



Theoretical Idea for Identification of Leakage Areas in Virtual District Metered Areas of Water Distribution Networks Using the Artificial Neural Network

M.R. Shekofteh¹, M.R. Jalili Ghazizadeh^{2*},
and J. Yazdi³

Abstract

One of the advantages of designing water distribution networks (WDNs) as district metered areas (DMAs) is that the leakage in each area can be identified by controlling the input and output flow, which of course requires that the areas are separated and flowmeters are installed between the interconnecting pipes of each area. Since most existing WDNs have been expanded traditionally and not as DMA, turning them into DMAs would require huge costs and might not be even practical in some networks. In this paper, the theoretical idea of virtual DMA is presented to identify the leakage in each areas. The innovation of this paper is the ability to transform networks into DMAs using a combination of the graph theory and artificial neural network to find leaks without using a flowmeter. The proposed method, in addition to reducing the costs for the flowmeters, increases the speed of detection of leakage areas. Furthermore, there is no need to specify the number of leakage nodes before the leak detection begins. The proposed method has been applied to the Balerna WDN in Spain with 443 nodes and 454 pipes for two, three and four simultaneous leaks. The results of this paper showed that the proposed theory is able to detect leakage in each area, and this method can determine the number of optimal virtual DMAs for each network. In all examples, the leakage area was correctly predicted and the maximum leakage error was about 6.5%.

Keywords: Leakage, Graph Theory, Virtual District Metered Areas, Water Distribution Network, Artificial Neural Network, Hydraulic Simulation.

Received: May 8, 2019
Accepted: June 20, 2020

تئوری شناسایی محدوده نشت در نواحی مجزای مجازی شبکه‌های توزیع آب با استفاده از شبکه‌ی عصبی مصنوعی

محمدرضا شکفته^۱، محمدرضا جلیلی قاضی زاده^{۲*}
و جعفر یزدی^۳

چکیده

یکی از مزیت‌های طراحی شبکه‌های توزیع آب به صورت نواحی مجزا، شناسایی نشت موجود در هر ناحیه با کنترل جریان ورودی و خروجی می‌باشد که البته این کار نیازمند مجزاسازی و نصب دبی‌سنج بین لوله‌های رابط هر ناحیه است. با توجه به اینکه اکثر شبکه‌های موجود به صورت سنتی و غیرمجزا گسترش یافته‌اند، تبدیل آنها به نواحی مجزا نیازمند هزینه‌های زیاد و حتی گاهی غیراجرایی است. در مقاله حاضر برای شناسایی نشت بین نواحی، ایده‌ی نظری نواحی مجزای مجازی ارائه شده است. نوآوری این مقاله، امکان تبدیل شبکه‌ها به نواحی مجزا با استفاده از ترکیب تئوری گراف و شبکه عصبی مصنوعی برای یافتن نشت بدون استفاده از دبی‌سنج می‌باشد. روش پیشنهادی علاوه بر کاهش هزینه‌های لازم برای دبی‌سنجی، باعث افزایش سرعت در شناسایی محدوده‌های نشت می‌شود. علاوه بر این، نیازی نیست تعداد گره‌های نشت، قبل از شروع عملیات نشت‌یابی مشخص باشد. روش پیشنهادی برای شبکه‌ی توزیع آب شهر Balerna در اسپانیا با ۴۴۳ گره و ۴۵۴ لوله برای دو، سه و چهار نشت همزمان مورد بررسی قرار گرفت. نتایج مقاله حاضر نشان می‌دهد که نظریه‌ی پیشنهادی در روش ارائه شده، قادر به شناسایی نشت در هر ناحیه می‌باشد و با این روش می‌توان تعداد نواحی مجزای بهینه برای هر شبکه را تعیین کرد. در تمامی مثال‌ها، ناحیه‌ی نشت به درستی پیش‌بینی شد و حداکثر خطای تعیین مقدار نشت حدود ۶/۵ درصد بود.

کلمات کلیدی: نشت، تئوری گراف، نواحی مجزای مجازی، شبکه توزیع آب، شبکه عصبی مصنوعی، شبیه‌سازی هیدرولیکی.

تاریخ دریافت مقاله: ۹۸/۲/۱۸

تاریخ پذیرش مقاله: ۹۹/۳/۳۱

1- M.Sc. Graduate of Civil Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran.

2- Associate Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran. Email: m_jalili@sbu.ac.ir.

3- Assistant Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran.

*- Corresponding author

۱- دانش‌آموخته کارشناسی ارشد مهندسی عمران، آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران.

۲- دانشیار، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران.

۳- استادیار، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران.

*- نویسنده مسئول
بحث و مناظره (Discussion) در مورد این مقاله تا پایان زمستان ۱۳۹۹ امکانپذیر است.

۱- مقدمه

توسط نشت در اطراف لوله‌ها و شناسایی وجود آب در نشت می‌پردازد (Fanner et al., 2008). همانطور که اشاره شد، روش‌های فیزیکی نیازمند تجهیزات مختلف جهت یافتن نشت در شبکه می‌باشد. از طرفی استفاده از این تجهیزات مختلف برای شبکه‌های شهری علاوه بر هزینه‌های زیاد و غیراقتصادی بودن، به زمان و نیروی انسانی زیادی نیازمند می‌باشد. به همین دلیل در سال‌های گذشته محققین سعی کرده‌اند با استفاده از روش‌های مدل‌سازی شبکه و داده‌های میدانی از آن (به صورت دبی یا فشارسنجی) مکان نشت موجود در شبکه‌های آب را مشخص کنند. برای مثال می‌توان به پیش‌بینی نشت به روش‌های فراکاوشی همانند سیستم عصبی فازی مصنوعی^۳ (Wachla et al., 2015)، استفاده از سیستم طبقه‌بندی بیزین^۴ (Soldevila et al., 2017)، استفاده از الگوریتم‌هایی مانند الگوریتم ژنتیک برای تعیین محل نشت (Wu and Sage, 2008) و استفاده از تئوری گراف (Candelieri et al., 2014)، اشاره کرد. Qi et al. (2014) یک مدل بهینه‌سازی بر اساس ترکیبی از الگوریتم ژنتیک و سیستم طبقه‌بندی بیزین ارائه کردند، که از مقادیر محاسبه شده و مقادیر میدانی نقاط دارای فشارسنج برای تعیین نشت استفاده کرده‌اند (Darsana and Attari and Faghfour, 2018; Varija, 2018; Qi et al., 2014). Maghrebi (2018) به کمک شبکه‌ی عصبی مصنوعی و ترکیب فشارسنج و دبی‌سنج، به شناسایی گره‌های نشت پرداخته‌اند.

برای شناسایی بهتر نشت در شبکه‌های توزیع آب، می‌توان با ایجاد یک سیستم کنترل هدررفت ثابت، به صورت تقسیم‌بندی شبکه به تعدادی مناطق مجزا تحت عنوان DMA^۵، به گونه‌ای عمل نمود که بتوان هدررفت هر منطقه را به صورت کمی بیان کرده و فعالیت‌های تشخیص نشت را همواره به قسمتی از شبکه با بیشترین مقدار نشت معطوف نمود. DMA، یک ناحیه‌ی مجزای شبکه توزیع آب می‌باشد که معمولاً با بستن شیرها یا انفعال کامل لوله‌ها ایجاد می‌شود و در آن مقادیر آب ورودی به ناحیه و خروجی از آن اندازه‌گیری می‌شود. در ادامه‌ی مقاله حاضر، DMA به اختصار ناحیه مجزا نامیده می‌شود. در نواحی مجزا، شبکه‌ی توزیع به نواحی اندازه‌گیری شده‌ای تقسیم می‌شود و توسط تعداد محدودی از لوله‌های اصلی (که روی آنها دبی‌سنج نصب می‌شود) تغذیه می‌گردد. متناسب با وضعیت شبکه، هر ناحیه‌ی مجزا ممکن است توسط یک یا چند ورودی تأمین شود و یا ممکن است از بخش‌های مجاور تغذیه شود (Farley and Trow, 2003). بدین ترتیب می‌توان به طور منظم سطح نشت در هر ناحیه را به صورت کمی بیان نموده و عملیات پرهزینه‌ی نشت‌یابی را تنها معطوف به مناطق پرحادثه نمود. با نصب دبی‌سنج در لوله‌های ورودی و خروجی هر ناحیه و اندازه‌گیری جریان شبانه^۶، یعنی زمانی که مصرف در طول شبانه روز در کمترین حالت ممکن است، می‌توان در هر ناحیه

آب به عنوان یکی از مهم‌ترین نیازهای بشر، در طول تاریخ نقش مهمی را در شکل‌گیری تمدن‌های مختلف ایفا کرده و همواره از دغدغه‌های اصلی جوامع بشری به شمار آمده است. کمبود منابع آب آشامیدنی همراه با رشد سریع تقاضا به علت توسعه جمعیت و هزینه‌های بالای تصفیه و انتقال آب، باعث به وجود آمدن مشکلات زیاد اجتماعی، اقتصادی و حتی سیاسی در بسیاری از کشورها گردیده است. بحران آب زودتر از اغلب کشورهای جهان دامن‌گیر کشورهای کم‌آب از جمله ایران شده است. کم‌آبی چند ساله اخیر اگرچه در نگاه بسیاری امری گذرا تلقی می‌شود، ولی در حقیقت می‌توان آن را پیش‌زمینه‌ی بحران گسترده آب دانست که در صورت عدم برنامه‌ریزی منسجم، بدون شک خسارات جبران‌ناپذیری را بر پیکره‌ی آسیب‌پذیر اقتصاد کشور وارد خواهد ساخت. متوسط بارش سالیانه کشور ایران در سال آبی ۹۵-۹۶ (از اول مهر تا ۱۳ شهریور)، با ثبت ۲۳۰ میلی‌متر و سال آبی ۹۶-۹۷ با ثبت ۱۶۹/۵ میلی‌متر به ثبت رسیده است (Report, 2018) که نشان می‌دهد، ایران در زمره مناطقی از جهان است که از موهبت نزولات جوی به اندازه کافی بهره‌مند نیست.

نشت در شبکه‌های آبرسانی علاوه بر اتلاف آب، باعث کاهش کیفیت آب به دلیل افزایش احتمال ورود آلودگی از طریق نشت، افت فشار و اتلاف انرژی و افزایش هزینه‌های مربوط به تصفیه، انتقال و توزیع می‌شود. این تأثیرات در کشورهای در حال توسعه به دلیل کیفیت پایین طراحی و همچنین عمر زیاد شبکه‌های توزیع، بیشتر مشاهده می‌شود. هدررفت آب تقریباً در تمام شبکه‌های آب رخ می‌دهد و مقدار آن بستگی به وضعیت لوله‌ها، اتصالات شبکه و همچنین نوع طراحی شبکه دارد. به طور مثال در کشور هلند، مقدار هدررفت بین ۳ تا ۷ درصد و در بعضی از کشورهای در حال توسعه این مقدار به بیش از ۵۰ درصد می‌رسد (Puust et al., 2010).

