detected.




Fig. 2. The number of neurons at the hidden layer

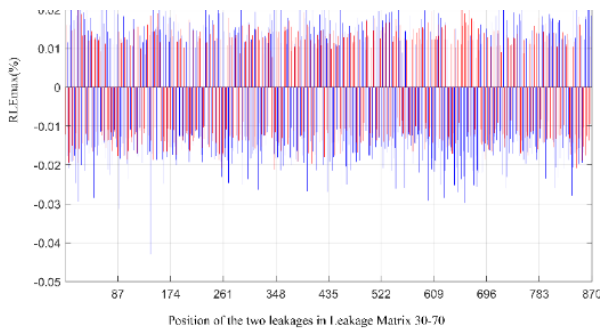


Fig. 3. RLEmax versus two simultaneous leakages

4- Conclusions

The accuracy of trained neural networks with total pipe flow was less than 0.2% for the first scenario and less than 0.05% for the second scenario. The sensitivity analysis was performed by Hybrid ANNs for the fewer pipe numbers with known flow rates. The obtained results indicate the promising applicability of the proposed methodology for finding leakage location in water distribution networks.

References

[1] Attari, M., & F.Maghrebi, M., 2018. "A new method of leak detection using artificial neural networks." Journal

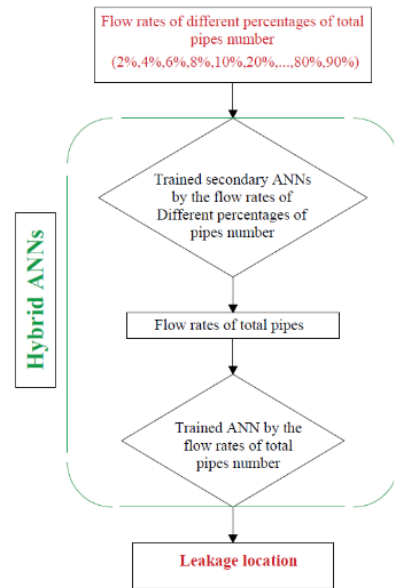


Fig. 4. Flowchart of constructing the Hybrid ANNs

of water and wastewater, 29(1), pp 14-26 (In Persian).

[2] Fallahi, H., Jalili Ghazizadeh, M.R., Aminnejad, B., & Yazdi, Y., 2021. "Leakage detection in water distribution networks using hybrid feedforward artificial neural networks." Journal of Water Supply: Research and Technology-Aqua, 70(5) 637-653.

[3] Kang J., Park Y. J., Lee J., Wang S. H. & Eom D.S., 2018. "Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems." IEEE Trans. Ind. Electron, 65(5),4279-4289.

[4] Poulakis Z., Valougeorgis D. & Papadimitriou C., 2003. "Leakage detection in water pipe networks using a Bayesian probabilistic framework." Probabilistic Engineering Mechanics, 18, 315-327.

[5] Wachla D., Przystalka P., & Moczulski, W. 2015." A method of leakage location in water distribution networks using artificial neuro-fuzzy system". IFAC-PapersOnLine, 48(21), pp 1216-1223.

[6] Yan, Y., Wang, L., Wang, T., Wang, X., Hu, Y., & Duan, Q., 2018. "Application of soft computing techniques to multiphase flow measurement: A review". Flow Measurement and Instrumentation, 60, pp 30-43.

HOW TO CITE THIS ARTICLE

H. Fallahi, M. R. Jalili Ghazizadeh, B. Aminnejad, J. Yazdi, Detection of two simultaneous leakages in water distribution network using hybrid feedforward artificial neural networks, Amirkabir J. Civil Eng., 54(5) (2022) 391-394.

DOI: 10.22060/ceej.2021.20017.7316





یافتن محل دو نشت همزمان در شبکه توزیع آب با استفاده از شبکه‌های عصبی مصنوعی پیش‌خور ترکیبی

حمیده فلاحی^۱، محمدرضا جلیلی قاضی زاده^{۲*}، بابک امین نژاد^۱، جعفر یزدی^۲

۱-دانشکده مهندسی عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران
۲-دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهیدبهشتی، تهران، ایران

تاریخچه داوری:

دریافت: ۱۴۰۰/۰۲/۱۸

بازنگری: ۱۴۰۰/۰۵/۱۳

پذیرش: ۱۴۰۰/۰۶/۰۴

ارائه آنلاین: ۱۴۰۰/۰۶/۲۵

کلمات کلیدی:

نشت‌یابی

شبکه عصبی مصنوعی پیش‌خور

دبی سنجی

EPANET2.0

شبکه‌های توزیع آب

خلاصه: نشت یکی از چالش‌های اساسی در بهره‌برداری از شبکه‌های توزیع آب است. در این پژوهش با استفاده از شبکه‌های عصبی مصنوعی پیش‌خور (Feedforward) به تعیین محل نشت‌ها در شبکه‌های توزیع آب پرداخته شده است. برای این منظور، دو سناریو در آموزش شبکه‌های عصبی در نظر گرفته شده است. در سناریو اول دو نشت همزمان با مقادیر برابر و در سناریو دوم دو نشت همزمان اما با مقادیر نابرابر در هر یک از دو گره شبکه قرار داده شده است. داده‌های آموزش با استفاده از نرم‌افزار شبیه‌ساز هیدرولیکی EPANET2.0 در محیط MATLAB به دست آمده است. در هر یک از دو سناریو، ابتدا شبکه‌های عصبی با استفاده از مقدار دبی کل لوله‌ها آموزش می‌بینند. سپس تحلیل حساسیت توسط شبکه‌های عصبی مصنوعی ترکیبی به ازای مقدار دبی درصدی مختلف لوله‌ها انجام می‌شود. نتایج شبکه‌های عصبی ترکیبی پیشنهادی نشان می‌دهد که در سناریو اول با داشتن دبی ۱۰٪ لوله‌ها موفقیت دو نشت همزمان با موفقیت قابل تعیین است. در سناریو دوم، مادامی که اختلاف مقدار دو نشت کمتر از ۸۰٪ نشت بیشینه است (تا نسبت‌های ۱۰ و ۹۰ درصد) با داشتن دبی ۱۰٪ لوله‌ها، موفقیت هر دو نشت با موفقیت تعیین می‌گردد. اما برای اختلاف‌های بیشتر، فقط محل نشت بزرگ‌تر قابل تعیین است. علی‌رغم پیچیدگی‌های سناریوی دوم، شبکه‌های عصبی پیشنهادی نشت‌های بزرگ‌تر را با موفقیت تشخیص می‌دهند.

۱- مقدمه

داده شده است. یکی از روش‌های معمول در شبکه‌های توزیع به منظور کاهش نشت، استفاده از روش‌های مدیریت فشار است [۳ و ۲]. از جمله روش‌های کاربردی دیگر برای پیدا کردن محل نشت استفاده از سنسورهای صوتی به صورت ثابت و متحرک است [۴]. همچنین روش‌های مدل‌سازی تحلیل معکوس جریان گذرا در سال‌های اخیر به منظور تشخیص نشت جایگاه ویژه‌ای در نزد مهندسين پیدا کرده است [۵]. این روش‌ها به دلیل حل عددی مسئله به صورت گام‌های زمانی متوالی در تمامی گره‌های محاسباتی، از منظر راندمان محاسباتی، پرهزینه و زمان‌بر است. در حل چنین مسائلی پرهزینه مهندسی، تجربه نشان داده که استفاده از تکنیک‌های یادگیری ماشین به خصوص فرایند داده‌کاوی توانسته سبب افزایش کارایی محاسباتی شود [۶]. روش‌های عددی به منظور مدل‌سازی نشت در شبکه‌های توزیع آب ابزار مهم و کلیدی می‌باشند [۷]. بررسی‌های اخیر در زمینه هوش محاسباتی، مانند محاسبات نرم، یادگیری ماشین و یا مدل‌سازی بر اساس داده خروجی، بسیاری از مشکلات در زمینه مسائل مهندسی را حل کرده

با کمیاب شدن منابع آب شرب در بسیاری از نقاط جهان، به منظور مدیریت کارآمد این ماده حیاتی، توسعه روش‌های مختلف اهمیت ویژه‌ای یافته است. همچنین با توجه به محدودیت‌های موجود در منابع تأمین آب و هزینه بالای آن، می‌توان با بهره‌برداری اصولی و علمی از منابع آب موجود و جلوگیری از هدررفت آب، نیازها و کمبودهای آبی را به نحوه صحیحی مدیریت نمود. کاهش میزان نشت در شبکه‌های توزیع آب را می‌توان یکی از اهداف عمده سازمان‌های تأمین کننده آب شرب دانست. نشت در شبکه‌های توزیع آب علاوه بر اتلاف آب، باعث کاهش کیفیت (به دلیل افزایش احتمال ورود آلودگی از طریق نشت)، افت فشار، اتلاف انرژی و افزایش هزینه‌های مربوط به تصفیه، انتقال و توزیع می‌شود. بنابراین مدیریت شبکه‌های توزیع آب به منظور کاهش نشت می‌بایست به نحوی صورت گیرد که بالاترین کیفیت آب به دست مصرف کننده برسد [۱]. تاکنون روش‌های مختلف تجربی و تحلیلی زیادی برای محاسبه مقدار نشت توسط پژوهشگران، توسعه

* نویسنده عهده‌دار مکاتبات: m_jalili@sbu.ac.ir



می‌باشد.

