

Research Paper

Pipe Failure Rate Prediction In Water Distribution Networks Using RCNN-SVR and FCMR Methods

Ahmad Ravanbakhsh¹, Mehdi Momeni^{1*}, Amir Robati¹

1. Department of Civil Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran

Received: 2021/03/11

Revised: 2021/05/18

Accepted: 2021/06/29

Use your device to scan and read the article online



DOI:

[10.30495/wej.2021.27427.2301](https://doi.org/10.30495/wej.2021.27427.2301)

Key words:

water distribution network, pipe burst, artificial intelligence, fuzzy, burst rate

Abstract

Introduction: It is essential to optimize repair, reconstruction and rehabilitation programs of urban water distribution networks for the correct use of limited water resources. The aim of the present study is to implement and compare two artificial intelligence methods to predict the burst rate of water pipes.

Methods: In this article, dataset of the pipe bursts in Joopar water network from 2012 to 2017 has been collected. The parameters for predicting of pipe failure includes: material, age, diameter, water pressure and installation depth, and the correlation coefficient of these parameters with the failure rate has been investigated. In order to predict the failure rate, convolution neural network with support vector machine (RCNN-SVR) and fuzzy regression based on c mean clustering (FCMR) have been used. To compare the performance of these two methods, the criteria such as Root-Mean Squared Error (RMSE), Index Of Agreement (IOA), Mean Absolute Percentage Error (MAPE), and coefficient of determination (R^2) have been used.

Findings: According to the evaluations, RCNN-SVR method compared to FCMR method shows excellent results. Also, the correlation between age and failure rate in asbestos pipes is high and in polyethylene pipes this value is positive but low. The correlation coefficient between pressure and failure rate is also positive for both pipe types.

Citation: Ravanbakhsh A, Momeni M, Robati A. Pipe Failure Rate Prediction In Water Distribution Networks Using RCNN-SVR and FCMR Methods. Water Resources Engineering Journal. 20254; 16(59): 11-24.

***Corresponding author:** Mehdi Momeni

Address: Department of Civil Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran

Tell: +989131424830

Email: zimaraz.pars1387@gmail.com

Extended abstract

Introduction

Water distribution networks (WDNs) are critical infrastructures. The objective of WDNs is to provide water with desirable quantity, quality and pressure for the consumers. However, in case of pipe failure which is the progressive effect of physical, operational and weather-related factors, might fail the WDN to achieve these goals. Pipe burst prediction helps to prioritize the maintenance, repair, rehabilitation and replacement of pipes after assessing and forecasting pipe propensity to burst. In addition, pipe burst prediction can be used for budget allocation and cost analysis of dynamic or static designing of water distribution networks. The goal of any data analysis is to extract accurate estimation from the raw information. One of the most substantial and typical issues is whether there is statistical relationship between a response variable and explanatory variables. One way to answer this issue is to employ regression analysis in order to model its relationship.

Materials and Methods

In order to implement the regression models, six different input variables consist of pipe diameter, length, age, depth of installation, average and maximum hydraulic pressure have been used. Two multivariate regression models for pipe failure prediction such as FCMR and RCNN-SVR will be implemented and discussed. Fuzzy c-means regression (FCMR) is an extension of fuzzy c-means approach which is one of the most popular clustering methods. It performs classification based on the iterative minimization of an objective function and constraints. The membership values are initialized randomly and both these and the cluster centers are iteratively updated until the maximum change in membership values becomes less than or equal to a specified threshold. The cluster center and membership values are then iteratively updated until either the maximum number of iterations or threshold is reached. Finally, the weighted least square is used for regression model, in which

weights are membership values of train data and for each cluster, regression coefficients are calculated.

RCNN-SVR has two main steps, the feature extraction step in RCNN model, and predicting step in SVR model. The feature extraction is performed by three convolution layers, and three max pooling layers, one rectified linear unit layer, and one normalization layer. The prediction step consists of a fully-connected layer and a regression layer. Convolutional layers apply sliding convolutional filters to the input. The layers convolve the input by moving the filters along the input vertically and horizontally and computing the dot product of the weights and the input, and then adding a bias term. A max pooling layer performs down-sampling by dividing the input into rectangular pooling regions, and computing the maximum of each region. Finally, a channel-wise local response normalization layer carries out channel-wise normalization. In prediction stage the SVR uses features which extracted from RCNN.