در طول چند دهه‌ی گذشته، روش‌ها و ابزارهای بسیاری برای ارزیابی، محاسبه و نظارت بر نشت در شبکه‌های توزیع آب توسعه یافته است. روش‌های تشخیص نشت آکوستیک بر اساس این واقعیت است که آب تحت فشار هنگامی که از یک روزنه به عنوان نشت از لوله‌ها خارج می‌شود، صدایی قابل شنیدن را در یک فرکانس کم ایجاد می‌کند که می‌توان با استفاده از دستگاه‌های مخصوص مکان این صداها را شناسایی کرد. روش دیگر برای شناسایی نشت، تزریق گاز ردیاب^۱ در لوله‌های شبکه می‌باشد. این گازها معمولاً هلیوم یا هیدروژن می‌باشد. یکی دیگر از روش‌های غیرآکوستیک، استفاده از رادارهای نفوذ به زمین^۲ (GPR) می‌باشد. این روش به شناسایی حفره‌های ایجاد شده

مشکلات اجرای نواحی مجزا، استفاده از دبی سنج بین نواحی برای کنترل جریان ورودی و خروجی به هر ناحیه است که علاوه بر مشکلات اجرایی، هزینه‌های زیادی نیز دارد. به همین دلیل در مقاله‌ی حاضر با کمک تئوری‌های مبحث گراف و ارتباط آنها با نرم‌افزار شبیه‌سازی هیدرولیکی EPANET (Rossman, 2000) و همچنین به کمک شبکه‌ی عصبی مصنوعی^{۱۴}، مقدار نشت در هر ناحیه‌ی مجزا بدون استفاده از دبی سنج بین نواحی، شناسایی می‌شود. نوآوری که در مقاله حاضر مورد بررسی قرار گرفته است، حذف کامل دبی سنج بین نواحی مجزا می‌باشد. به عبارتی در شبکه‌ی واقعی هیچ تغییر فیزیکی ایجاد نمی‌شود و نواحی مجزای پیشنهادی، مجازی می‌باشند و فقط از فشارسنج‌های موجود در شبکه و با استفاده از شبکه‌ی عصبی، نشت موجود بین هر نواحی شناسایی می‌شود. روش پیشنهادی می‌تواند تأثیر زیادی در کاهش هزینه‌های عملیات نشت‌یابی داشته باشد.

۲- روش تحقیق

در این مقاله روشی پیشنهاد شده است که برای شبکه‌های موجود بدون اینکه تغییری در شبکه ایجاد شود و با استفاده از تئوری گراف، شبیه‌سازی هیدرولیکی و شبکه‌ی عصبی مصنوعی، نواحی دارای نشت در شبکه شناسایی شود.

۲-۱- تئوری گراف

با توجه به اینکه شبکه‌های توزیع آب مجموعه‌ای از گره‌ها و لوله‌ها می‌باشد، می‌توان آنها را به عنوان یک گراف در نظر گرفت و سپس با استفاده از الگوریتم‌های تئوری گراف، شبکه را مورد تحلیل قرار داد. گراف یک ساختاری مجزا از یال‌ها^{۱۵} و رأس‌ها^{۱۶} می‌باشد که رأس‌ها از طریق یال‌ها به هم متصل می‌شوند. هر گراف به صورت زوج مرتبی مانند $G(V, E)$ نشان داده می‌شود. V زیرمجموعه‌ای از رأس‌ها و E زیرمجموعه‌ای از یال‌ها به صورت اعضای دو عضوی V می‌باشد (به این معنی که هر یال با دو رأس در ارتباط است). در شبیه‌سازی شبکه آب با استفاده از تئوری گراف می‌توان گره‌های مصرف و مخازن شبکه را رأس‌های گراف (V) و لوله‌ها، پمپ‌ها و شیرهای شبکه را همچون یال‌های گراف (E) در نظر گرفت. برای خوشه‌بندی شبکه توزیع آب در این مقاله از الگوریتم Girvan-Newman^{۱۷} در تئوری گراف استفاده شده است. در این الگوریتم ابتدا به هر یک از یال‌ها یک امتیاز اختصاص داده می‌شود. سپس در جهت تشکیل فرم کلی نواحی، یال‌های دارای امتیاز بیشتر به تدریج از شبکه حذف می‌شوند. روند کلی الگوریتم پیشنهادی به صورت زیر می‌باشد:

گام اول- محاسبه‌ی امتیاز کل یال‌های شبکه
گام دوم- یافتن یالی که بیشترین امتیاز را دارد و حذف آن از شبکه

مقدار نشت را شناسایی و برای ردیابی نشت، هر ناحیه را اولویت‌بندی کرد. بدین منظور حداقل جریان شبانه در یک دوره مشخص (معمولاً یک هفته) اندازه‌گیری و از بین مقادیر جریان شبانه‌های اندازه‌گیری شده، کمترین مقدار انتخاب که حداقل جریان شبانه^{۱۸} نامیده می‌شود. با استفاده از حداقل جریان شبانه معمولاً برای تخمین مقدار نشت در شبکه استفاده می‌شود (Hamilton and McKenzie, 2014).

با توجه به اینکه اکثر شبکه‌های آب با افزایش جمعیت شهرها به صورت غیراصولی گسترش پیدا کرده‌اند، تبدیل آنها به نواحی مجزا کاری پرهزینه و حساس می‌باشد. به همین دلیل در سال‌های اخیر، سعی شده است با استفاده از روش‌های نرم‌افزاری و به خصوص استفاده از تئوری گراف^{۱۹}، بتوان به صورت بهینه شبکه‌های موجود را به نواحی مجزا تبدیل کرد.

تئوری گراف در سال‌های اخیر برای تعیین نواحی مجزا یا زون‌های مدیریت فشار^{۲۰} در شبکه‌های توزیع آب به کار گرفته شده است. از جمله (Tzatchkov et al. (2008 یک الگوریتم مشتق شده از نظریه گراف برای شناسایی بخش‌های عرضه مستقل یک شبکه بر اساس روش اولین صادره از آخرین وارده^{۲۱} پیشنهاد کرده‌اند. یک روش خوشه‌بندی طیفی توسط Herrera et al. (2010) برای تعیین نواحی مجزای شبکه توزیع آب با استفاده از ماتریس‌های متمایز^{۲۲} و اطلاعات گرافیکی (لوله‌ها، گره‌های تقاضا و محدودیت‌های آب) پیشنهاد شده است. Di Nardo and Di Natale (2011) یک روش فراکوشی برای طراحی نواحی به وسیله تئوری گراف معرفی کرده‌اند. روش آنها بر اساس روش پشتیبانی طراحی (DSM)^{۲۳} و استفاده از شاخص‌های انرژی و تحقیق در مورد مسیرهای حداقل انرژی که از هر مخزن به هر گره در یک شبکه آب محاسبه می‌شود، امکان تعریف نواحی بهینه را فراهم می‌کند. روش دیگری با استفاده از روش پشتیبانی طراحی توسط Gomes et al. (2012.a) معرفی شده است. روش آنها بر اساس مفاهیم تئوری گراف و الگوریتم تیرید شبیه‌سازی شده^{۲۴} می‌باشد که اجازه شناسایی محل نقاط ورودی و شیرهای مرزی و همچنین تعیین لوله‌های تقویتی مورد نیاز برای برآوردن نیازهای سرعت و فشار در آنها را می‌دهد. Shekofteh and Jalili Ghazizadeh (2019) در نظر گرفتن یک شبکه‌ی آب به عنوان گراف، با استفاده از الگوریتم Girvan-Newman موجود در تئوری گراف ابتدا شبکه‌ی را به صورت بهینه به تعداد نواحی مورد نظر تقسیم می‌کنند سپس با ارتباط نتایج این الگوریتم و نرم‌افزار شبیه‌سازی هیدرولیکی، سعی در کاهش تعداد لوله‌های رابط پیشنهادی الگوریتم Girvan-Newman می‌کنند. همانطور که اشاره شد، استفاده از تئوری گراف باعث سهولت تبدیل شبکه‌های موجود به نواحی مجزا شده است. ولی یکی دیگر از

گام سوم - محاسبه مجدد امتیاز یال‌های باقی‌مانده
گام چهارم - تکرار مراحل از گام دوم

در شبکه تغییر فیزیکی صورت گیرد، می‌توان تعداد نواحی را به طور دلخواه تغییر داد و نتایج را در هر اجرا مورد بررسی قرار داد ولی باید توجه کرد اگر چه با افزایش تعداد نواحی مجازی محدودی کوچک‌تری که شامل نشت است شناسایی می‌شود، ولی دقت نتایج نهایی کاهش و همچنین داده‌های مورد نیاز برای شبکه‌ی عصبی افزایش پیدا می‌کند.

۲-۲- شبکه‌ی عصبی مصنوعی

شبکه‌ی عصبی مصنوعی، سیستمی است که با پردازش روی داده‌های موجود، رابطه‌ی نهفته بین داده‌ها را شناسایی می‌کند و هدف از آموزش شبکه عصبی این است که شبکه قانون کار را یاد بگیرد و پس از آموزش به ازای هر ورودی، خروجی مناسب را ارائه دهد. برای یافتن نشت در شبکه‌های توزیع آب با استفاده از شبکه‌های عصبی، باید سناریوهای فرضی نشت در حالت‌های مختلف ایجاد شود و شبکه‌ی عصبی قانون بین داده‌ها را آموزش ببیند و سپس با داده‌های میدانی، بتواند مکان و مقدار نشت در شبکه را مشخص کند. با توجه به اینکه ابعاد شبکه‌های توزیع آب در واقعیت دارای گره‌ها و لوله‌های زیاد می‌باشد، نمی‌توان برای تولید داده‌های شبکه‌ی عصبی تمامی گره‌ها را مورد بررسی قرار داد. از طرفی نیز نمی‌توان فقط برای تعدادی گره به صورت تصادفی اقدام به تولید داده‌ی آموزشی کرد. برای رفع این مشکل در مقاله‌ی حاضر، نواحی مجزایی که در بخش قبل توسط تئوری گراف ایجاد شد، به زیرگروه‌های کوچک‌تری تقسیم می‌شود. به عبارتی گره‌هایی را که در مجاورت هم قرار دارند، یک گره در نظر گرفته می‌شود و جستجوی نشت به جای گره، در این زیرگروه‌ها صورت می‌پذیرد (Shekofteh et al., 2018). در واقع به جای اینکه داده‌های آموزش شبکه‌ی عصبی برای تک‌تک گره‌ها تولید شود، به صورت تصادفی در تکرار زیاد برای این زیرگروه‌ها تولید می‌شود. با این کار حجم داده‌های تولیدشده برای شبکه‌ی عصبی کاهش پیدا می‌کند و آموزش شبکه بسیار سریع‌تر و با دقت بیشتری صورت می‌گیرد. به طور مثال اگر یک شبکه دارای ۴۰۰ گره باشد و فرض کنیم تعداد نواحی مجازی ۴ عدد می‌باشد، به طور تقریبی در هر ناحیه حدود ۱۰۰ گره وجود دارد. اگر برای تمامی این ۱۰۰ گره در یک ناحیه حالت‌های نشت در نظر گرفته شود، تعداد حالت‌ها بسیار زیاد می‌شود. ولی استفاده از تکنیک زیر گروه باعث کاهش شدید این حالت‌ها می‌شود. مثلاً هر ۱۰ گره‌ی نزدیک به هم به عنوان یک گره‌ی مادر در نظر گرفته می‌شود و تعداد فضای جستجو از ۱۰۰ عدد به ۱۰ عدد کاهش می‌یابد. در واقع نشت در هر ناحیه، بین زیرگروه‌ها جستجو می‌شود.