در پژوهش حاضر روشی جدید برای تعیین موقعیت دو نشت همزمان در شبکه‌های توزیع آب با استفاده از شبکه‌های عصبی پیش‌خور ارائه شده است. اکثر روش‌های تشخیص موقعیت نشت در شبکه‌های توزیع آب بر اساس فشار گرهی می‌باشند که مقاله حاضر از دبی‌سنجی و بررسی مقدار و جهت دبی‌های گذرنده از لوله‌ها برای یافتن موقعیت نشت استفاده می‌کند که کمتر مورد بررسی قرار گرفته است. حساسیت دبی در شرایط وجود نشت و تغییرات آن نسبت به حالت عدم وجود نشت زیاد است در حالی که تغییرات فشار در گره‌ها در شرایط وجود نشت کم است. همچنین با لحاظ کردن توزیع غیریکنواخت نشت علاوه بر توزیع یکنواخت، شبکه‌های عصبی ارائه شده قادر به تشخیص موقعیت نشت‌های کوچک تا بزرگ می‌باشند. در برخی از تحقیقات گذشته نیز از شبکه‌های عصبی MLP (و عمدتاً مبتنی بر فشارسنجی) برای نشت‌یابی استفاده شده است که در آن‌ها تعداد گره‌های پایش به طور تصادفی و دلخواه در نظر گرفته شده است، اما در پژوهش حاضر، برای اولین بار، شبکه‌های عصبی مصنوعی ترکیبی^۷ و مبتنی بر اطلاعات دبی‌سنجی برای تشخیص موقعیت نشت‌ها ارائه شده است و با این رویکرد، تعداد حداقل لوله‌های لازم برای نصب دبی‌سنج بر روی آن‌ها تعیین شده است. به منظور شبیه‌سازی هیدرولیکی شبکه، با نوشتن کدهایی در MATLAB، برنامه ارتباطی بین EPANET2.0 و MATLAB ایجاد شده است تا بتوان با تکرار بالا و زمان بهینه که قابل انجام برای کامپیوترهای مرسوم است، برنامه را اجرا نموده و به نتایج مطلوب‌تری رسید. به منظور آموزش شبکه‌های عصبی، دو سناریو پیشنهاد شده است. در سناریو اول دو نشت همزمان با مقدار برابر و در سناریو دوم دو نشت همزمان با مقدار نابرابر به هر دو گره شبکه اعمال می‌شود. در هر یک از دو سناریو، ابتدا شبکه‌های عصبی با فرض داشتن دبی کل لوله‌ها آموزش می‌بینند. از آنجایی که تعیین موقعیت نشت با اطلاعات حداقل تعداد لوله، برای استفاده روش‌های پیشنهادی در شبکه‌های توزیع آب ضروری است، در این پژوهش شبکه‌های عصبی مصنوعی ترکیبی به ازای دبی درصدی مختلف لوله‌ها، با استفاده از تحلیل حساسیت برای پیدا کردن تعداد لوله بهینه معرفی شده است. نتایج قابلیت بالای روش پیشنهادی را نشان می‌دهد.

است [۸]. شبکه‌های عصبی مصنوعی^۱ به طور گسترده در تمام زمینه‌های مهندسی و روش‌های مدل‌سازی بر اساس سیستم‌های عصبی بیولوژیکی مورد استفاده قرار گرفته‌اند. این شبکه‌ها، به دلیل توانایی تقریب توابع پیچیده، می‌توانند ارتباط بین ورودی‌ها و خروجی‌های نظیر را تعیین نموده و با استفاده از قابلیت تعمیم‌دهی، در شرایطی که برای آن‌ها معرفی نشده نیز، عملکرد مناسبی از خود نشان دهند [۹]. همچنین مطالعاتی در زمینه نشت‌یابی در شبکه‌های توزیع آب با استفاده از شبکه عصبی چند لایه‌ای پرسپترون انجام گرفته که توانسته میزان محاسبات را نسبت به روش‌های متداول تا حدی کاهش دهد [۱۰].

در روش پیشنهادی واچلا^۲ و همکاران در سال ۲۰۱۵ [۱۱]، موقعیت نشت با استفاده از دسته‌بندی کننده‌های فازی-عصبی تعیین شده است. عطاری و فغفورمغربی در سال ۲۰۱۸ [۱۲]، با استفاده از شبکه‌های عصبی و آزمون و خطا، موقعیت و مقدار نشت در شبکه‌های توزیع آب را با دریافت فشار گرهی تعیین نمودند. کانگ^۳ و همکاران در سال ۲۰۱۸ [۱۳]، روشی دقیق بر اساس ترکیب شبکه عصبی کانولوشن و ماشین بردار پشتیبان^۴ برای تعیین موقعیت نشت ارائه دادند. کوئینونس-گروئو^۵ و همکاران در سال ۲۰۱۸ [۱۴]، کاربرد دسته‌بندی کننده‌های با نظارت در تعیین موقعیت نشت در شبکه‌های توزیع آب را مورد بررسی قرار دادند. در چارچوب تشخیص الگوی آن‌ها، ۴ ابزار دسته‌بندی مورد استفاده قرار گرفته است: نزدیک‌ترین همسایگی، دسته‌بندی کننده بیز، شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان. برخی دیگر از محققین نیز با استفاده از ترکیب شبکه‌های عصبی مصنوعی و تئوری گراف نیز به تعیین موقعیت نشت در شبکه‌های توزیع آب پرداختند [۱۶ و ۱۵]. روش‌های فوق‌الذکر مبتنی بر شبکه‌های عصبی، قادر به شناسایی نشت‌های کوچک نمی‌باشند زیرا به داده‌های آموزش گسترده‌ای نیاز دارند. این مسئله منجر به افزایش زمان آموزش و پیچیدگی روند آموزش می‌شود. همچنین داده‌های نادرست و ناکافی در مرحله آموزش شبکه‌های عصبی منجر به نتایج نادرست می‌شود [۱۷]. فلاحی و همکاران در سال ۲۰۲۰ [۱۸] به تعیین محل نشت در ۲۴ ساعت شبانه‌روز با استفاده از شبکه‌های عصبی پیش‌خور^۶ در شبکه‌های توزیع آب پرداختند. شبکه‌های عصبی پیشنهادی آن‌ها، قادر به شناسایی نشت‌های کوچک در تمامی ساعات شبانه‌روز نیز

- 1 Artificial Neural Network (ANN)
- 2 Wachla
- 3 Kang
- 4 CNN-SVM
- 5 Quinones-Gruciro
- 6 Feedforward Neural Network

۲- شبکه مورد مطالعه

شبکه توزیع آب مورد مطالعه در این مطالعه، شبکه معروف پولاکیس می‌باشد که اولین بار در سال ۲۰۰۳ معرفی شد (شکل ۱). این شبکه شامل ۵۰ لوله، ۳۰ گره، ۲۰ حلقه و یک مخزن می‌باشد. شبکه تماماً حلقوی بوده و از نظر تحلیل هیدرولیکی به مراتب مشکل‌تر از شبکه‌های شاخه‌ای است. طول لوله‌های عمودی و افقی به ترتیب برابر ۲۰۰۰ و ۱۰۰۰ متر، ارتفاع مخزن ۵۲ متر، محدوده قطر لوله‌ها بین ۳۰۰ تا ۶۰۰ میلی متر می‌باشد. ضریب زبری کلیه لوله‌ها برابر ۰/۲۶ میلی متر و میزان تقاضای آب در گره‌ها مقدار متوسط ۲۰ لیتر بر ثانیه فرض شده است [۱۹].

۳- مواد و روش‌ها


۳-۱- تعریف شبکه عصبی مصنوعی

شبکه‌های عصبی به عنوان یک ابزار کاربردی برای تخمین و پیش‌بینی پاسخ در سیستم‌های غیرخطی و چند متغیره مورد استفاده قرار می‌گیرند. یک شبکه عصبی مجموعه‌ای از نورون‌هاست که با قرار گرفتن در لایه‌های مختلف، معماری خاصی را بر مبنای ارتباطات بین نورون‌ها در لایه‌های مختلف تشکیل می‌دهند. نورون می‌تواند یک تابع ریاضی غیرخطی باشد، در نتیجه یک شبکه عصبی که از اجتماع این نورون‌ها تشکیل می‌شود، نیز می‌تواند یک سامانه کاملاً پیچیده و غیرخطی باشد [۲۰]. یک شبکه عصبی مصنوعی، از سه بخش لایه ورودی^۱، خروجی^۲ و لایه‌های پنهان^۳ تشکیل می‌شود. هر لایه شامل گروهی از سلول‌های عصبی (نورون) است که با نورون‌های لایه‌های دیگر در ارتباط هستند. از منظر ریاضی عملکرد شبکه‌های عصبی با استفاده از توابع محرک^۴، ضرایب وزنی^۵ و بایاس‌ها^۶ شبیه‌سازی می‌شود [۲۱].

در این پژوهش جهت دستیابی به موقعیت نشت، از شبکه عصبی پیش‌خور استفاده شده است. شبکه عصبی پیش‌خور یک شبکه عصبی مصنوعی است که در آن اتصال میان واحدهای تشکیل دهنده آن یک چرخه را تشکیل نمی‌دهند. شبکه عصبی پیش‌خور اولین و ساده‌ترین نوع شبکه عصبی مصنوعی می‌باشد. در این شبکه اطلاعات تنها از یک مسیر حرکت می‌کند که جهت آن رو به جلو می‌باشد. در واقع اطلاعات با شروع از گره (نورون)‌های ورودی و گذر از لایه‌های پنهان (در صورت وجود) به سمت گره‌های خروجی می‌روند. شکل ۲ معماری یک شبکه عصبی پیش‌خور با یک لایه ورودی، یک لایه میانی و یک لایه خروجی را نشان می‌دهد. لایه میانی ساختار اصلی شبکه عصبی را تعیین می‌کند و اثر مهمی بر روند آموزش شبکه عصبی و عملکرد کلی شبکه دارد. تعداد نورون‌های لایه میانی می‌تواند با حداقل کردن تابع خطای از پیش تعیین شده روی داده‌های آموزش به وسیله آزمون و خطا تعیین شود. رابطه (۱) خروجی حاصل از شبکه عصبی مصنوعی با یک ورودی، یک لایه میانی و یک خروجی را نشان می‌دهد [۲۲]:

$$y_s = \varphi\left(\sum_{r=1}^m w_{rs} x_{rs} - \theta_s\right) \quad (1)$$

- 1 Input layer
- 2 Output layer
- 3 Hidden layer
- 4 Activation Function
- 5 Connection weight
- 6 Biases



شکل ۱. شبکه مورد مطالعه [۱۹]


Fig.1. Case-study network

اوقات مقدار قابل قبول با همگرایی خوبی را نشان می‌دهد اما لزوماً نیاز مسئله تامین نمی‌شود. در واقع شاخص RMSE متوسط رفتار شبکه را نشان می‌دهد، در حالی که ممکن است در این بین خطاهای بالا برای تعدادی نقاط وجود داشته باشد. اگر نیاز باشد که تمامی داده‌ها حتی بدترین داده (با خطای بالا) نیز رفتار خوبی از خود نشان دهد، استفاده از شاخص RMSE دیگر گزینه مناسبی نخواهد بود. لذا برای حل این مشکل، در مطالعه حاضر شاخص خطای نسبی نشت (RLE) تعریف شده است که در بخش‌های بعدی ارائه خواهد شد.