Findings

The WDN of Joopar city is selected as the case study for pipe failure prediction and has an area of 12 Km² and covers 2622 water subscribers with 51.6 km of water distribution pipes. The network with a lifespan of more than 50 years, was built in the early days with asbestos cement pipes and developed with polyethylene. In this case study, 158 cases of pipe failure for polyethylene (PE) pipes with diameters of 29.4–101.4 mm and 124 cases for asbestos cement (AC) pipes with diameters of 100–200 mm have been used as regression model datasets which have been collected by author during 2012-2019. As mentioned, diameter, length, installation depth, age, maximum and average hydraulic pressure of pipes are considered as the main variables that influence the PBR of pipes. The linear relationship of the collected data is measured with the Pearson correlation coefficients. As can be seen from the obtained results, it is evident that there is a correlation between PBR and the pipe burst variables. A higher PBR values obtained with the higher average or maximum pressure of

PE pipes. Conversely, increase in the values of length, diameter and depth of PE pipes decrease the corresponding values of PBR. It is worth mentioning that the development of the WDN of Joopar city was performed with PE pipes, which have a resistance near existing pressure in the network. So, it is expected to have low correlation between age and high correlation between pressure and PBR. On the other hand, as represented results show, there is a negative correlation coefficient between diameter and PBR. Based on local investigations, it has been found that old asbestos cement pipes can bear a pressure more than the present pressure in the network. Findings show there is a strong positive correlation between age and PBR because of aged pipes, verifying that by increasing the age of pipes, PBR will increase. Also, it can be seen that there is a positive correlation coefficient between both P_{avg} and P_{max} and PBR. According to the mentioned regression techniques, data-driven pipe burst models were set up for the asbestos cement and polyethylene pipes in Joopar WDN. According to the calculated values, the RCNN-SVR model, with a relatively long computational time, is the most accurate burst rate predictor of pipes. According to authors' knowledge, implementing the RCNN-SVR model for PBR prediction has not been reported yet.

Discussion and Conclusion

In this paper we compared and evaluated two artificial intelligence and machine learning methods, Fuzzy regression based on c-means clustering (FCMR) and regressive convolution neural network with support vector regression (RCNN-SVR) for pipe failure prediction and implemented them in Joopar WDN as a real case study. Models were setup based on pipes age, diameter, length, installation depth, maximum and average hydraulic pressure of pipes as the input variables and pipe burst rate (PBR) as model output. Models performance has been compared with error assessment criteria such as Root-Mean Squared Error (RMSE), Index Of Agreement (IOA), Mean Absolute Percentage Error

(MAPE), and coefficient of determination (R^2). Findings show that RCNN-SVR is the most accurate prediction model, which has the lowest values of RMSE and MAPE which can effectively predict the burst rate. The analyses show that there is positive correlation between pressure and PBR for PE and AC pipes.

Ethical Considerations compliance with ethical guidelines

The cooperation of the participants in the present study was voluntary and accompanied by their consent.

Funding

No funding.

Authors' contributions

Design and conceptualization: Ahmad Ravanbakhsh, Mehdi Momeni.
Methodology and data analysis: Ahmad Ravanbakhsh, Mehdi Momeni.
Supervision and final writing: Ahmad Ravanbakhsh, Mehdi Momeni, Amir Robati.

Conflicts of interest

The authors declared no conflict of interest.

مقاله پژوهشی

پیش بینی نرخ شکست لوله ها در شبکه های توزیع آب با استفاده از روش های RCNN-SVR و FCMR

احمد روان بخش^۱، مهدی مومنی^{۱*}، امیر رباطی^۱
 ۱. گروه مهندسی عمران، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران

چکیده

مقدمه: بهینه سازی برنامه های اصلاح، بازسازی و نوسازی شبکه های آب شهری به منظور استفاده صحیح از منابع محدود آب امری ضروری است. هدف از تحقیق حاضر پیاده سازی و مقایسه دو روش هوش مصنوعی به منظور پیش بینی نرخ شکست لوله های آب می باشد.

روش: در این مقاله، اطلاعات اتفاقات شبکه آب شهر جوپار از سال ۱۳۹۱ تا ۱۳۹۸ جمع آوری شده است. پارامترهای بررسی شده در شکست لوله ها شامل جنس، سن، قطر، فشار آب و عمق نصب بوده که ضریب همبستگی این پارامترها با نرخ شکست بررسی گردیده است. به منظور پیش بینی نرخ شکست، از روش های شبکه عصبی کانولوشن با ماشین بردار پشتیبان (RCNN-SVR) و رگرسیون فازی براساس خوشه بندی میانگین c (FCMR) استفاده شده است. جهت مقایسه عملکرد دو روش نیز از معیارهای میانگین مربعات خطا، درصد خطای میانگین مطلق، شاخص تطابق و ضریب تعیین بهره گرفته شده است.

یافته ها: با توجه به ارزیابی صورت گرفته، روش RCNN-SVR نسبت به روش FCMR نتایج بسیار مناسبی را نشان می دهد. همچنین همبستگی بین سن و نرخ شکست در لوله های آریست بالا بوده و در لوله های پلی اتیلن این مقدار مثبت ولی کم می باشد. ضریب همبستگی بین فشار و نرخ شکست نیز برای هر دو جنس لوله مثبت است.