امتیازدهی یال‌های یک گراف حلقوی متناسب با دو پارامتر وزن و فاصله می‌باشد که در ادامه مورد بررسی قرار می‌گیرد. برای محاسبه‌ی این دو پارامتر در گراف مراحل زیر انجام می‌گیرد:

۱- وزن اولیه گره‌ی r برابر با ۱ و فاصله‌ی آن (d_r) برابر با صفر در نظر گرفته می‌شود. (فاصله پارامتری برای تعیین وزن بعضی از گره‌ها و امتیاز یال‌های شبکه می‌باشد.)

- اگر هنوز برای گره z هیچ فاصله‌ای تعیین نشده است، فاصله آن برابر با $d_z = d_r + 1$ و وزن آن برابر با $w_z = w_r$.
- اگر برای گره z فاصله‌ای تعریف شده باشد و $d_z = d_r + 1$ ، آنگاه وزن آن به اندازه w_i افزایش می‌یابد: $w_z = w_r + w_i$.
- اگر برای گره z فاصله‌ای تعیین شده باشد و $d_z < d_r + 1$ باشد، وزن آن تغییری نمی‌کند.

۴- تکرار مرحله ۳ تا جایی که هیچ گره‌ی بدون فاصله و وزن نمانده باشند.

پس از محاسبه‌ی وزن و فاصله برای تمامی گره‌های گراف، مراحل زیر برای محاسبه امتیاز یال‌ها، مراحل زیر انجام می‌شود:

- ۱- مشخص کردن گره‌های برگ (l) در شبکه.
- ۲- به یال متصل به گره برگ (l) و همسایگی آن (i)، امتیازی برابر با $\frac{w_i}{w_l}$ اختصاص داده می‌شود.
- ۳- ادامه امتیازدهی یال‌ها، از یال‌هایی که دورترین فاصله تا گره مرجع را دارند، شروع می‌شود (تحلیل از پایین به بالا صورت می‌گیرد). برای محاسبه امتیاز یال متصل به گره i و z (فاصله z به r بیشتر از فاصله i به r است) مجموع امتیاز یال‌هایی که گره‌ی z در آنها مشترک و نسبت به یال مذکور پایین‌تر قرار دارد، با ۱ جمع شده و سپس جواب حاصل شده، در $\frac{w_i}{w_j}$ ضرب می‌شود.

۴- مرحله ۳ تا زمانی که به گره r برسد، تکرار می‌یابد (Newman and Girvan, 2004; Shekofteh and Jalili Ghazizadeh, 2019).

با توجه به اینکه نواحی مجزای تعریف شده مجازی هستند و تعداد لوله‌های رابط بین نواحی اهمیتی ندارد، برای خوشه‌بندی پارامتری که مهم است تعداد گره‌های هر ناحیه است و با توجه به اینکه قرار نیست

توسط تئوری گراف و الگوریتم GN به دو ناحیه‌ی مجزا تقسیم و سپس هر ناحیه به زیرگروه‌هایی تقسیم می‌شود. سپس با در دست داشتن مقدار کلی نشت، داده‌های آموزش برای شبکه‌ی عصبی در حالت‌های مختلف همزمانی نشت تولید می‌شود. سپس شبکه‌ی عصبی با پارامترهای پیش فرض ایجاد می‌شود. آخرین مرحله از شبیه‌سازی یک پدیده توسط شبکه‌ی عصبی، تست شبکه است که از اهمیت فوق‌العاده‌ای برخوردار می‌باشد. سپس با معرفی یک سری داده که در مرحله آموزش هیچ دخالتی نداشته‌اند (ایجاد یک نشت فرضی که در داده‌های آموزش نیست)، شبیه‌سازی شبکه صورت می‌گیرد و داده‌های فشار برای حالت جدید به شبکه‌ی عصبی داده شود و مقایسه‌ای بین خروجی شبکه‌ی عصبی و نرم‌افزار هیدرولیکی صورت می‌گیرد. اگر میزان خطای مشاهده شده در مرحله تست نیز همچون آموزش شبکه، در حد قابل قبول و جواب‌ها پایدار باشد، می‌توان گفت این شبکه برای مسئله مورد نظر، کارآیی مطلوبی دارد و می‌تواند مورد استفاده واقع شود. این روند برای تعداد بیشتر نواحی مجزا به صورت مرحله‌ای، تکرار می‌یابد. شرط توقف این الگوریتم تا زمانی است که، شبکه‌ی عصبی نتواند پاسخ درستی برای آن تعداد ناحیه‌ی تولیدشده، پیش‌بینی کند و یا اینکه ناحیه‌ی دارای نشت طبق الگوریتم GN در مراحل بعد برای تقسیم‌بندی به صورت بهینه، اولویت نداشته باشد و برای تقسیم ناحیه‌ی دارای نشت، شبکه به تعداد نواحی کوچک و غیراقتصادی تبدیل می‌شود.

۳- شبکه‌ی توزیع آب مورد بررسی

شبکه‌ای که در این بخش مورد بررسی قرار گرفته است، شبکه‌ی توزیع آب شهر Balerna در شکل ۲، می‌باشد که برای اولین بار توسط Reza and Martínez (2006) ارائه شده است. این شبکه دارای چهار مخزن تامین آب، حدود ۴۴۰ گره و ۴۵۰ لوله می‌باشد. در این شبکه مصرف گرهی به طور متوسط برابر با ۵ لیتر بر ثانیه در نظر گرفته شده است. دلیل استفاده از این شبکه در تحقیق حاضر وجود اطلاعات و مرجع بودن آن است به‌صورتی که در مقالات زیادی مورد استفاده قرار گرفته است (Geem, 2009; Jung and Kim, 2018; Reza et al., 2008).

۳-۱- تعریف نواحی مجزا برای شبکه

در این بخش برای یافتن تعداد نواحی مجزای بهینه برای شبکه، ابتدا شبکه به دو نواحی مجزای طبق الگوریتم GN تقسیم می‌شود و سپس مرحله به مرحله تعداد نواحی مجزا افزایش می‌یابد تا تعداد ناحیه‌ی بهینه شناسایی شود.

معماری شبکه‌ی عصبی که در این مقاله مورد استفاده قرار گرفته است، از نوع MLP^{۱۸} پیشخور^{۱۸} می‌باشد که معمولاً در بیشتر اجراهای برنامه، ۸۰ درصد داده‌های ورودی به $trainRatio$ ، ۱۰ درصد به $valRatio$ و ۱۰ درصد دیگر به $testRatio$ اختصاص داده شده است که معمولاً بین ۵-۱۵ لایه نورون در نظر گرفته شده است. در واقع زمانی می‌توان به جواب‌های شبکه‌ی عصبی اعتماد کرد که جواب‌های هر اجرا تقریباً ثابت شده باشد و تغییرات زیادی نداشته باشد و یا به اصطلاح، شبکه‌ی عصبی پایدار شده باشد. در این مقاله روش تولید داده‌های آموزش شبکه‌ی عصبی به این صورت است که به صورت تصادفی در زیرگروه‌های هر ناحیه‌ی مجزای مجازی، نشت فرضی ایجاد می‌شود و سپس فشار گره‌هایی که فشارسنج بر روی آنها نصب شده است، برداشت می‌شود. با توجه به اینکه در واقعیت نمی‌توان تعداد گره‌های دارای نشت در شبکه را تعیین کرد، به همین دلیل در این مقاله برای تولید داده‌های آموزش شبکه‌ی عصبی، در هر سناریو، تعداد گره‌های نشت و همچنین مقدار آنها به صورت تصادفی تغییر می‌کند. پس از تهیه‌ی داده‌های مرحله‌ی آموزش، نوبت به ایجاد شبکه عصبی و تعیین پارامترهای بهینه مورد نیاز شبکه می‌رسد. در این مرحله باید هر کدام از توابع و پارامترها و حتی نوع معماری شبکه چندین بار تغییر داده شده و هر بار خروجی‌های شبکه با خروجی‌های حالت قبل مقایسه شود. در حالتی که شبکه به بهترین شبیه‌سازی و کمترین میزان خطا برسد، آن شبکه‌ی عصبی قادر به پیش‌بینی نشت متناسب با داده‌های مناسب می‌باشد. البته با توجه به اینکه مقادیر اولیه وزن‌ها و بایوس‌ها در شبکه عصبی به صورت تصادفی انتخاب می‌شوند، بهتر است برای هر معماری خاص نیز شبکه ایجاد شده چندین بار تحت آزمایش و اجرا قرار گیرد و یک حالت متوسط از نتایج اجراهای مختلف آن به عنوان خروجی‌های معماری مورد نظر جهت بررسی و مقایسه، ملاک عمل قرار گیرد. با انتخاب بهترین معماری و پارامترهای بهینه برای شبکه عصبی، شبکه‌ی ایجاد شده تا حدود زیادی توانایی پیش‌بینی محل و مقدار نشت را در زیرگروه‌های مختلف شبکه برای حالت‌های متفاوت نشت در شرایط واقعی را خواهد داشت. در آموزش شبکه‌ی عصبی، داده‌های ورودی مقادیر فشار در فشارسنج‌ها در هر سناریو و داده‌های هدف، ناحیه‌های دارای نشت به همراه مقدار آنها می‌باشد. پس از آموزش شبکه، مقادیر فشارهای ثبت‌شده توسط فشارسنج‌ها در شبکه‌ی واقعی به شبکه‌ی عصبی داده می‌شود و شبکه‌ی عصبی متناسب با آموزشی که دیده است، مکان نشت در هر ناحیه‌ی مجزا را نشان می‌دهد.