۳-۲- نحوه آموزش شبکه عصبی پیشنهادی

در شبکه عصبی پیش‌خور پیشنهادی، ابتدا شبکه با استفاده از داده‌های متغیرهای ورودی و خروجی از پیش تعیین شده (آموزش با ناظر^۲) آموزش می‌بیند. به منظور تولید داده‌های آموزش شبکه عصبی مصنوعی از مدل هیدرولیکی EPANET2.0 برای تولید تعداد زیادی سناریوی تصادفی استفاده شده است. برای این منظور، ابتدا دو نشت فرضی با آرایش‌های مختلف و مدنظر بر روی گره‌های شبکه (متغیرهای خروجی داده‌های آموزش شبکه عصبی) قرار داده شده و سپس دبی لوله‌ها به عنوان متغیرهای ورودی داده‌های آموزش شبکه عصبی محاسبه می‌شود. سپس با داشتن متغیرهای ورودی (دبی لوله‌ها) و متغیرهای خروجی (موقعیت و مقدار نشت‌های فرضی) شبکه عصبی آموزش می‌بیند. توضیحات فوق را می‌توان در دو مرحله در شکل ۳ نشان داد. همانطور که ملاحظه می‌شود، متغیرهای Q_{P1} ، Q_{P2} ، ...، Q_{P50} مقدار دبی در لوله‌های ۱، ۲، ۳، ...، ۵۰ و X_{11} ، X_{12} ، X_{21} ، X_{22} ، ... موقعیت و مقدار دو نشت را نشان می‌دهند.

کلیه برنامه‌های شبکه عصبی در محیط برنامه نویسی MATLAB کدگذاری شده است. به منظور ایجاد داده‌های آموزش، نرم‌افزار EPANET2.0 می‌بایست به تعداد دفعات زیاد اجرا شود. بنابراین برای کاهش زمان ایجاد داده‌های آموزش، کدهایی به منظور ایجاد ارتباط بین EPANET2.0 و MATLAB برای شبیه‌سازی دبی لوله‌ها نوشته شده است. بدین ترتیب که بر اساس کتابچه راهنمای کاربر EPANET2.0^۳ [۲۳] کدهایی در متلب بر اساس ساختار شبکه مورد مطالعه ایجاد گردید تا بر اساس آن با وارد کردن نشت‌های فرضی به برنامه تهیه شده بتوان مقدار دبی لوله‌ها را با سرعت بسیار بالا به دست آورد. با توجه به آنکه نرم‌افزار EPANET2.0 می‌تواند یک فایل متنی را دریافت



شکل ۲. معماری شبکه عصبی مصنوعی [۲۲]

Fig. 2. The structure of the artificial neural network


در رابطه قبل Y_s خروجی شبکه عصبی، X_{rs} ورودی r ام به ازای نورون s ، m تعداد ورودی‌ها، W_{rs} ضریب وزنی ورودی r ام، θ_s بایاس نورون و ϕ تابع محرک به صورت تابع تانژانت هیپربولیک یا تابع سیگموئید است. پس از تعیین معماری ANN، پارامترهایی، شامل ضرایب وزنی W_{rs} و بایاس نورون‌ها θ_s به منظور به حداقل رساندن اختلاف بین متغیر خروجی شبکه و متغیرهای خروجی واقعی در داده‌های آموزش، می‌بایست تنظیم شوند. این اختلاف بر اساس شاخص RMSE^۱ به شکل زیر قابل محاسبه است:

$$\min RMSE = \sqrt{\frac{1}{M} \sum_{r=1}^M \|y_s - o_r\|^2} \quad (2)$$

که M تعداد نمونه‌ها، (X_r, Y_r) جفت ورودی-خروجی برای نمونه r ام و O_r خروجی واقعی برای ورودی X_r می‌باشند. بهینه‌سازی پارامترهای ANN معمولاً در یک فضای جستجو با ابعاد بالا انجام می‌شود. به طور معمول، مقادیر وزن‌ها و بایاس‌ها به محدوده (۰ و ۱) یا (-۱ و ۱) محدود می‌شود. در شبکه‌های عصبی، RMSE یکی از شاخص‌های تعیین عملکرد شبکه برای تعیین وزن‌ها و بایاس‌ها می‌باشد. شاخص RMSE گاهی

2 Supervised Training
3 EPANET2.0 User Manual

1 Root Mean Squared Error



شکل ۳. مراحل آماده‌سازی داده‌های آموزش

Fig. 3. Steps of preparing the training data

داده‌های ورودی برای ایجاد داده‌های خروجی مرتبط می‌باشد. فاکتورهای مهم در شبکه عصبی پیشنهادی، تعداد نورون‌های لایه‌های پنهان و الگوریتم آموزش می‌باشد. در این تحقیق الگوریتم آموزش‌ترین لیم^۲ برای بروزرسانی وزن‌ها و بایاس‌ها براساس بهینه‌یابی لونیگ-مارکوارت^۳ استفاده شده است. الگوریتم لونیگ-مارکوارت روشی است برای یافتن کمینه یک تابع غیرخطی چند متغیره که به عنوان یک روش استاندارد برای حل مسئله کمینه مربعات برای توابع خطی معرفی می‌شود. ترین لیم، در اغلب موارد سریع‌ترین الگوریتم پس انتشار^۴ در جعبه ابزار شبکه عصبی در متلب می‌باشد و معمولاً برای اولین انتخاب الگوریتم با ناظر پیشنهاد می‌شود، اما نسبت به

و سپس خروجی مورد نظر را در فایل متنی دیگر قرار دهد، برنامه‌ای در MATLAB نوشته شد که بر اساس سناریوی نشت، فایل متنی ورودی را تهیه می‌کند و سپس EPANET2.0 را با آن فایل متنی فراخوانی می‌نماید. پس از اتمام محاسبات EPANET2.0 و نوشته شدن فایل خروجی بر روی هارد دیسک، برنامه نوشته شده در MATLAB، آن فایل را به صورت خودکار باز کرده و داده‌های مورد نظر (دبی لوله‌ها) را از فایل می‌خواند. با استفاده از یک حلقه این چرخه به دفعات مورد نیاز اجرا می‌گردد. به منظور ایجاد شبکه عصبی پیش‌خور پیشنهادی، از یک شبکه عصبی پرسپترون چند لایه (MLP)^۱ در جعبه ابزار متلب به منظور برازش تابع استفاده شده است. برازش تابع، یک فرآیند آموزش شبکه عصبی روی

2 Trainlm
3 Levenberg-Marquardt
4 Back Propagation (BP)

1 Multi-Layer perceptron

داده شده است.

در جدول ۱، سطرها تعداد گره‌های موجود در شبکه و ستون‌ها موقعیت گره‌های نشت‌دار را نشان می‌دهد. با وارد کردن ماتریس نشت (۳۰×۴۳۵) به نرم‌افزار EPANET2.0، مقادیر دبی لوله‌ها در هر حالت محاسبه شده و یک ماتریس (۵۰×۴۳۵) به دست می‌آید. در این ماتریس، سطرها معرف دبی لوله‌ها و ستون‌ها معرف موقعیت گره‌های نشت هستند. ماتریس (۵۰×۴۳۵) که "ماتریس دبی لوله‌ها" نامیده می‌شود به عنوان متغیر ورودی آموزش به شبکه عصبی وارد می‌شود. با داشتن متغیر ورودی (ماتریس دبی لوله‌ها) و متغیر خروجی (ماتریس نشت) می‌توان به آموزش شبکه عصبی پرداخت. تمامی توضیحات فوق در روندنمای شکل ۴ نشان داده شده است. خروجی روندنما، شبکه عصبی آموزش دیده می‌باشد. حال می‌توان با وارد کردن دبی لوله‌ها به شبکه عصبی آموزش دیده به تعیین موقعیت نشت در شبکه پرداخت.

۳-۳-۲ سناریو دوم: تعیین موقعیت دو نشت همزمان با مقدار نابرابر در بخش ۳-۳-۱ مقدار نشت بیشینه برابر ۱٪ کل دبی ورودی به شبکه یعنی مقداری برابر ۶ لیتر بر ثانیه فرض شد. این نشت بیشینه به صورت برابر و یکنواخت بین هر یک از دو گره انتخابی در ماتریس نشت تقسیم شد، به طوری که به هر یک از دو گره، ۵۰٪ نشت بیشینه یعنی ۳ لیتر بر ثانیه اختصاص داده شد. هدف اصلی در این بخش، توزیع غیریکنواخت نشت بین هر دو گره انتخابی می‌باشد. نحوه انجام این توزیع غیریکنواخت در جدول ۲ نشان داده شده است. همانطور که در جدول ۲ دیده می‌شود، ۴ گروه نشت در سطر اول تعریف شده است. برای گروه نشت اول در حالت ۱، به گره اول ۶۰٪ نشت بیشینه یعنی ۳/۶ لیتر بر ثانیه و به گره دوم ۴۰٪ نشت بیشینه یعنی ۲/۴ لیتر بر ثانیه اختصاص داده شده است. این توزیع منجر به تولید یک ماتریس نشت (۳۰×۴۳۵) می‌شود. از آن جایی که نشت قرار داده شده در گره‌ها برابر نیست، موقعیت قرارگیری دو نشت ۳/۶ لیتر بر ثانیه و ۲/۴ لیتر بر ثانیه مهم می‌باشد. بنابراین در حالت ۲، به گره اول ۴۰٪ نشت بیشینه یعنی ۲/۴ لیتر بر ثانیه و به گره دوم ۶۰٪ نشت بیشینه یعنی ۳/۶ لیتر بر ثانیه اختصاص داده می‌شود و در نهایت ماتریس نشت دیگری (۳۰×۴۳۵) ایجاد می‌گردد. با قرار دادن این دو ماتریس کنار یکدیگر ماتریس نشت (۳۰×۸۷۰) تحت عنوان "ماتریس نشت ۴۰-۶۰" معرفی می‌گردد که به ازای دبی نشت ۴۰٪ و ۶۰٪ نشت بیشینه ایجاد شده است. این روند برای سایر گروه‌های نشت تکرار می‌شود. در نهایت برای هر یک از ۸ حالت یک

سایر الگوریتم‌ها حافظه بیشتری نیاز دارد [۲۱]. همچنین در شبکه عصبی پیشنهادی نیز توابع محرک تانژانت سیگموئید^۱ و خطی^۲ به عنوان توابع محرک به ترتیب در لایه پنهان و لایه خروجی استفاده شده است. تابع تانژانت سیگموئید تابعی در محدوده (۱ و -۱) می‌باشد.