نتیجه گیری: RCNN-SVR مدل پیش بینی دقیق تری را نسبت به FCMR ارائه داده و خطای کمتری دارد. لذا این روش می تواند به طور موثر نرخ شکست لوله ها را پیش بینی نماید.

تاریخ دریافت: ۱۳۹۹/۱۲/۲۱

تاریخ داوری: ۱۴۰۰/۰۲/۲۸

تاریخ پذیرش: ۱۴۰۰/۰۴/۰۸

از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید



DOI:

[10.30495/wej.2021.27427.2301](https://doi.org/10.30495/wej.2021.27427.2301)

واژه های کلیدی:

شبکه توزیع آب، شکست لوله، هوش مصنوعی، فازی، نرخ شکست

* نویسنده مسئول: مهدی مومنی

نشانی: گروه مهندسی عمران، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران.

تلفن: ۰۹۱۳۱۴۳۴۸۳۰

پست الکترونیکی: zimaraz.pars1387@gmail.com

مقدمه

مناسی برای مدل سازی و پیش بینی نرخ شکست لوله ها هستند. در سال های اخیر کاربرد شبکه های عصبی مصنوعی در زمینه های مختلف افزایش یافته است. مرور ادبیات فنی نیز نشان می دهد کاربرد این نوع سامانه ها در پیش بینی شکست لوله ها نیز موفقیت آمیز بوده است.


اثنی عشری در سال ۲۰۰۷ با در نظر گرفتن متغیرهای سن، جنس، طول، قطر، ضخامت، عمق لوله، فشار هیدرولیکی (حداکثر)، بار ترافیک و تعداد شکستگی های قبلی از مدل شبکه عصبی مصنوعی چند لایه و مدل رگرسیون (پواسون چند متغیره) برای پیش بینی تعداد شکست لوله های اصلی استفاده نموده است (۴). در سال ۱۳۹۱ سلطانی و محمدرضاپور طبری به منظور تعیین پارامترهای ورودی مؤثر در نرخ شکست و همچنین تعیین مناسب ترین پارامترهای مرتبط با ساختار شبکه عصبی به تلفیق الگوریتم بهینه سازی ژنتیک با شبکه عصبی پرداختند (۵). در سال ۲۰۰۴ واتسون و همکاران تأثیر عواملی نظیر طول، قطر، جنس، زمان نصب لوله و فشار هیدرولیکی را بر روی شکست لوله در نظر گرفته و یک مدل بیزی سلسله مراتبی برای پیش بینی نرخ شکست لوله ارائه کردند (۲). در سال ۲۰۰۹ دریدی و همکاران با استفاده از سامانه استنتاج بیزی به مدل سازی پدیده شکست لوله ها پرداخته اند. آن ها فاصله زمانی بین شکست های متوالی لوله ها را به صورت یک متغیر تصادفی با توزیع احتمال ویبول-نمایی در نظر گرفته اند. بدین صورت که برای فاصله زمانی بین نصب لوله و وقوع اولین شکست از توزیع ویبول و برای فاصله زمانی شکست های بعدی از توزیع نمایی استفاده کردند (۶). روزبهانی در سال ۱۳۹۱ نیز از شبکه بیزین فازی برای پیش بینی شکست لوله های شبکه توزیع آب و تحلیل ریسک استفاده کرده است. وی پارامترهایی نظیر سن لوله، جنس لوله، قطر لوله، طول لوله و زمان شکست قبلی لوله را برای مدل سازی پدیده شکست لوله مد نظر قرار داده است (۷). همچنین مدل سازی فیزیکی (۸)، رگرسیون انطباق پذیر چند متغیره (۹)، شبکه های عصبی مصنوعی (۱۰ و ۱۱)، ماشین های بردار پشتیبان (۱۲)، منطق فازی (۱۳)، سیستم های عصبی-فازی (۱۴ و ۱۵)، رگرسیون چند جمله ای تکاملی (۱۶) در زمینه مدل سازی شکست لوله های شبکه های آب استفاده شده است.