فلوچارت شکل ۱، مراحل کلی تعیین نواحی دارای نشت را با استفاده از تئوری گراف و شبکه‌ی عصبی نشان می‌دهد. به طور خلاصه پس از دریافت نقشه‌ی شبکه و تعیین نقاط دارای فشارسنج، ابتدا شبکه

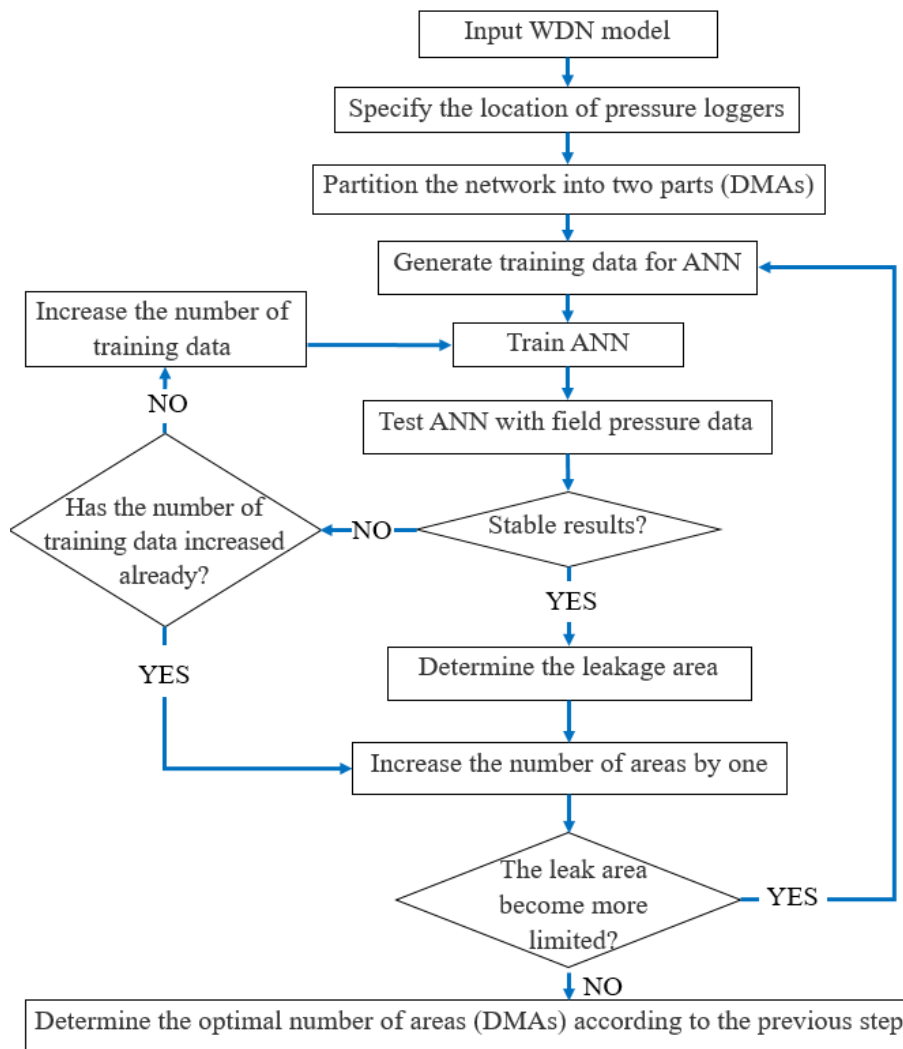


Fig. 1- The steps to identify leaky DMAs with ANN

شکل ۱- مراحل تعیین نواحی دارای نشت با شبکه‌ی عصبی

به اینکه هر ناحیه مجزا به چند زیرگروه تقسیم شده است، در هر سناریو این مقدار نشت به صورت تصادفی بین این زیرگروه‌های شبکه پخش می‌شود. برای این شبکه فرض می‌شود که تعداد فشارسنج‌های موجود در شبکه ۲/۵ درصد کل گره‌های شبکه (۱۱ عدد) مطابق شکل ۳ می‌باشد. برای انتخاب مکان فشارسنج‌ها سعی شده است فشارسنج‌ها حتی‌الامکان کل شبکه را پوشش دهد و به عبارتی هر فشارسنج بتواند محدوده‌ای از نقاط اطراف را پوشش دهد.

با توجه به اینکه از همزمانی تعداد گره‌های نشت اطلاعاتی در دست نمی‌باشد، فرض می‌شود حداکثر تعداد همزمان گره‌های دارای نشت در شبکه به تعداد نواحی مجزای انتخابی می‌باشد. پس از اینکه داده‌های آموزش تولید شد، پارامترهای شبکه عصبی تنظیم می‌شود و متناسب با داده‌های ورودی و هدف، آموزش شروع می‌شود.

با توجه به تعداد زیاد گره‌های شبکه، همانطور که قبلاً اشاره شد، برای کاهش داده‌های آموزش شبکه‌ی عصبی، هر ناحیه نیز به چند زیرگروه تقسیم می‌شود. با این تقسیم‌بندی گره‌های نزدیک به هم، در یک گروه قرار می‌گیرند و به جای جستجوی نشت بین تمامی گره‌های شبکه، فقط بین این زیرگروه‌ها جستجوی نشت انجام می‌شود. این روش پیشنهادی سبب کاهش حجم داده‌های آموزش و افزایش تنوع در داده‌ها می‌شود.

۲-۳- نحوه آموزش شبکه عصبی

به منظور آموزش شبکه‌ی عصبی، باید سناریوهای مختلفی از نشت (انتخاب تصادفی تعداد همزمانی نشت و مقدار نشت موجود در هر گره‌ی انتخابی) در تعداد زیادی تولید شود. در این شبکه فرض می‌شود که مقدار نشت کل در شبکه برابر با ۱۰ لیتر بر ثانیه می‌باشد. با توجه

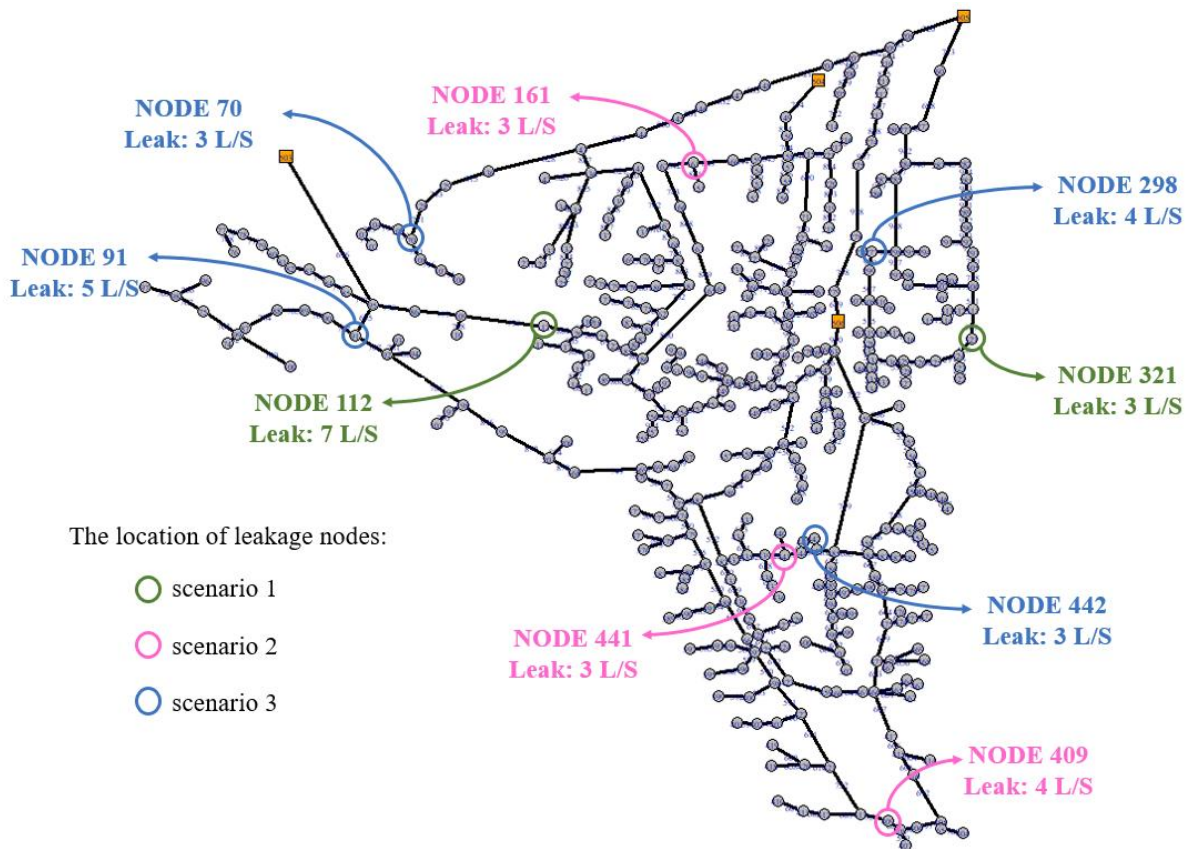


Fig. 2- Balerma network (Reca and Martínez, 2006) and the leakage positions for all scenarios
 شکل ۲- شبکه‌ی Balerma به همراه موقعیت گره‌های نشت در تمامی سناریوها

۳-۳- بررسی کارایی روش ارائه شده

به منظور کارایی روش ارائه شده، اقدام به ایجاد نشت فرضی در شبکه مورد مطالعه شده و سپس در مدل دارای نشت، مقادیر فشارسنج‌ها در گره‌هایی که به عنوان محل‌های اندازه‌گیری فشار میدانی در نظر گرفته شده‌است، به عنوان فشارهای میدانی به شبکه‌ی عصبی معرفی می‌شود. خروجی شبکه‌ی عصبی، مقدار نشت در هر ناحیه را مشخص می‌کند.

۳-۳-۱- سناریوی شماره ۱

در سناریوی اول، دو نشت فرضی همزمان در گره‌های ۱۱۲ و ۳۲۱ بترتیب به مقدار ۷ و ۳ لیتر ایجاد شد. موقعیت گره‌های نشت در شکل ۲ نشان داده شده است.