۳-۳-۳ نحوه توزیع و تعیین مقدار نشت بین هر یک از دو گره انتخابی

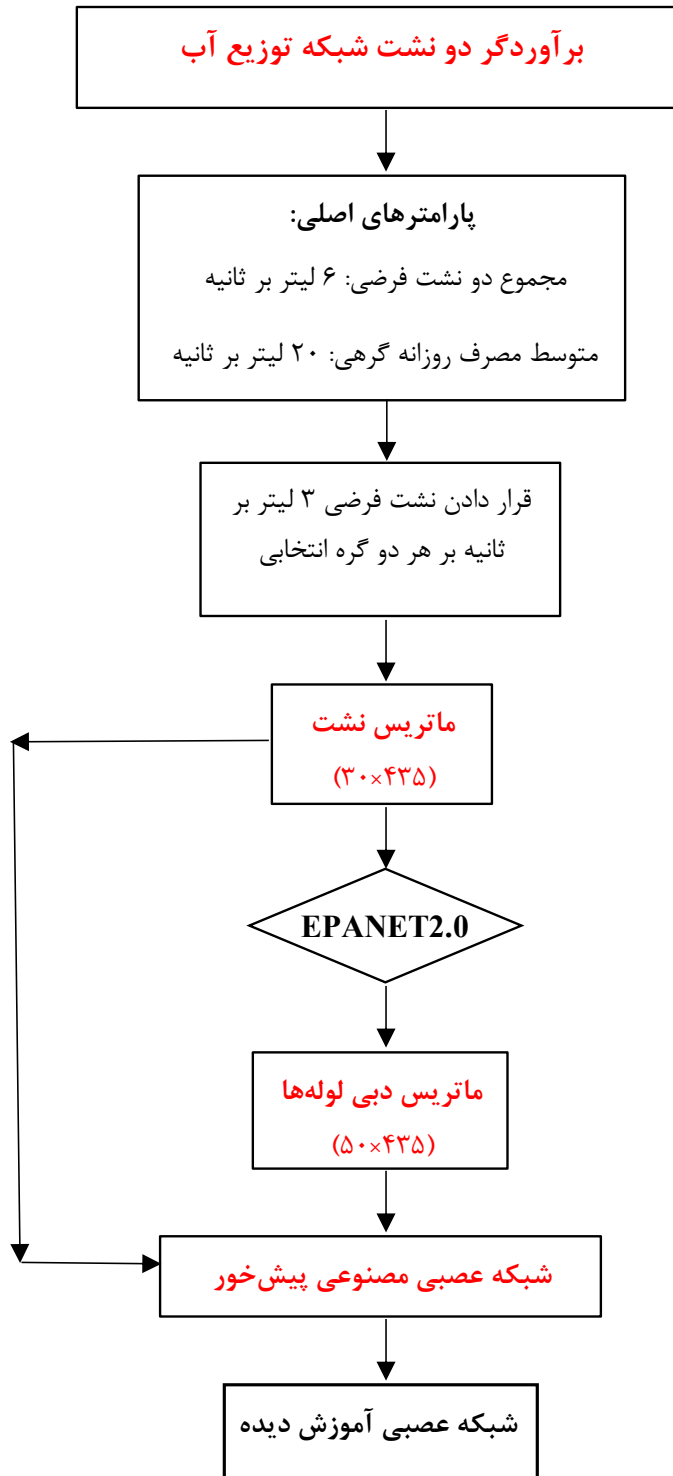
۳-۳-۱ سناریو اول: تعیین موقعیت دو نشت همزمان با مقدار برابر

در مطالعه حاضر، موقعیت نشت در شبکه‌های توزیع آب با استفاده از شبکه عصبی مصنوعی تعیین شده است که به محاسبه دو نشت در شبکه می‌پردازد. جهت محاسبه دبی لوله‌ها از نرم‌افزار EPANET2.0 استفاده شده است. به منظور تحلیل شبکه (محاسبه دبی لوله‌ها)، با اعمال دو نشت فرضی به گره‌های شبکه، نرم‌افزار EPANET2.0 دبی لوله‌ها که متغیرهای ورودی آموزش شبکه عصبی می‌باشد را محاسبه می‌کند. بنابراین با داشتن متغیرهای ورودی (دبی لوله‌ها) و متغیرهای خروجی (موقعیت و مقدار نشت‌های فرضی) شبکه عصبی آموزش می‌بیند. پس از آموزش شبکه با اعمال دبی لوله‌ها به شبکه عصبی آموزش دیده می‌توان، موقعیت نشت را تعیین نمود.

از آنجایی که در آموزش شبکه عصبی، تعداد داده‌های آموزش تاثیر زیادی بر عملکرد مدل دارد، در این پژوهش برای ایجاد داده‌های آموزش کافی، نشت‌های فرضی بر اساس درصدی از کل دبی ورودی به شبکه در نظر گرفته شده است. با توجه به اینکه میزان تقاضای آب در گره‌ها مقدار متوسطی برابر ۲۰ لیتر بر ثانیه فرض شده است، کل دبی ورودی به شبکه برابر ۶۰۰ لیتر بر ثانیه می‌باشد. بنابراین به کل شبکه مقدار نشت بیشینه‌ای برابر با ۱٪ کل دبی ورودی به شبکه یعنی مقدار ۶ لیتر بر ثانیه اختصاص داده شده است. با توجه به در نظر گرفتن دو نشت فرضی، می‌بایست مقدار ۶ لیتر بر ثانیه را در حالت‌های مختلف بین هر دو گره به نحوی تقسیم نمود و بر اساس آن شبکه را آموزش داد. به همین دلیل آرایش‌های مختلفی از قرار دادن دو نشت فرضی یکسان با مجموع برابر ۶ لیتر بر ثانیه به وجود خواهد آمد. اولین سناریو، اختصاص دادن نشتی برابر ۵۰٪ نشت بیشینه به هر یک از دو گره انتخابی می‌باشد. یعنی در سناریوی اول نشتی به میزان ۳ لیتر بر ثانیه به هر دو گره انتخابی شبکه اضافه خواهد شد. ماتریس حاصله که ورودی EPANET2.0 برای تعیین دبی لوله‌ها می‌باشد، ماتریسی ۳۰×۴۳۵ خواهد بود که "ماتریس نشت" نامیده شده و در جدول ۱ نشان

1 Tansig

2 Purelin



شکل ۴. روندنمای پیشنهادی محاسبه نشت

Fig. 4. The proposed leakage detection flowchart

جدول ۲. توزیع نشت نسبت به نشت بیشینه در هر دو گره انتخابی

Table 2. Leakage distribution relative to the maximum leakage in both selected nodes

چهارم		سوم		دوم		اول		گروه نشت
حالت		حالت		حالت		حالت		حالت
۸	۷	۶	۵	۴	۳	۲	۱	گره اول %
۱۰	۹۰	۲۰	۸۰	۳۰	۷۰	۴۰	۶۰	گره دوم %
۱۰-۹۰		۲۰-۸۰		۳۰-۷۰		۴۰-۶۰		ماتریس نشت (۳۰×۸۷۰)

تعیین موقعیت نشت هر گره استفاده شده است. این شاخص (RLE) را به صورت رابطه (۳) می‌توان معرفی نمود:

$$RLE_i(\%) = \frac{CLD_{ANN_i} - HLD_i}{HLD_i} \times 100 \quad (3)$$

که در رابطه فوق RLE خطای نسبی نشت، CLD_{ANN} مجموع مصرف گرهی و دبی نشت محاسبه شده توسط شبکه عصبی، HLD مجموع مصرف گرهی و دبی نشت فرضی و i تعداد گره‌ها ($i=1,2,3,\dots,30$) هستند. بنابراین با استفاده از رابطه (۳) مقدار RLE در کلیه گره‌ها را در هر سناریو به صورت جداگانه می‌توان محاسبه نمود. این امر منجر به ایجاد ماتریس‌هایی تحت عنوان "ماتریس‌های خطای نسبی نشت" می‌گردد. در سناریو اول ماتریس خطای نسبی نشت به ابعاد (۳۰×۴۳۵) و در سناریو دوم برای هر یک از گروه‌های نشت ذکر شده در جدول ۲، یک ماتریس خطای نسبی نشت به ابعاد (۳۰×۸۷۰) و در نهایت در سناریو دوم ۴ ماتریس خطای نسبی نشت به ابعاد (۳۰×۸۷۰) به دست می‌آید. خروجی هر ستون ماتریس‌های فوق، خطای نسبی محاسبه نشت در ۳۰ گره به ازای یکی از حالات ماتریس نشت (در سناریو ۱ بر اساس جدول ۱ و در سناریو ۲ بر اساس جدول ۲) را نشان می‌دهد. به عنوان مثال ستون اول ماتریس خطای نسبی نشت در سناریو ۱ برای حالتی است که نشت‌های فرضی ۳ لیتر بر ثانیه در گره‌های ۱ و ۲ قرار داشته باشند. بررسی نتایج نشان می‌دهد که اولین مقدار بیشینه و دومین مقدار بیشینه هر یک از ستون‌های ماتریس‌های فوق

ماتریس نشت (۳۰×۴۳۵) و در نهایت ۴ ماتریس نشت (۳۰×۸۷۰) برای هر یک از گروه‌های نشت به دست می‌آید که در جدول ۲ نشان داده شده است. ماتریس‌های نشت به دست آمده، ورودی EPANET2.0 برای تعیین دبی لوله‌ها می‌باشند.

با استفاده از جدول ۲، با وارد کردن هر یک از ۴ ماتریس نشت (۳۰×۸۷۰) به نرم افزار EPANET2.0 که در محیط MATLAB نوشته شده است، مقادیر دبی لوله‌ها محاسبه شده و ماتریسی تحت عنوان "ماتریس دبی لوله (۵۰×۸۷۰)" برای هر یک از ۴ گروه نشت به دست می‌آید. در ماتریس‌های دبی لوله‌ها، سطرها معرف دبی لوله‌ها و ستون‌ها معرف اینکه دو نشت نابرابر بر روی کدام دو گره قرار گرفته‌اند، می‌باشد. ماتریس دبی لوله‌ها به عنوان متغیر ورودی آموزش به شبکه عصبی داده می‌شود. با داشتن متغیر ورودی (ماتریس دبی لوله‌ها) و متغیر خروجی (ماتریس نشت) می‌توان همانند بخش ۳-۱-۳ به آموزش شبکه عصبی پرداخت.