شکل ۴، شبکه را هنگامی که به دو ناحیه تقسیم شده است نشان می‌دهد. پس از دریافت فشارهای ثبت شده توسط فشارسنج‌ها، فشارهای میدانی برداشت شده به عنوان ورودی به شبکه‌ی عصبی داده شد. در این مرحله تعداد داده‌های تولید شده برای آموزش شبکه‌ی

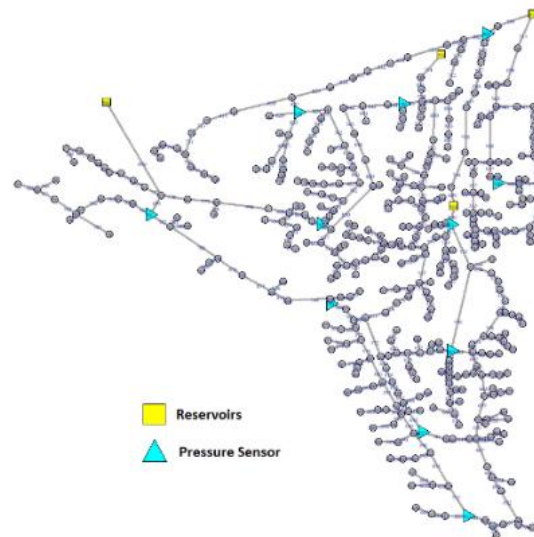


Fig. 3- The placement of the pressure data loggers in the network (2.5% of all nodes)

شکل ۳- مکان فشارسنج‌های شبکه ۲/۵ درصد کل گره‌های شبکه

Table 1- The final result for 2 DMAs (Scenario 1)
جدول ۱- خروجی نهایی برای دو ناحیه (سناریو ۱)

DMA No.	1	2
Predicted Demand (L/S)	11.96	8.02
Base Demand (L/S)	5	5
Real Leakage (L/S)	7	3
Real Demand (L/S)	12	8

عصبی ۱۰۰ عدد در نظر گرفته شده است. در واقع با در نظر گرفتن این تعداد داده‌ی آموزش برای شبکه‌ی عصبی، جواب‌های ارائه شده توسط آن ثابت می‌باشد و شبکه عصبی پایدار می‌باشد. به همین دلیل می‌توان به جواب‌های آن اعتماد کرد. مقدار ضریب همبستگی (رگرسیون) کلی شبکه‌ی عصبی ۰/۹۹۹ بدست آمده است. جدول ۱ نتایج خروجی شبکه‌ی عصبی را نشان می‌دهد.



Fig. 4- Clustering the network into 2 DMAs
شکل ۴- تبدیل شبکه به دو ناحیه مجزا

Table 2- The final result for 3 DMAs (Scenario 1)
جدول ۲- خروجی نهایی برای سه ناحیه (سناریو ۱)

DMA No.	1	2	3
Predicted Demand (L/S)	11.75	8.33	5.04
Base Demand (L/S)	5	5	5
Real Leakage (L/S)	≈ 7	3	0
Real Demand (L/S)	12	8	5

همانطور که ملاحظه می‌شود ناحیه‌ی ۱ دارای نشت ۷ لیتر بر ثانیه و ناحیه‌ی ۲ دارای نشت ۳ لیتر بر ثانیه است که از مقایسه این جدول و موقعیت نشت‌ها در شکل ۲، شبکه‌ی عصبی به درستی نواحی دارای نشت و مقدار نشت در آن نواحی را تشخیص داده است. با توجه به اینکه در مرحله‌ی اول شبکه به دو ناحیه تبدیل شده است، تعداد گره‌ها در هر ناحیه زیاد می‌باشد، به همین دلیل نمی‌توان این تعداد ناحیه را برای شبکه به عنوان نواحی بهینه در نظر گرفت.

مشاهده می‌شود که با تبدیل شبکه به سه ناحیه‌ی مجزا، مشخص شده است که ناحیه‌ی سه، دارای نشت نمی‌باشد. به عبارتی منطقه‌ی نشت نسبت به مرحله‌ی قبل محدودتر شده است. برای اینکه ناحیه‌ی بهینه برای این شبکه تعریف شود، این مراحل برای تعداد بیشتر ناحیه تکرار می‌شود. جدول ۳ خروجی را برای نواحی ۴ و ۵ نشان می‌دهد. تعداد داده‌های آموزش برای نواحی ۴ نیز ۱۰۰ عدد در نظر گرفته شده است که رگرسیون آن ۰/۹۹۲ بدست آمده است.

در مرحله‌ی بعد برای اینکه محدوده نشت، کوچکتر شود، شبکه به ۳ ناحیه‌ی مجزا مطابق شکل ۵ تبدیل می‌شود. در این حالت، الگوریتم GN، ناحیه ۱ در مرحله قبل را به دو قسمت تقسیم کرده است. پس از تقسیم شبکه، مجدد داده‌های شبکه‌ی عصبی بر مبنای این سه ناحیه تولید می‌شود. در این مرحله نیز ۱۰۰ داده‌ی آموزش تولید شده است که رگرسیون کلی ۰/۹۸۷ بدست آمده است. جدول ۲، نتایج خروجی شبکه‌ی عصبی برای این مرحله را نشان می‌دهد.

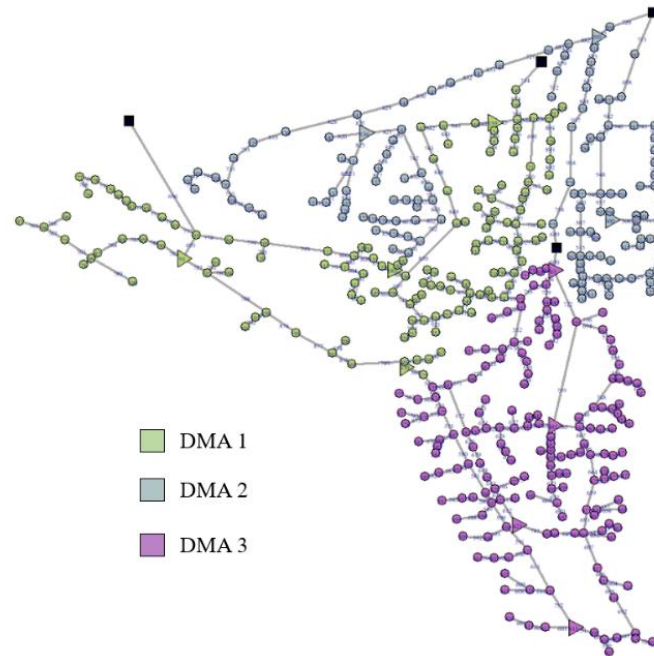


Fig. 5- Clustering the network into 3 DMAs
 شکل ۵- تبدیل شبکه به سه ناحیه مجزا

Table 3- The final result for (a) 4, (b) 5 DMAs (Scenario 1)
 جدول ۳- خروجی نهایی برای (الف) چهار، (ب) پنج ناحیه (سناریو ۱)

		DMA No.	1	2	3	4	
(a)	Predicted Demand (L/S)		8.10	4.91	5.16	12.22	
	Base Demand (L/S)		5	5	5	5	
	Real Leakage (L/S)		3	0	0	7	
	Real Demand (L/S)		8	5	5	12	
		DMA No.	1	2	3	4	5
(b)	Predicted Demand (L/S)		4.69	5.56	5.11	12.59	7.91
	Base Demand (L/S)		5	5	5	5	5
	Real Leakage (L/S)		0	0	0	≈ 7	≈ 3
	Real Demand (L/S)		5	5	5	12	8

با مقایسه خروجی جدول ۳ و شکل ۶، مشاهده می‌شود که با توجه به نواحی تولید شده در هر مرحله، محدوده‌ی نشت کوچکتر شده است و شبکه‌ی عصبی با دقت بالایی نشت در هر ناحیه را پیش‌بینی کرده است. در مرحله‌ی بعد با تبدیل شبکه به شش و هفت ناحیه‌ی مجزا مطابق شکل ۷، مشاهده می‌شود که الگوریتم GN اولویت تقسیم‌بندی را به نواحی داده است که مشکوک به نشت نبوده‌اند. به عبارتی ناحیه‌های جدید تولید شده تأثیری در محدودتر کردن منطقه‌ی نشت ندارد؛ ولی با این وجود شبکه‌ی عصبی طبق جدول ۴، نتایج را به درستی پیش‌بینی کرده است. البته قابل ذکر است که با افزایش نواحی مجزا، دقت شبکه‌ی عصبی کاهش پیدا کرده است. در این دو مرحله تعداد داده‌های آموزش شبکه‌ی عصبی ۵۰۰ عدد در نظر گرفته شده است.

برای نواحی ۵، با توجه به دقت پایین رگرسیون برای ۱۰۰ داده‌ی آموزش در این مرحله، تعداد داده‌های آموزش ۳۰۰ عدد در نظر گرفته شده شد که رگرسیون متناسب با آن ۰/۹۵۹ بدست آمده است. به عبارت دیگر هنگامی که داده‌های آموزش برای این بخش، ۱۰۰ عدد در نظر گرفته شده بود، جواب‌هایی که شبکه‌ی عصبی ارائه می‌کرد ثابت و پایدار نبود و در هر بار اجرا جواب‌های مختلفی ارائه می‌کرد و چون فرض بر این است که اطلاعاتی از موقعیت نقاط نشت در دسترس نیست، نمی‌توان به چنین شبکه‌ای اعتماد کرد. با افزایش داده‌های آموزش، همانطور که اشاره شد، علاوه بر افزایش رگرسیون شبکه عصبی، جواب‌های پایدار و ثابت در هر اجرا پیش‌بینی می‌شود. شکل ۶، نواحی ایجاد شده در شبکه را نشان می‌دهد.

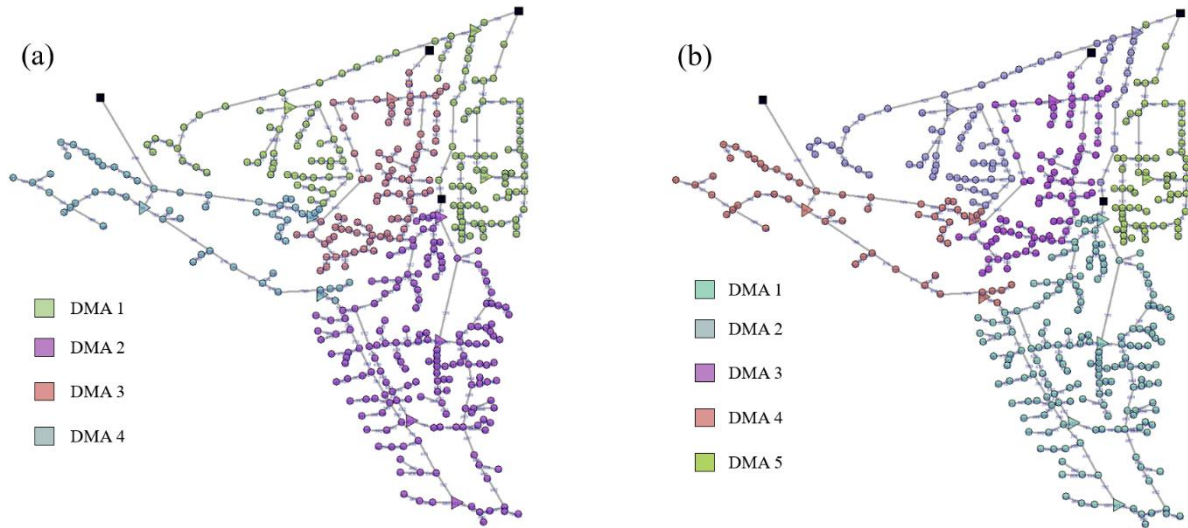


Fig. 6- Clustering the network into (a) 4, (b) 5 DMAs
 شکل ۶- تبدیل شبکه به (الف) چهار، (ب) پنج ناحیه مجزا

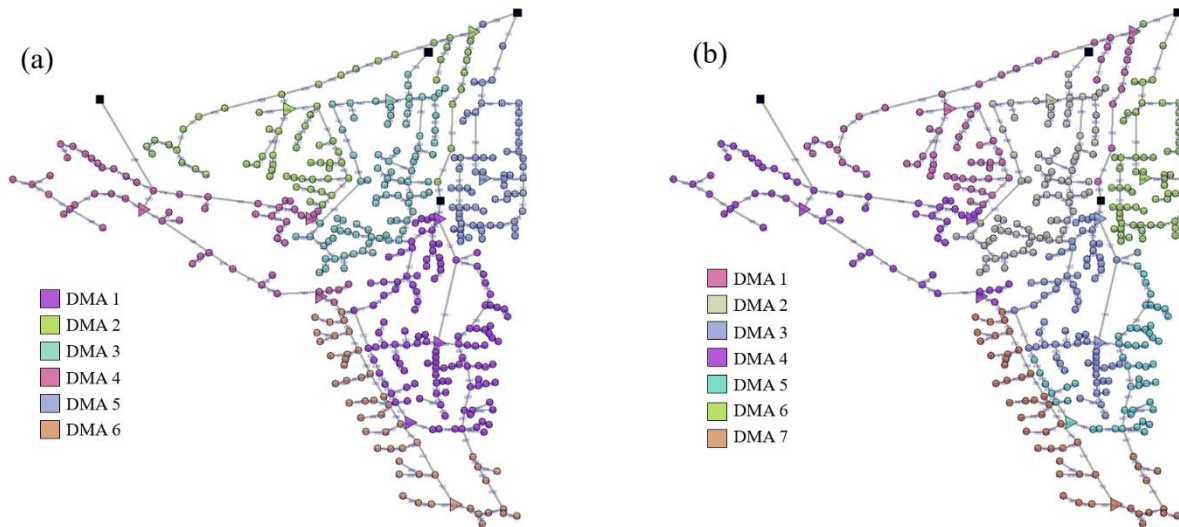


Fig. 7- Clustering the network into (a) 6, (b) 7 DMAs
 شکل ۷- تبدیل شبکه به (الف) شش، (ب) هفت ناحیه مجزا

Table 4- The final result for (a) 6, (b) 7 DMAs (Scenario 1)
 جدول ۴- خروجی نهایی برای (الف) شش، (ب) هفت ناحیه (سناریو ۱)

DMA No.		1	2	3	4	5	6	
(a)	Predicted Demand (L/S)	4.63	4.77	4.63	12.78	7.83	5.23	
	Base Demand (L/S)	5	5	5	5	5	5	
	Real Leakage (L/S)	0	0	0	7	3	0	
	Real Demand (L/S)	5	5	5	12	8	0	
DMA No.		1	2	3	4	5	6	7
(b)	Predicted Demand (L/S)	5.37	5.32	5.84	12.24	4.34	8.29	3.88
	Base Demand (L/S)	5	5	5	5	5	5	5
	Real Leakage (L/S)	0	0	0	7	0	3	0
	Real Demand (L/S)	5	5	5	12	5	8	5

با توجه به اینکه از مرحله ۵ ناحیه‌ی مجزا تا مرحله ۱۰ هیچ کدام از نواحی مشکوک به نشت توسط الگوریتم GN تقسیم نشده است، می‌توان همان ۵ ناحیه‌ی مجزا را به عنوان تعداد ناحیه بهینه برای این سناریو انتخاب کرد. با توجه به جدول‌های این سناریو، بیشترین خطای پیش‌بینی مقدار نشت مربوط به جدول ۴ بخش a می‌باشد که حدود ۶/۵ درصد می‌باشد که مقدار نشت برای ناحیه ۴ حدود ۱۲/۷۸ به جای ۱۲ و برای ناحیه ۵، حدود ۷/۸۳ به جای ۸ پیش‌بینی شده است.

۳-۳-۲- سناریوی شماره ۲

در سناریوی دوم فرض می‌شود که ۳ نشت همزمان در گره‌ی ۴۴۱ به مقدار ۳ لیتر، گره‌ی ۱۶۱ به مقدار ۳ لیتر و گره‌ی ۴۰۹ به مقدار ۴ لیتر ایجاد شد. موقعیت نشت‌های شبکه در شکل ۲ نشان داده شده است.

برای اینکه یکی از نواحی مشکوک به نشت توسط الگوریتم GN تقسیم شود، باید این روند ادامه یابد. در مرحله ۱ یازده، یکی از نواحی مشکوک به نشت به دو بخش تقسیم می‌شود. شکل ۸ شبکه را هنگامی که به یازده ناحیه تقسیم شده است، نشان می‌دهد و در جدول ۵ نتایج خروجی مشاهده می‌شود. برای این مرحله، داده‌های آموزش ۱۰۰۰ عدد در نظر گرفته شده است که رگرسیون ۰/۹۴۴ به دست آمده است.

در این تقسیم‌بندی جدید، ناحیه‌ی ۴ در مرحله ۱ هفت ناحیه‌ی مجزا به دو بخش تقسیم شده و نواحی ۱۰ و ۱۱ در این مرحله جدید را بوجود آورده است. با توجه به خروجی جدول ۵، مشخص شده است که نشت در ناحیه ۱۰ قرار دارد. به عبارتی این تقسیم‌بندی جدید ناحیه نشت مربوط به گره‌ی ۱۱۲ را محدودتر کرده است. طبق جدول ۵، ناحیه‌ی ۲ نیز دارای نشت است. این ناحیه از مرحله ۱ پنج ناحیه‌ی مجزا به عنوان ناحیه‌ی نشت مشخص شده است.

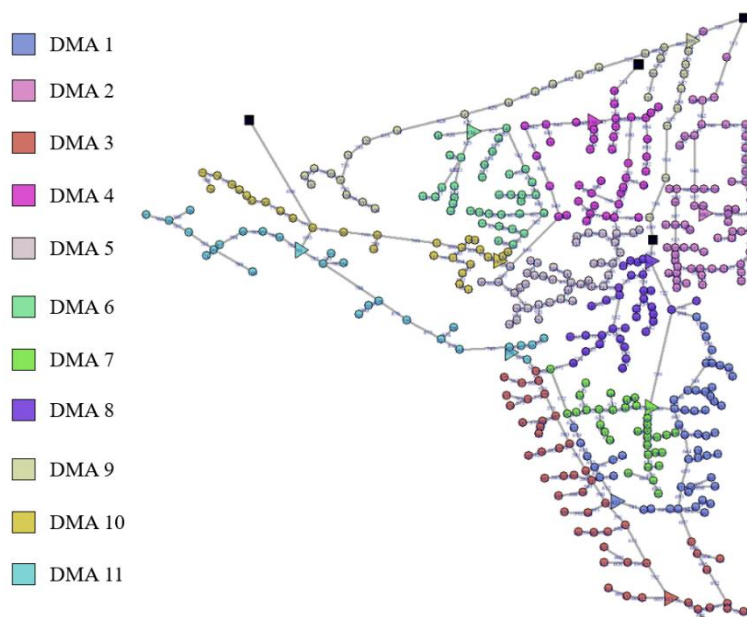


Fig. 8- Clustering the network into 11 DMAs

شکل ۸- تبدیل شبکه به یازده ناحیه مجزا

Table 5- The final result for 11 DMAs (Scenario 1)

جدول ۵- خروجی نهایی برای یازده ناحیه (سناریو ۱)

DMA No.	1	2	3	4	5	6	7	8	9	10	11
Predicted Demand (L/S)	5.16	8.09	4.93	5.11	4.73	5.03	4.61	5.09	5.08	11.26	5.89
Base Demand (L/S)	5	5	5	5	5	5	5	5	5	5	5
Real Leakage (L/S)	0	3	0	0	0	0	0	0	0	7	0
Real Demand (L/S)	5	8	5	5	5	5	5	5	5	12	5

نشت در ناحیه‌ی سه پیش‌بینی شده است. این مرحله باعث محدودتر شدن ناحیه‌ی نشت شده است.

مرحله‌ی D (شکل ۶-ب)، با تقسیم ناحیه‌ی یک از مرحله‌ی قبل کمکی به محدودتر شدن مکان نشت نشده است. ملاحظه می‌شود که دقت نتایج نیز کاهش یافته است.

مرحله‌ی E (شکل ۷-الف)، با تقسیم ناحیه‌ی یک از مرحله‌ی قبل به دو قسمت، نواحی یک و شش از این مرحله را به وجود آورده است. با مقایسه موقعیت نقاط نشت و نواحی تولیدشده و جدول ۶ ملاحظه می‌شود که شبکه‌ی عصبی به درستی تشخیص داده است که نشت گره‌ی ۴۴۱ مربوط به ناحیه‌ی یک و نشت گره‌ی ۴۰۹ مربوط به ناحیه‌ی شش می‌باشد.