۴- نتایج و بحث

به منظور تشخیص موقعیت دو نشت همزمان با استفاده از شبکه‌های عصبی پیش‌خور، دو سناریو در نظر گرفته شد. در سناریو اول دو نشت همزمان با مقدار برابر و در سناریو دوم دو نشت همزمان با مقدار نابرابر با آرایش‌های مختلف در هر دو گره انتخابی در شبکه قرار داده می‌شود. در نهایت با توجه به سناریوهای تعریف شده، شبکه‌های عصبی آموزش دیده برای تعیین موقعیت نشت به کار گرفته می‌شود.

در پژوهش حاضر، به منظور بررسی رفتار شبکه، علاوه بر شاخص RMSE، از شاخصی تحت عنوان خطای نسبی نشت (RLE) به منظور

برای صحت‌سنجی، به منظور جلوگیری از بیش‌برازش^۴ در شبکه عصبی آموزش دیده می‌باشد. همچنین شبکه عصبی آموزش دیده، توسط ۱۵٪ داده‌ها که به منظور داده‌های تست کنار گذاشته شده بود، مورد ارزیابی قرار می‌گیرد.

قابلیت تعمیم در تمامی مدل‌های داده مینا مانند شبکه عصبی بسیار حائز اهمیت است. از آنجایی که در نظر گرفتن ۱۵٪ داده‌ها برای تست بسیار کم است، در این پژوهش برای ارزیابی کامل‌تر و اطمینان بیشتر به قابلیت تعمیم شبکه عصبی آموزش دیده، داده‌های جدیدی تحت عنوان داده‌های تست (علاوه بر ۱۵٪ ابتدایی که خود شبکه عصبی کنار گذاشته است) تولید شد و شبکه عصبی آموزش دیده، با این داده‌ها نیز مورد آزمون قرار گرفت. برای این منظور درصدهای بیشتر و کمتر از ۳ لیتر بر ثانیه به عنوان دبی نشت در هر یک از دو گره انتخابی برای داده‌های تست در نظر گرفته شده است. بنابراین نشت‌های انتخابی داده‌های تست برابر ۲/۵ و ۳/۵ لیتر بر ثانیه فرض می‌شود. همانطور که در شکل ۵ مشاهده می‌شود، مقدار MaxRLE برای داده‌های آموزش از ۴۰ نورون به بعد به مقدار قابل ملاحظه‌ای کاهش یافته است. بنابراین در این سناریو می‌توان تعداد نورون بهینه را ۴۰ نورون معرفی نمود. همانطور که در شکل ۵ ملاحظه می‌شود، مقدار MaxRLE برای داده‌های تست نیز از ۴۰ نورون به بعد کاهش یافته است، که این مسئله نیز صحت انتخاب نورون بهینه ۴۰ را تایید می‌نماید. همچنین به منظور وضوح بیشتر برای مقادیر نورون‌های بیشتر از ۴۰، بزرگ‌نمایی صورت گرفته است. مقادیر خطای نسبی نشت بیشینه اول (RLEmax1) و بیشینه دوم (RLEmax2) به ازای دو نشت فرضی ۳ لیتر بر ثانیه با در نظر گرفتن تعداد نورون بهینه ۴۰ در لایه میانی برای تمامی حالات در شکل ۶ نشان داده شده است. محور y نشان دهنده مقادیر RLEmax برای مقدار بیشینه اول و دوم و محور x حالت‌های مختلف ماتریس نشت (۴۳۵ حالت) به ازای دو نشت برابر ۳ لیتر بر ثانیه را نشان می‌دهد. همانطور که در شکل ۶ ملاحظه می‌شود، مقدار RLEmax در تمام حالات برای هر دو بیشینه کمتر از ۰/۲٪ است که نسبتاً مقدار قابل قبولی را نشان می‌دهد [۳]. بنابراین شبکه عصبی آموزش دیده با ورودی برابر با مقدار دبی کل لوله‌ها، موقعیت نشت را در شبکه توزیع آب با دقت قابل قبولی پیش‌بینی می‌کند. به منظور استفاده از شبکه عصبی آموزش دیده، دبی لوله‌ها می‌بایست توسط دبی‌سنج اندازه‌گیری شود. با به کار بردن دبی لوله‌ها در شبکه آموزش دیده، دو گرهی که مقادیر بیشینه اول و بیشینه دوم RLE را دارا باشند، نشان دهنده

(ماتریس‌های خطای نسبی نشت)، نشان دهنده موقعیت دو نشت می‌باشند. بنابراین بعد از آموزش شبکه عصبی و وارد کردن دبی لوله‌ها به منظور تعیین موقعیت نشت، دو گرهی که مقدار بیشینه اول و بیشینه دوم RLE را دارا باشند، نشان دهنده موقعیت دو نشت می‌باشند.

با توجه به توضیحات فوق، خطای نسبی نشت گره‌ای که بیشینه اول را به خود اختصاص داده را به صورت رابطه (۴) می‌توان معرفی نمود:

$$RLEmax1_j(\%) = \max(RLE_i)_j \quad (4)$$

که RLEmax1 خطای نسبی نشت گره با مقدار بیشینه اول برحسب درصد و j ستون‌های ماتریس RLE (سناریو ۱، ۲، ۳، ...، ۴۳۵) و j=۱، ۲، ۳، ...، ۸۷۰ (سناریو ۲، ۳، ...، ۸۷۰) می‌باشند.

همچنین به منظور محاسبه خطای نسبی نشت گره با مقدار بیشینه دوم، ابتدا مقادیر بیشینه اول هر ستون از ماتریس RLE را برابر صفر قرار داده و سپس رابطه (۵) به صورت زیر به دست خواهد آمد:


$$RLEmax2_j(\%) = \max(RLE_i)_j \quad \& \quad RLEmax1_j(\%) = 0 \quad (5)$$

که RLEmax2 خطای نسبی نشت گره با مقدار بیشینه دوم بر حسب درصد می‌باشد.

۴-۱- بررسی نتایج سناریو ۱

از جمله پارامترهای مهم برای آموزش شبکه عصبی مصنوعی تعداد نورون‌های لایه میانی است. با وارد کردن ماتریس داده‌های ورودی و خروجی به شبکه عصبی به منظور آموزش، می‌توان بر اساس بیشینه مقدار RLE در کل شبکه (MaxRLE) به ازای تعداد نورون‌های مختلف، به تعیین تعداد نورون بهینه لایه میانی پرداخت. نتیجه این محاسبات در شکل ۵ نشان داده شده است. در فرآیند آموزش شبکه عصبی، کل داده‌های آموزش شبکه عصبی، به سه بخش داده‌های آموزش^۱ (در اینجا ۷۰٪)، صحت‌سنجی^۲ (۱۵٪) و تست^۳ (۱۵٪) تقسیم می‌شود. استفاده از ۱۵٪ داده‌ها

-
- 1 Training Data
 - 2 Validation Data
 - 3 Test Data



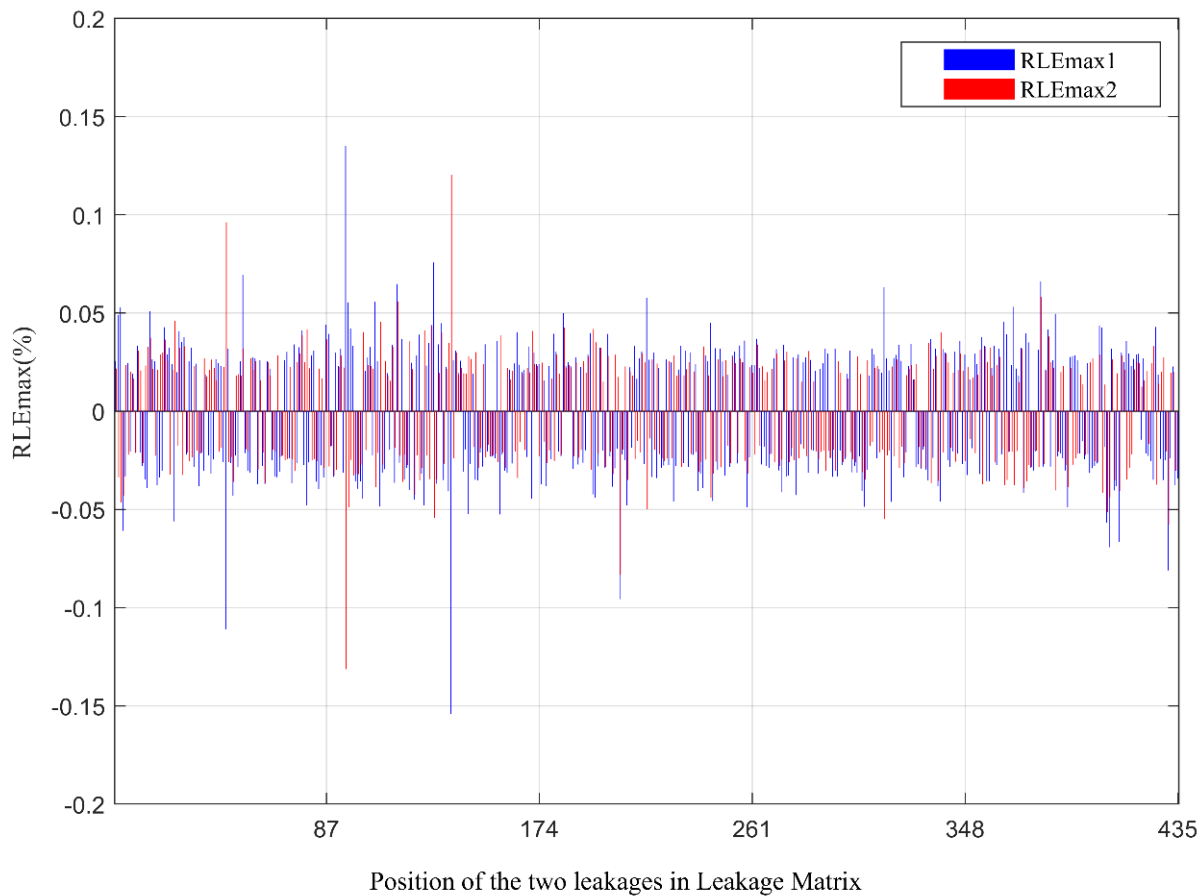
شکل ۵. تعداد نورون‌های لایه میانی برای دو نشت همزمان با مقدار برابر (آبی: داده‌های آموزش، قهوه‌ای تیره و روشن: داده‌های تست برای نشت‌های ۳/۵ و ۲/۵ لیتر بر ثانیه. سبز، قرمز و صورتی: داده‌های آموزش و تست نشت‌های ۳/۵ و ۲/۵ لیتر بر ثانیه برای نورون‌های بیشتر از ۴۰)