مرحله‌ی F (شکل ۷-ب)، با تقسیم ناحیه‌ی یک از مرحله‌ی E، نواحی سه و پنج مرحله‌ی F را تشکیل داده است. به عبارتی با توجه به موقعیت نقاط نشت فرضی، در این تقسیم‌بندی، گره‌ی ۱۶۱ در ناحیه‌ی ۲، گره‌ی ۴۰۹ در ناحیه‌ی ۷ و گره‌ی ۴۴۱ در ناحیه‌ی ۳ قرار می‌گیرند. یعنی شبکه‌ی عصبی باید نشت نواحی ۲، ۳ و ۷ را با مقادیر ۳، ۴ و ۳ لیتر بر ثانیه پیش‌بینی کند. با مراجعه به جدول ۶ ملاحظه می‌شود نواحی ۲ و ۷ با مقدار تقریبی ۴ و ۳ لیتر بر ثانیه به درستی شناسایی شده‌اند ولی مقدار نشت ناحیه‌ی ۳، حدوداً ۱/۵ لیتر پیش‌بینی شده است که نادرست می‌باشد. در صورتی که ناحیه یک از مرحله‌ی E نشتی برابر با ۲/۵ پیش‌بینی شده بود. با مقایسه خروجی جدول F-۶ در نواحی سه و پنج ملاحظه می‌شود که مجموع نشت پیش‌بینی شده مجموع این ناحیه ۲/۵ می‌باشد. به عبارتی با تقسیم‌بندی شبکه به هفت ناحیه‌ی مجزا، شبکه‌ی عصبی قادر به پیش‌بینی ناحیه‌ی دقیق گره‌ی ۴۴۱ بین نواحی سه و پنج نشده است. به این ترتیب می‌توان نتیجه گرفت برای این سناریو تبدیل شبکه به شش ناحیه‌ی مجزا بهینه می‌باشد و بعد از آن دقت خروجی نتایج کاهش پیدا می‌کند.

در این سناریو نیز ابتدا تحلیل با دو ناحیه شروع می‌شود و سپس به ترتیب تا هفت ناحیه‌ی مجزا ادامه می‌یابد. جدول ۶ خروجی در هر مرحله را نشان می‌دهد. واحد عددهای جدول همانند سناریوی قبل، لیتر بر ثانیه است که برای بدست آوردن مقدار نشت در هر ناحیه، عددهای جدول باید از مقدار مصرف پایه که ۵ لیتر بر ثانیه است، کم شود.

در مرحله‌ی A (شکل ۴)، ناحیه‌ی یک با توجه به خروجی شبکه‌ی عصبی در جدول ۶ نشتی برابر با ۸ و ناحیه‌ی دو بدون نشت پیش‌بینی شده است. با مقایسه موقعیت نقاط نشت و نواحی تولیدشده، ملاحظه می‌شود که شبکه‌ی عصبی به درستی تشخیص داده است که در ناحیه‌ی دو نشتی وجود ندارد ولی مقدار نشت کل که ۱۰ لیتر بر ثانیه بوده است را ۸ پیش‌بینی کرده است و دلیل آن کافی نبودن تعداد نواحی برای شناسایی نشت می‌باشد. با توجه به اینکه نواحی تولید شده، گره‌های زیادی را شامل می‌شود، در مرحله‌ی بعد شبکه به سه ناحیه تقسیم می‌شود.

در مرحله‌ی B (شکل ۵)، مقدار نشت ناحیه‌ی یک، ۴ و مقدار نشت ناحیه‌ی سه، ۷ لیتر بر ثانیه طبق جدول ۶ پیش‌بینی شده است و ناحیه‌ی دو بدون نشت می‌باشد. با مقایسه موقعیت نقاط نشت و نواحی تولیدشده در مرحله‌ی B، ملاحظه می‌شود که شبکه‌ی عصبی به درستی تشخیص داده است که در ناحیه‌ی دو نشتی وجود ندارد و به عبارتی ناحیه‌ی یک در مرحله‌ی A را به دو قسمت تقسیم کرده که ملاحظه می‌شود با دقت قابل قبولی مقدار نشت در هر کدام از نواحی را پیش‌بینی کرده است.

در مرحله‌ی C (شکل ۶-الف)، ناحیه‌ی یک از مرحله‌ی قبل به دو قسمت تقسیم شده است که این دو قسمت نواحی سه و چهار در مرحله C می‌باشد که با توجه به جدول ۶ ملاحظه می‌شود به درستی مقدار

Table 6- The final output of ANN (scenario 2)
جدول ۶- خروجی نهایی شبکه‌ی عصبی (سناریو ۲)

		DMA No.						
		1	2	3	4	5	6	7
STEP	A	12.98	5.94	-	-	-	-	-
	B	8.87	4.11	12.04	-	-	-	-
	C	4.98	11.45	8.54	5.02	-	-	-
	D	9.21	5.38	9.53	6.58	4.21	-	-
	E	7.56	5.32	8.45	4.99	4.74	9.09	-
	F	4.70	9.78	6.64	4.49	6.17	4.45	8.60

۴ و ۵ که دارای نشت بوده‌اند، به درستی شناسایی شده است و مقادیر نشت در هر ناحیه با دقت قابل قبولی پیش‌بینی شده است.

۳-۴- تحلیل حساسیت نسبت به تعداد فشارسنج‌ها

در این بخش برای سه سناریوی انجام شده فرض می‌شود تعداد نواحی در هر سه سناریو شش عدد ثابت طبق شکل ۷-الف می‌باشد ولی تعداد فشارسنج‌ها در شبکه نصف حالت قبل و ۶ عدد (۱/۵ درصد کل گره‌های شبکه) فرض می‌شود و در نهایت مقایسه‌ای بین جواب‌ها انجام می‌شود. شکل ۹ موقعیت نقاط فشارسنج‌های جدید در شبکه را نشان می‌دهد.

جدول ۸، خروجی برای سناریوی اول در دو حالت فشارسنج را نشان می‌دهد. بخش‌های سبز نشان‌دهنده‌ی پیش‌بینی صحیح شبکه‌ی عصبی می‌باشد و بخش‌های زرد از نظر مکان و یا مقدار نشت به درستی شناسایی نشده‌اند.

۳-۳- سناریوی شماره ۳

در این سناریو فرض می‌شود مقدار نشت کل ۱۵ لیتر بر ثانیه می‌باشد. اگر مقدار نشت کل در شبکه تغییر کند باید داده‌های تولید شده برای شبکه‌ی عصبی متناسب با مقدار نشت کل نیز تغییر کند. با توجه به سناریو ۱ و ۲، در این سناریو فرض می‌شود تعداد نواحی مجزا شش عدد و ثابت مطابق شکل ۷-الف می‌باشد. مقدار نشت به چهار گره‌ی ۷۰، ۹۱، ۲۹۸ و ۴۴۲ (به ترتیب در نواحی ۲، ۴، ۵ و ۱) با مقادیر نشت ۳، ۴، ۵ و ۳ لیتر بر ثانیه اختصاص داده شده است. موقعیت نقاط نشت این سناریو نیز همانند دو سناریوی قبل در شکل ۲ نشان داده شده است.

پس از آموزش مجدد شبکه‌ی عصبی، جدول ۷ خروجی نهایی را نشان می‌دهد. برای این سناریو، ۲۰۰۰ داده‌ی آموزش تولید شده است و رگرسیون کلی ۰/۹۹۰ بدست آمده است. ملاحظه می‌شود که با تغییر نشت به ۱۵ لیتر، نتایج خروجی با توجه به اینکه همزمانی تعداد نشت در شبکه افزایش یافته است، همچنان قابل اعتماد بوده و نواحی ۱، ۲،

Table 7- The final output of ANN (scenario 3)
جدول ۷- خروجی نهایی شبکه‌ی عصبی (سناریو ۳)

DMA NO.	1	2	3	4	5	6
Predicted Demand (L/S)	7.8911	7.9646	5.0555	10.5365	8.4517	5.1003
Base Demand (L/S)	5	5	5	5	5	5
Real Leakage (L/S)	3	3	0	5.5	3.5	0
Real Demand (L/S)	8	8	5	10	9	5

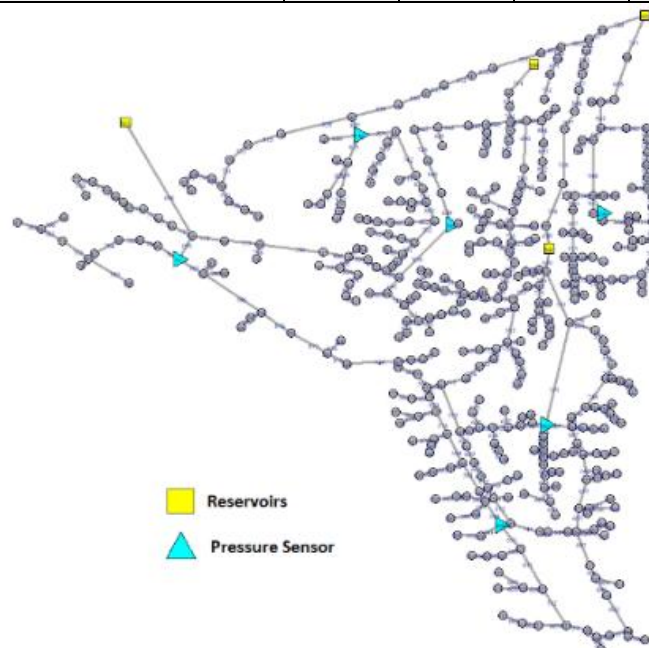


Fig. 9- The new placement of the pressure data loggers in the network (1.5% of all nodes)
شکل ۹- مکان فشارسنج‌های جدید شبکه (۱/۵ درصد کل گره‌های شبکه)

تفاوت چندانی ندارد، به عبارتی کاهش فشارسنج‌ها تأثیر زیادی بر خروجی نداشته است و شبکه‌ی عصبی با تعداد کمتر فشارسنج نیز پیش‌بینی قابل قبولی انجام داده است.

نکته‌ی قابل توجه از مقایسه‌ی نتایج خروجی سه سناریو این است که الزاماً تعداد زیاد فشارسنج به معنای دقت بیشتر در نتایج خروجی نمی‌باشد و مشاهده شد که با تعداد کمتر فشارسنج، نواحی دارای نشت به درستی شناسایی شدند و از مقایسه نتایج مربوط به حالت اول (فشارسنج‌های کمتر) نسبت به حالت دوم (فشارسنج بیشتر) مشخص می‌شود درصد خطای کمی بین دو جواب وجود دارد.

در حالت (الف) دو ناحیه‌ی ۴ و ۵ به درستی شناسایی شده است ولی در عین حال ناحیه‌ی ۳ نیز به عنوان ناحیه‌ی دارای نشت مشخص شده است. در حالت (ب) با افزایش تعداد فشارسنج‌ها، همانطور که در جدول ۸-ب مشخص است دقت نتایج خروجی افزایش قابل توجهی داشته‌است و علاوه بر نواحی دارای نشت، مقدار دقیق نشت در هر ناحیه پیش‌بینی شده است.