Fig. 5. The number of neurons at the hidden layer for two simultaneous leakages with equal values (Blue: the training data, Dark and light brown: the test data for leakages 3.5 and 2.5 L/s, respectively. Green, Red, and Pink: the training and test data for leakages 3.5L/s and 2.5 L/s for the neurons more than 40 respectively)

جدول ۳. تعداد و درصد لوله‌ها برای شبکه مورد مطالعه

Table 3. The percentage and associated number of pipes for the case-study network

۱۰۰	۹۰	۸۰	۷۰	۶۰	۵۰	۴۰	۳۰	۲۰	۱۰	۸	۶	۴	۲	درصد لوله‌ها
۵۰	۴۵	۴۰	۳۵	۳۰	۲۵	۲۰	۱۵	۱۰	۵	۴	۳	۲	۱	تعداد لوله‌ها



شکل ۶. مقدار RLEmax محاسبه شده در برابر موقعیت دو نشت با مقدار برابر در ماتریس نشت (آبی: بیشینه اول، قرمز: بیشینه دوم)

Fig. 6. The calculated RLEmax value versus the location of two equal simultaneous leakages values in the leakage matrix (Blue: first maximum, Red: second maximum)

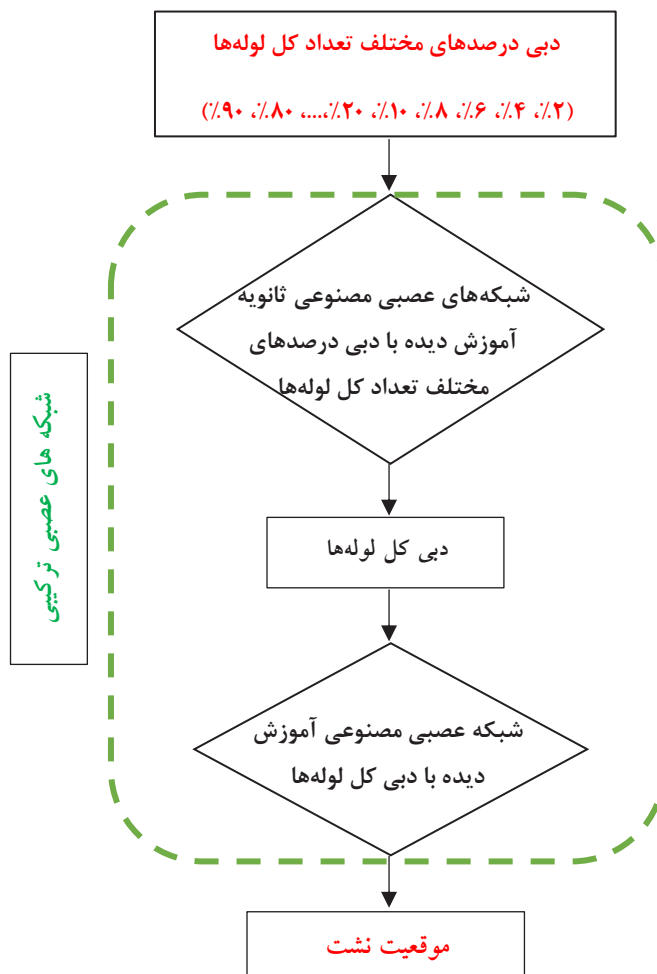
با تعداد مختلف یعنی ۲، ۴، ۶، ۸، ۱۰، ۲۰، ۳۰، ۴۰، ۵۰، ۶۰، ۷۰، ۸۰ و ۹۰ درصد از کل لوله‌ها ارائه شده است. جدول ۳ درصد و تعداد لوله‌ها در شبکه مورد مطالعه را نشان می‌دهد.

تحلیل حساسیت بر اساس شبکه‌های عصبی ثانویه و در نهایت شبکه‌های عصبی ترکیبی انجام می‌شود. شبکه‌های عصبی ثانویه بر اساس دبی درصدهای مختلف تعداد کل لوله‌ها به عنوان ورودی و دبی کل لوله‌ها به عنوان خروجی آموزش می‌بینند. در هر حالت، لوله‌ها به صورت تصادفی انتخاب می‌شوند. از آنجایی که بررسی تمامی حالت‌ها (مثلاً انتخاب ۴۵ لوله از ۵۰ لوله) بسیار زمان‌بر می‌باشد، تعداد لوله‌ها به صورت تصادفی در تکرارهای محدود انتخاب شده و برای هر حالت، درصدی از حالات ممکن مورد بررسی قرار گرفته است.

موقعیت دو نشت می‌باشند. همچنین مقدار RLE میزان تغییرات مقدار نشت محاسبه شده توسط شبکه عصبی با نشت‌های فرضی اولیه را نشان می‌دهد که بر اساس شکل ۶ در محدوده قابل قبولی می‌باشد.

۴-۱-۱- تحلیل حساسیت سناریو اول

نتایج ارائه شده در بخش قبل به نحوی بود که آموزش شبکه عصبی با در نظر گرفتن دو نشت همزمان با مقدار برابر در گره‌ها و دبی کلیه لوله‌ها انجام می‌شد. در واقع شبکه عصبی با در نظر گرفتن دبی ۱۰۰٪ لوله‌ها (۵۰ لوله) آموزش داده شد. یکی از اهداف شبکه‌های توزیع آب تعیین موقعیت نشت با حداقل تعداد لوله‌ها می‌باشد. برای این منظور در این بخش، تحلیل حساسیت با استفاده از شبکه‌های عصبی مصنوعی ترکیبی با دبی تعداد لوله‌های کمتر از تعداد کل لوله‌ها انجام شده است. نتایج برای دبی لوله‌های

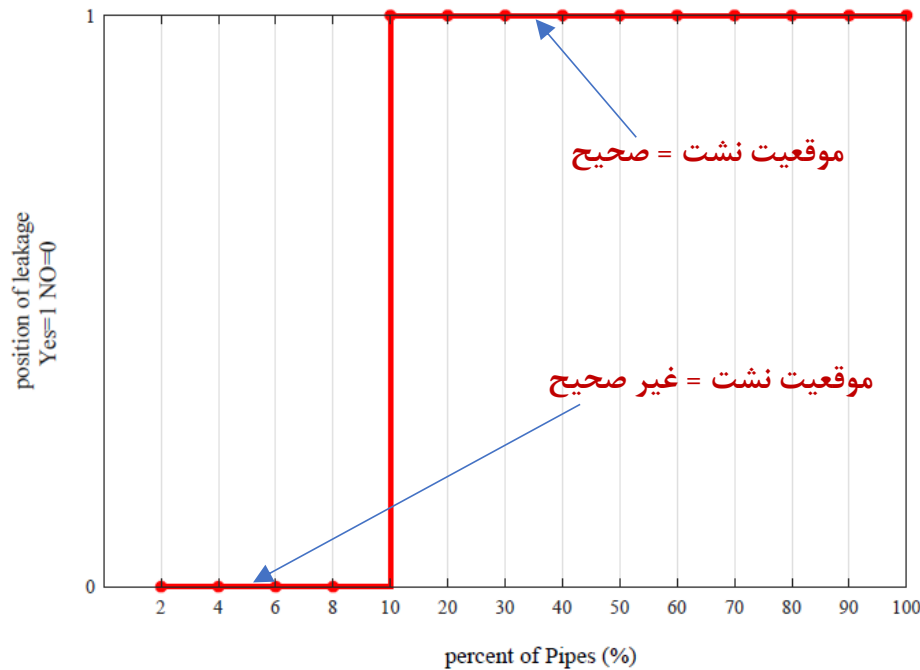


شکل ۷. روند نمای تحلیل حساسیت برای شبکه‌های عصبی ترکیبی

Fig. 7. Flowchart of sensitivity analysis for the Hybrid ANNs

عصبی ترکیبی به دست می‌آید. این روند برای درصدهای مختلف تعداد لوله‌ها به همین ترتیب تکرار می‌شود. شبکه‌های ثانویه نیز شبکه‌های عصبی پیش‌خور می‌باشند. تعداد نورون بهینه در هر یک از شبکه‌های عصبی ثانویه بر اساس درصدهای مختلف تعداد لوله‌ها متغیر می‌باشد. پس از ایجاد شبکه‌های عصبی ترکیبی، باید بررسی شود که کدام شبکه عصبی ترکیبی موقعیت نشت را به درستی می‌تواند تعیین نماید. این بررسی در شکل ۸ نشان داده شده است. به عبارت دیگر، تعیین حداقل تعداد لوله‌ها برای تعیین موقعیت نشت ضروری می‌باشد. همانطور که در شکل ۸ مشاهده می‌شود، دو مقدار برای تعیین موقعیت نشت در شبکه‌های عصبی ترکیبی نشان داده شده است. مقدار "۱" نشان دهنده درصد تعداد لوله‌هایی است که به ازای آن‌ها، شبکه‌های عصبی ترکیبی موقعیت نشت را صحیح تشخیص

خروجی‌های شبکه‌های عصبی ثانویه ورودی شبکه عصبی آموزش دیده با دبی کل لوله‌ها می‌باشند. این روند منجر به ایجاد شبکه‌های عصبی ترکیبی (همانند تابع‌های ترکیبی ریاضی) می‌شود. شبکه‌های عصبی ترکیبی دبی درصدهای مختلف تعداد لوله‌ها را دریافت می‌کنند و در نهایت موقعیت نشت را نشان می‌دهند. شکل ۷ روند نمای نحوه ایجاد شبکه‌های عصبی ترکیبی را نشان می‌دهد. این شبکه‌های عصبی ترکیبی برای درصدهای مختلف تعداد لوله‌ها به صورت جداگانه ایجاد می‌شوند. به عنوان مثال، برای شبکه عصبی ۲۰٪ تعداد کل لوله‌ها، شبکه ثانویه با دبی ۱۰ لوله به عنوان ورودی و دبی ۵۰ لوله به عنوان خروجی آموزش می‌بیند. خروجی شبکه عصبی ثانویه به عنوان ورودی برای شبکه عصبی آموزش دیده با دبی کل لوله‌ها استفاده می‌شود. در نهایت موقعیت نشت به عنوان خروجی شبکه



شکل ۸. تعیین موقعیت نشت با دبی درصدی مختلف تعداد لوله‌ها

Fig. 8. Detection of the leakage location by the flow rates of different percentages of pipes number

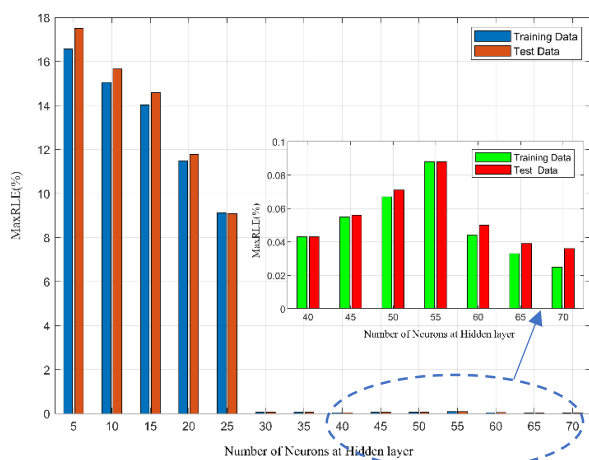
درصدی توزیع نشت را ۳۵٪ و ۶۵٪ برای داده‌های تست در نظر گرفته و ماتریس نشت ۳۵-۶۵ تولید می‌شود. سایر ماتریس‌های نشت به همین ترتیب به دست آورده می‌شود. ماتریس نشت ۳۰-۷۰ به ۲۵-۷۵، ماتریس نشت ۲۰-۸۰ به ۱۵-۸۵ و ماتریس نشت ۱۰-۹۰ به ۵-۹۵ برای داده‌های تست تبدیل می‌شود. پس از تولید داده‌های تست، حداکثر RLE در کل شبکه (MaxRLE) به ازای تعداد نورهن‌های مختلف برای داده‌های تست محاسبه شده که نتیجه این محاسبات در شکل ۹ نشان داده شده است. همانطور که ملاحظه می‌شود، در داده‌های تست نیز نمودار از ۴۰ نورهن به بعد کاهش چشمگیری داشته است که این مسئله نیز تعداد ۴۰ نورهن را به عنوان تعداد نورهن بهینه تایید می‌نماید. همچنین برای وضوح بیشتر مقادیر نورهن‌های بیشتر از ۴۰، در شکل ۹ بزرگ‌نمایی صورت گرفته است.

بر اساس شکل ۹ و توضیحات فوق، شبکه عصبی با ۴۰ نورهن برای پیش‌بینی محل نشت به ازای دو نشت فرضی همزمان با مقدار نابرابر در شبکه پیشنهاد می‌شود. مقادیر خطای نسبی نشت بیشینه اول (RLEmax1) و بیشینه دوم (RLEmax2) برای هر یک از گروه‌های نشت با قرار دادن $j=1,2,3,\dots,870$ در شکل ۱۰ نشان داده شده است. در هر گروه نشت، محور y نشان دهنده مقادیر RLEmax برای بیشینه اول و دوم


داده‌اند. مقدار "۰" نیز مربوط به حالاتی است که شبکه‌های عصبی ترکیبی قادر به تشخیص صحیح موقعیت نشت نیستند. بنابراین برای تشخیص موقعیت صحیح نشت به وسیله شبکه‌های عصبی ترکیبی پیشنهاد شده، دبی حداقل ۱۰٪ لوله‌ها (۵ لوله) نیاز است.

۴-۲- بررسی نتایج سناریو ۲


در این سناریو نیز می‌توان بر اساس حداکثر RLE در کل شبکه (MaxRLE) به ازای تعداد نورهن‌های مختلف به تعیین تعداد نورهن بهینه لایه میانی پرداخت. نتیجه این محاسبات در شکل ۹ قابل مشاهده می‌باشد. همان‌طور که دیده می‌شود، MaxRLE برای داده‌های آموزش برای هر یک از ۴ ماتریس نشت معرفی شده، از ۴۰ نورهن به بعد به مقدار قابل ملاحظه‌ای کاهش یافته است. بنابراین در این سناریو نیز تعداد نورهن بهینه ۴۰ قابل قبول می‌باشد. همچنین به منظور بررسی بیشتر عملکرد شبکه عصبی آموزش دیده، همانند بخش ۴-۱ می‌بایست شبکه عصبی برای داده‌هایی غیر از داده‌های آموزش یعنی داده‌های تست (علاوه بر ۱۵٪ ابتدایی که خود شبکه عصبی کنار گذاشته است) مورد ارزیابی قرار گیرد. برای این منظور برای تولید داده‌های تست، در هر گروه نشت، ۵٪ به درصدی توزیع نشت اضافه و کم می‌شود. مثلاً برای ماتریس نشت ۴۰-۶۰



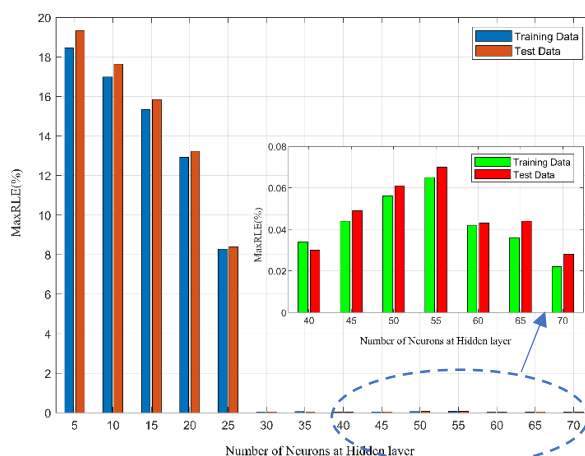
(ب)



(الف)



(د)




(ج)

شکل ۹. تعداد نورون‌های لایه میانی برای دو نشت با مقدار نابرابر (الف) ماتریس نشت ۴۰-۶۰، (ب) ماتریس نشت ۳۰-۷۰، (ج) ماتریس نشت ۲۰-۸۰، (د) ماتریس نشت ۱۰-۹۰ (آبی: داده‌های آموزش، قهوه‌ای: داده‌های تست، سبز و قرمز: به ترتیب داده‌های آموزش و تست برای نورون‌های بیشتر از ۴۰)


Fig.9. The number of neurons at the hidden layer for two simultaneous leakages with unequal values a) 40-60 leakage matrix, b) 30-70 leakage matrix, c) 20-80 leakage matrix, d) 10-90 leakage matrix (Blue: the training data, Brown: the test data. Green and Red: the training and test data for the neurons larger than 40)

شبکه توزیع آب با دقت قابل قبولی پیش‌بینی می‌کند. به منظور استفاده از شبکه عصبی آموزش دیده، دبی لوله‌ها می‌بایست توسط دبی سنج اندازه‌گیری شود. با استفاده از دبی لوله‌ها در شبکه آموزش دیده، دو گرهی که مقادیر بیشینه اول و بیشینه دوم RLE را دارا باشند، نشان دهنده موقعیت دو نشت می‌باشند.

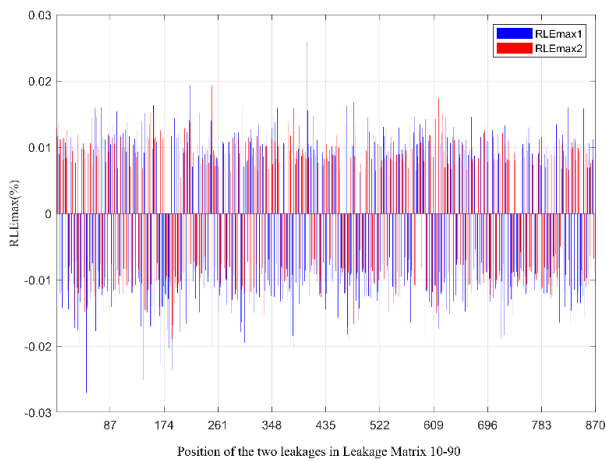
و محور X حالت‌های مختلف ماتریس نشت (۸۷۰ حالت) را نشان می‌دهد. همانطور که در شکل ۱۰ ملاحظه می‌شود، برای هر ۴ گروه نشت موجود در جدول ۲ نشان داده شده است. مقدار RLEmax در هر ۴ گروه نشت برای هر دو بیشینه کمتر از ۰/۰۵٪ می‌باشد که نسبتاً مقدار قابل قبولی را نشان می‌دهد [۳]. این مسئله نشان می‌دهد که، شبکه عصبی آموزش دیده با ورودی برابر با مقدار دبی کل لوله‌ها، موقعیت نشت را در




(ب)



(ف)



(د)



(ج)

شکل ۱۰. مقدار RLEmax محاسبه شده در برابر موقعیت دو نشت با مقدار نابرابر در ۴ گروه نشت. الف) ماتریس نشت ۴۰-۶۰ (ب) ماتریس نشت ۳۰-۷۰ (ج) ماتریس نشت ۲۰-۸۰ (د) ماتریس نشت ۱۰-۹۰ (آبی: بیشینه اول، قرمز: بیشینه دوم)

Fig. 10. The calculated RLEmax value versus the location of the two simultaneous leakages with unequal values at four leakage matrices. a) 40-60 leakage matrix, b) 30-70 leakage matrix, c) 20-80 leakage matrix, d) 10-90 leakage matrix (Blue: first maximum, Red: second maximum)