جدول ۹، خروجی برای سناریوی دوم در دو حالت فشارسنج را نشان می‌دهد. در این سناریو مشاهده می‌شود نتایج خروجی برای دو حالت

Table 8- The final output for the condition where the pressure data loggers are placed in (a). 1.5% and (b). 2.5% of all nodes (scenario 1)

جدول ۸- خروجی نهایی: (الف) برای ۱/۵ درصد فشارسنج‌ها، (ب) برای ۲/۵ درصد فشارسنج‌ها (سناریو ۱)

DMA No.		1	2	3	4	5	6
(a)	Predicted Demand (L/S)	5.2579	4.9861	6.3876	10.2562	8.2656	4.8474
	Base Demand (L/S)	5	5	5	5	5	5
	Real Leakage (L/S)	0	0	1	5	3	0
	Real Demand (L/S)	5	5	5	12	8	5
DMA No.		1	2	3	4	5	6
(b)	Predicted Demand (L/S)	4.63	4.77	4.63	12.78	7.83	5.23
	Base Demand (L/S)	5	5	5	5	5	5
	Real Leakage (L/S)	0	0	0	7	3	0
	Real Demand (L/S)	5	5	5	12	8	5

Table 9- The final output for the condition where the pressure data loggers are placed in (a). 1.5% and (b). 2.5% of all nodes (scenario 2)

جدول ۹- خروجی نهایی: (الف) برای ۱/۵ درصد فشارسنج‌ها، (ب) برای ۲/۵ درصد فشارسنج‌ها (سناریو ۲)

DMA No.		1	2	3	4	5	6
(a)	Predicted Demand (L/S)	7.3528	5.0196	8.1470	4.7242	5.2435	9.5117
	Base Demand (L/S)	5	5	5	5	5	5
	Real Leakage (L/S)	2	0	3	0	0	4
	Real Demand (L/S)	8	5	8	5	5	9
DMA No.		1	2	3	4	5	6
(b)	Predicted Demand (L/S)	7.56	5.32	8.45	4.99	4.74	9.09
	Base Demand (L/S)	5	5	5	5	5	5
	Real Leakage (L/S)	2	0	3	0	0	4
	Real Demand (L/S)	8	5	8	5	5	9

Table 10- The final output for the condition where the pressure data loggers are placed in (a). 1.5% and (b). 2.5% of all nodes (scenario 3)

جدول ۱۰- خروجی نهایی: (الف) برای ۱/۵ درصد فشارسنج‌ها، (ب) برای ۲/۵ درصد فشارسنج‌ها (سناریو ۳)

DMA No.		1	2	3	4	5	6
(a)	Predicted Demand (L/S)	8.0166	8.3195	5.3966	9.8648	8.2844	5.0756
	Base Demand (L/S)	5	5	5	5	5	5
	Real Leakage (L/S)	3	3	0	≈ 5	3	0
	Real Demand (L/S)	8	8	5	10	9	5
DMA No.		1	2	3	4	5	6
(b)	Predicted Demand (L/S)	7.8911	7.9646	5.0555	10.5365	8.4517	5.1003
	Base Demand (L/S)	5	5	5	5	5	5
	Real Leakage (L/S)	3	3	0	≈ 5	3.5	0
	Real Demand (L/S)	8	8	5	10	9	5

- 8- Graph Theory
- 9- Pressure Management Zones (PMZ)
- 10- Last-In-First-Out (LIFO)
- 11- Dissimilarity Matrices
- 12- Design Support Methodology (DSM)
- 13- Simulated Annealing Algorithm
- 14- Artificial Neural Network
- 15- Edge
- 16- Vertex
- 17- Multilayer Perceptron
- 18- Feedforward

۵- مراجع

- Attari M and Faghfour Maghrebi M (2018) New method for leakage detection by using artificial neural networks. *Journal of Water and Wastewater (parallel title)*; Ab va Fazilab 29(1):14-26 (In Persian)
- Candelieri A, Conti D, and Archetti F (2014) A graph based analysis of leak localization in urban water networks. *Procedia Engineering* 70:228-237
- Darsana P and Varija K (2018) Leakage detection studies for water supply systems- A review. *Water Resources Management* 141-150
- Di Nardo A and Di Natale M (2011) A heuristic design support methodology based on graph theory for district metering of water supply networks. *Engineering Optimization* 43(2):193-211
- Fanner P, Davis S, Hoogerwerf T, Liemberger R, Sturm R, and Thornton J (2008) Leakage management technologies. *Water Environment Research Foundation*
- Farley M and Trow S (2003) *Losses in water distribution networks*. IWA publishing
- Geem ZW (2009) Particle-swarm harmony search for water network design. *Engineering Optimization* 41(4):297-311
- Gomes R, Marques AS, and Sousa J (2012.a) Decision support system to divide a large network into suitable District Metered Areas. *Water Science and Technology* 65(9):1667-1675
- Hamilton S and McKenzie R (2014) *Water management and water loss*. IWA Publishing
- Herrera M, Canu S, Karatzoglou A, Pérez-García R, and Izquierdo J (2010) An approach to water supply clusters by semi-supervised learning. *International Environmental Modelling and Software Society (iEMSs), International Congress on Environmental Modelling and Software*
- Jung D and Kim J H (2018) Using mechanical reliability in multiobjective optimal meter placement for pipe

۴- جمع بندی و نتیجه گیری

در این مقاله روشی برای تعیین محدوده‌های نشت در شبکه‌های توزیع آب پیشنهاد شده است. در این روش ابتدا شبکه‌ای موجود با استفاده از تئوری گراف به دو نواحی مجزای تقسیم می‌شود. سپس با استفاده فشارسنج‌های موجود در شبکه و بدون استفاده از دی‌سنج بین نواحی، نشت در هر ناحیه با استفاده از شبکه‌ی عصبی پیش‌بینی گردیده و امکان اولویت‌بندی نواحی برای یافتن نشت را در اختیار می‌گذارد. سپس مرحله به مرحله تعداد نواحی افزایش می‌یابد تا جایی که نتایج توسط شبکه‌ی عصبی تغییر معناداری نداشته باشد. با این کار تعداد ناحیه‌ی مجزای بهینه به دست می‌آید. این روش باعث کاهش هزینه‌ی زیاد برای تبدیل شبکه‌های قدیمی به شبکه‌های دارای نواحی مجزا به دلیل استفاده نکردن از دی‌سنج می‌شود. در مقاله حاضر از خطاهای فشارسنج‌ها در اندازه‌گیری مقدار فشار، صرف نظر شده است. نتایج مطالعات موردی نشان داد که روش ارائه شده، نشت در هر ناحیه برای هر مرحله را به درستی شناسایی می‌کند و می‌توان تعداد نواحی مجزای بهینه برای شبکه را تعیین کرد. همچنین تحلیلی براساس تعداد فشارسنج‌ها در مقاله صورت گرفت. نتایج نشان می‌دهد که کاهش دقت نتایج در زمان کاهش تعداد فشارسنج‌ها، چشمگیر نیست. به عبارت دیگر الزاماً تعداد زیاد فشارسنج به معنای افزایش دقت نتایج خروجی نمی‌باشد و مکان فشارسنج‌ها در شبکه تأثیر بیشتری بر دقت نتایج پیش‌بینی دارد. یکی از مزیت‌های روش حاضر با سایر مقالات مشابه این است که به داشتن تعداد گره‌های نشت (قبل از عملیات نشت‌یابی در شبکه) نیاز نیست. به عبارت دیگر در هر مرحله از روش ارائه شده، هر بخشی که دارای نشت باشد، شناسایی می‌شود. البته باید ذکر شود که در تحقیق حاضر از خطای فشارسنج‌ها صرف‌نظر شده است. از دیگر مزایای این مقاله، در نظر گرفتن تعداد زیاد گره‌های نشت می‌باشد که این مورد در سایر مقالات مشابه، حداکثر دو نشت همزمان بوده است. همچنین می‌توان بررسی یک شبکه بزرگ و پیچیده را نیز از مزایای مقاله حاضر محسوب کرد. روش پیشنهادی در این مقاله می‌تواند شبکه‌های قدیمی و شبکه‌هایی که به صورت غیراصولی گسترش یافته‌اند را به صورت مجزای ناحیه‌بندی کرده و سپس نشت موجود در هر ناحیه را با دقت قابل قبولی ارائه دهد.

پی‌نوشت‌ها

- 1- Tracer Gas Technique
- 2- Ground Penetrating Radar (GPR)
- 3- Artificial Neuro-Fuzzy System
- 4- Bayesian Classifiers
- 5- District Metered Areas
- 6- Night Flow
- 7- Minimum Night Flow

- Shekofteh MR and Jalili Ghazizadeh MR (2019) The optimized implementation of the District Metered Areas in the water distribution networks using graph theory. *Journal of Water and Wastewater* (parallel title); Ab va Fazilab (In Persian)
- Shekofteh MR, Jalili Ghazizadeh MR, and Yazdi J (2018) Finding the leakage zones in district metered areas (DMAs) of water distribution networks. *Isfahan University of Technology, Isfahan, Iran* (In Persian)
- Soldevila A, Fernandez-Canti RM, Blesa J, Tornil-Sin S, and Puig V (2017) Leak localization in water distribution networks using Bayesian classifiers. *Journal of Process Control* 55:1-9
- Tzatchkov VG, Alcocer-Yamanaka VH, and Bourguett Ortíz V (2008) Graph theory based algorithms for water distribution network sectorization projects. *Eighth Annual Water Distribution Systems Analysis Symposium (WDSA)* pp. 1-15
- Wachla D, Przystalka P, and Moczulski W (2015) A method of leakage location in water distribution networks using artificial neuro-fuzzy system. *IFAC-PapersOnLine* 48(21):1216-1223
- Wu ZY and Sage P (2008) Water loss detection via genetic algorithm optimization-based model calibration. *Eighth Annual Water Distribution Systems Analysis Symposium (WDSA)* pp. 1-11
- burst detection. *Journal of Water Resources Planning and Management* 144(7):04018031
- Newman ME and Girvan M (2004) Finding and evaluating community structure in networks. *Physical Review* 69(2):026113
- Puust R, Kapelan Z, Savic D, and Koppel T (2010) A review of methods for leakage management in pipe networks. *Urban Water Journal* 7(1):25-45
- Qi S, Gao J, Wu W, Qiao Y, Tu M, and Wang J (2014) Research on an optimized leakage locating model in water distribution system. *Procedia Engineering* 89:1569-1576
- Reca J and Martínez J (2006) Genetic algorithms for the design of looped irrigation water distribution networks. *Water Resources Research* 42(5)
- Reca J, Martínez J, Gil C, and Baños R (2008) Application of several meta-heuristic techniques to the optimization of real looped water distribution networks. *Water Resources Management* 22(10):1367-1379
- Report (2018) Report from office of Basic Water Resources Studies, 2018, website:<http://wrs.wrm.ir/m3/gozaresh.asp> (In Persian)
- Rossman LA (2000) EPANET 2: Users Manual.