نانویه همانند بخش ۴-۱-۱ به صورت تصادفی انتخاب شده است. تحلیل حساسیت انجام شده در بخش ۴-۱-۱ برای حالتی بود که دو نشت همزمان و برابر ۳ لیتر بر ثانیه بر روی گره‌ها قرار می‌گرفت. با توجه به اینکه در سناریو دوم، ۴ ماتریس نشت تعریف شده است، تحلیل حساسیت همانند شکل ۷ برای درصدهای مختلف لوله برای هر ماتریس نشت می‌بایست به صورت جداگانه انجام شود. نتایج نشان می‌دهد که برای ماتریس‌های نشت ۴۰-۶۰، ۷۰-۳۰ و ۸۰-۲۰ شبکه‌های عصبی ترکیبی پیشنهادی با دبی حداقل ۱۰٪ لوله‌ها (۵ لوله) قادر به شناسایی محل دو نشت می‌باشند. اما در مورد ماتریس

۴-۲-۱- تحلیل حساسیت سناریو دوم

همانند بخش ۴-۱-۱، در این بخش نیز با توجه به این که شبکه عصبی پیشنهادی با دبی ۱۰۰٪ لوله‌ها آموزش دیده است، لازم است تحلیل حساسیت با دبی تعداد لوله‌های کمتر نیز انجام شود. نتایج برای دبی درصدهای مختلف لوله‌ها نظیر ۲، ۴، ۶، ۸، ۱۰، ۲۰، ۳۰، ۴۰، ۵۰، ۶۰، ۷۰، ۸۰، ۹۰ درصد از کل لوله‌ها ارائه شده است. بنابراین شبکه‌های عصبی ترکیبی (همانند شکل ۷) برای تعیین موقعیت نشت با دبی درصدهای مختلف تعداد لوله‌ها باید ایجاد شود. در این بخش نیز تعداد لوله‌های لازم برای شبکه‌های عصبی

- [2] M. Zhao, C. Zhang, H. Liu, G. Fu, Y. Wang, Optimal sensor placement for pipe burst detection in water distribution systems using cost-benefit analysis, *Journal of Hydroinformatics*, 22(3) (2020) 606–618.
- [3] H.R. Asgari, M. F. Maghrebi, Application of nodal pressure measurements in leak detection, *Flow Measurement and Instrumentation*, 50 (2016) 128–134.
- [4] Z. Xue, L. Tao, J. Fuchun, E. Riehle, H. Xiang, N. Bowen, R.P. Singh, Application of acoustic intelligent leak detection in an urban water supply pipe network, *Journal of Water Supply: Research and Technology-AQUA*, 69(5) (2020) 512–520.
- [5] S. Sarkamaryan, A. Haghighi, A. Adib, Leakage detection and calibration of pipes networks by the inverse transient analysis modified by Gaussian functions for leakage simulation, *Journal of Water Supply: Research and Technology-AQUA*, 67(4) (2018) 404–413.
- [6] Y. Tenne, C-K. Goh, Computational intelligence in expensive optimization problems (Adaptation, Learning and Optimization), Springer Science & Business Media 2(2010).
- [7] E. Tsanov, I. Ribarova, G. Dimova, P. Ninov, M. Kossida, C. Makropoulos, Water Stress Mitigation in the Vit River Basin Based on WEAP and MatLab Simulation, *Civil Engineering Journal*, 6(11) (2020) 2058-2071.
- [8] Y. Yan, L. Wang, T. Wang, X. Wang, Y. Hu, Q. Duan, Application of soft computing techniques to multiphase flow measurement: A review, *Flow Measurement and Instrumentation*, 60 (2018) 30-43.
- [9] D. Jang, H. Park, G. Choi, Estimation of leakage ratio using principal component analysis and artificial neural network in water distribution systems, *Sustainability*, 10(3) (2018) 750.
- [10] G. M. Lima, B. M. Brentan, D. Manzi, Jr. E. Luvizotto, Metamodel for nodal pressure estimation at near real-time water distribution systems using artificial neural networks, *Journal of Hydroinformatics*, 20(2) (2018) 486–496.
- [11] D. Wachla, P. Przystalka, W. Moczulski, A method of leakage location in water distribution networks using

نشت ۱۰-۹۰ شبکه‌های عصبی ترکیبی پیشنهادی با دبی حداقل ۵ لوله فقط می‌تواند موقعیت نشت بزرگ‌تر را تعیین نمایند. این مسئله به دلیل اختلاف مقداری دو نشت فرضی بر روی گره‌های شبکه می‌تواند باشد.

۵- نتیجه‌گیری

در پژوهش حاضر، روشی جدید برای تعیین موقعیت دو نشت همزمان در شبکه‌های توزیع آب با استفاده از شبکه‌های عصبی پیش‌خور ارائه شده است. شبکه‌های عصبی پیشنهادی بر روی شبکه پولاکیس و برای دو سناریو با حداقل ۴۰ نورون در لایه میانی مورد بررسی قرار گرفته‌اند. در سناریو اول دو نشت همزمان با مقدار برابر و در سناریو دوم دو نشت همزمان با مقدار نابرابر در هر یک از دو گره شبکه قرار داده شد. شاخص خطای نسبی نشت (RLE) به منظور بررسی دقت شبکه‌های عصبی پیشنهادی ارائه شد. دقت شبکه‌های عصبی آموزش دیده با دبی کل لوله‌ها برای سناریو اول کمتر از ۰/۲٪ و برای سناریو دوم کمتر از ۰/۰۵٪ به دست آمد. به منظور کاربردی بودن روش پیشنهادی در شبکه‌های توزیع آب واقعی، تحلیل حساسیت توسط شبکه‌های عصبی ترکیبی برای درصد لوله‌های کمتر از کل لوله‌ها انجام گرفت. نتایج شبکه‌های عصبی ترکیبی پیشنهادی نشان می‌دهد که در سناریو اول با داشتن ۱۰٪ دبی لوله‌ها موقعیت هر دو نشت همزمان با موفقیت تعیین می‌گردد. در سناریو دوم که مقادیر دو نشت برابر نیست، مادامی که اختلاف نسبت مقدار دو نشت کمتر از ۰/۸۰٪ نشت بیشینه است (تا نسبت‌های ۱۰ و ۹۰ درصد نشت) با داشتن دبی لوله‌ها موقعیت هر دو نشت قابل تعیین است. اما برای اختلاف‌های بیشتر، فقط محل نشت بزرگ‌تر را می‌توان تعیین نمود. با توجه به اینکه در سناریو دوم پیچیدگی مسئله افزایش یافته است، اما به دلیل کارایی بالای شبکه‌های عصبی پیشنهادی، همچنان موقعیت نشت‌های بزرگ‌تر با موفقیت قابل تشخیص می‌باشد. توضیح اینکه با کاربرد این روش در یک شبکه واقعی، ابتدا بزرگ‌ترین نشت شبکه و یا دو نشت بزرگ شبکه شناسایی می‌شود. بعد از شناسایی و برطرف کردن نشت اصلی و یا دو نشت بزرگ شبکه، با استفاده مجدد روش می‌توان یک یا دو نشت بزرگ بعدی شبکه را شناسایی نمود و به همین طریق فرآیند را ادامه داد تا نشت‌های مهم شبکه شناسایی و برطرف شود.

منابع

- [1] A. Gupta, K. D. Kulat, A Selective literature review on leak management techniques for water distribution system, *Water Resources Management*, 32 (2018) 3247–3269.

- Journal of Civil Engineering 52(5) (2018) 1-10 (In Persian).
- [18] H. Fallahi, M. Jalili Ghazizadeh, B. Aminnejad, J. Yazdi, Leakage detection in water distribution networks using hybrid feedforward artificial neural networks, *Journal of Water Supply: Research and Technology-Aqua*, 70(5) (2021) 637-653.
- [19] Z. Poulakis, D. Valougeorgis, C. Papadimitriou, Leakage detection in water pipe networks using a Bayesian probabilistic framework, *Probabilistic Engineering Mechanics*, 18(4) (2003) 315-327.
- [20] S. Sarkamaryan, S. M. Ashrafi, A. Haghighi, H.M. V.Samani, Using Artificial Neural Network surrogate models to reduce the calculation cost of leak detection in water distribution networks, *Amirkabir Journal of Civil Engineering*, 52(10) (2019) 1-13 (In Persian).
- [21] M. T. Hagan, H.B. Demuth, M. Beale, *Neural network design*, 2nd edition, (2014).
- [22] X.H. Zhou, M.X. Zhang, Z.G. Xu, C.Y. Cai, Y.J. Huang, Y.J. Zheng, Shallow and deep neural network training by water wave optimization., *Swarm and Evolutionary Computation*, 50 (2019) 100561.
- [23] L. Rossman, *EPANET 2 Users Manual*, Technical Report EPA/600/R-00/057, Water Supply and Water Resources Division, National Risk Management Research Laboratory, US, Environmental Protection Agency, Cincinnati, OH, USA., (2000).
- artificial neuro-fuzzy system, *IFAC-PapersOnLine*, 48(21) (2015) 1216-1223.
- [12] M. Attari, M. F.Maghrebi, A new method of leak detection using artificial neural networks, *Journal of water and wastewater*, 29(1) (2018) 14-26 (In Persian).
- [13] J. Kang, Y.J. Park, J. Lee, S.H. Wang, D.S. Eom, Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems, *IEEE Transactions on Industrial Electronics*, 65(5) (2018) 4279-4289.
- [14] M. Quinones-Grueiro, J. M. Bernal-de Lázaro, C. Verde, A. Prieto-Moreno, O. Llanes-Santiago, Comparison of classifiers for leak location in water distribution networks, *IFAC-PapersOnLine*, 51(24) (2018) 407-413.
- [15] M.R. Shekofteh, M.R. Jalili Ghazizadeh, J. Yazdi, Theoretical Idea for Identification of Leakage Areas in Virtual District Metered Areas of Water Distribution Networks Using the Artificial Neural Network, *Iran-Water Resources Research*, 16(3) (2020) 47-62 (In Persian).
- [16] D. Ma, J. Wang, Q. Sun, X. Hu, A novel broad learning system-based leakage detection and universal localization method for pipeline networks, *IEEE Access*, 7 (2019) 42343-42353.
- [17] R. Moasheri, M.R. Jalili Ghazizadeh, Identifying position and amount of two simultaneous leaks in water supply networks by a two-step algorithm, *Amirkabir*

چگونه به این مقاله ارجاع دهیم

H. Fallahi, M. R. Jalili Ghazizadeh, B. Aminnejad, J. Yazdi, *Detection of two simultaneous leakages in water distribution network using hybrid feedforward artificial neural networks*, *Amirkabir J. Civil Eng.*, 54(5) (2022) 1965-1982.

DOI: 10.22060/ceej.2021.20017.7316