کنستانینو و استویانوف یک مطالعه مقایسه ای از روش های یادگیری ماشین و آماری را برای انجام تجزیه و تحلیل اکتشافی جهت پیش بینی شکست لوله در یک شبکه تامین آب ارائه داده اند. همچنین در این مقاله، مدل های رگرسیونی برای داده های آماری و مدل های احتمالی توسعه داده شده است. در این گزارش، عملکرد این مدل ها با معرفی تعاملات و گنجاندن بازنمایی های مختلف شبکه ارزیابی و بهبود پیدا کرده است (۱۷). در مقاله اسنایدر و مکین، به منظور مقایسه پیش بینی شکست لوله از دو روش مدل سازی آماری یادگیری ماشین و الگوریتم های تحلیل بقا استفاده شده است. مدل یادگیری ماشین از درخت تصمیم افزایش گرادیان و یک مدل تحلیل متناسب برای پیش بینی زمان شکست بعدی لوله های چدنی در یک سیستم توزیع آب کانادا استفاده می کند. نتایج نشان می دهند که حذف رویداد از مدل یادگیری ماشین، جهت مناسبی به مدل برای پیش بینی شکست های اولیه لوله می دهد. همچنین توانایی مدل تحلیل بقا برای ترکیب

شبکه های آب رسانی با عناصر هیدرولیک بهم پیوسته، وظیفه توزیع و عرضه آب را برای برآورده کردن تقاضا تحت فشار و کیفیت مطلوب برعهده دارند. این شبکه ها یکی از اساسی ترین اجزای زیرساخت صنایع مختلف و بخش جدایی ناپذیر جوامع بشری هستند و کاربرد وسیع آن ها در صنایع، کشاورزی و همچنین تأمین آب شرب مورد نیاز شهرها و روستاها انکارناپذیر است. یکی از مهم ترین چالش های صنعت آب، فرسودگی لوله ها و همچنین محدودیت بودجه در دسترس است که اهمیت بهینه سازی برنامه های اصلاح، بازسازی و نوسازی شبکه توزیع آب را بیش از پیش افزایش داده است. طبق گزارش انجمن مهندسی عمران آمریکا (۱)، قدمت بهره برداری برخی از اجزای سیستم انتقال آب در ایالات متحده و اروپا بیش از ۱۰۰ سال است. بنا به این گزارش، در شبکه آب ایالات متحده تقریباً ۲۴۰,۰۰۰ حادثه شکستگی در هر سال وجود دارد که منجر به هدررفت ۱۰ تا ۳۰ درصدی آب شده است. در حالی که اخیراً در انگلیس این مقدار ۲۵ درصد تخمین زده شده است (۱). همچنین پیش بینی شده است که بیش از ۱ میلیون مایل از شبکه های آب ایالات متحده نیاز به تعویض دارند که هزینه ای بالغ بر ۱ تریلیون دلار در ۲۵ سال آینده را برای حفظ و گسترش خدمات تأمین آب شرب در بر می گیرد. تعویض این لوله های فرسوده نیز با توجه محدودیت منابع مالی و نیاز به مدیریت کارآمد زیرساخت های شبکه های آب، چالش برانگیز اما ضروری است.

نظر به اینکه شبکه های توزیع آب در زیر خاک مدفون بوده و لوله ها به علت رفتار دینامیکی شان به طور تدریجی در طول زمان خراب می شوند و امکان پایش بصری و مستقیم آنها نیز وجود ندارد، لذا نگهداری از آنها مشکل بوده و معایب آن ها تا حد بحرانی پنهان مانده و تنها با وقوع حادثه نمایان می شود (۲). تاکنون تحقیقات زیادی در زمینه مدل سازی شکست خطوط لوله آب صورت گرفته است که می توان آن ها را به دو دسته اصلی مدل سازی فیزیکی و آماری تقسیم بندی نمود (۳). مدل سازی های فیزیکی با تحلیل بارهای وارده به لوله و ظرفیت باربری لوله، به پیش بینی شکست لوله می پردازند. در این مدل ها دامنه و شدت خوردگی در دیواره داخلی و خارجی لوله ارزیابی شده و تنش های ناشی از بارهای وارده به لوله تخمین زده می شود. چندین مؤلفه نظیر تنش های خارجی و داخلی ناشی از فشار خاک، ترافیک، یخبندان، فشار هیدرولیکی و غیره باید در مدل سازی رفتار سازه ای لوله در نظر گرفته شود. مدل های فیزیکی ارائه شده برای پیش بینی خرابی لوله پیچیده و گران قیمت هستند و در بخش محدودی از لوله ها قابل اعمال است. اما مدل های آماری بر اساس داده های تاریخی، هزینه کمتری داشته و کاربردهای بسیار زیادی دارند. امروزه در مدل سازی های آماری، سامانه های هوش مصنوعی شامل شبکه های عصبی مصنوعی، نروفازی و غیره با پردازش داده های تجربی، می توانند روابط بسیار پیچیده حاکم بر پدیده ها را کشف کنند. از آنجا که پدیده شکست لوله ها نیز بسیار پیچیده بوده و تابع عوامل زیادی است، لذا این نوع سامانه ها ابزار

ژانگ و لی در سال ۲۰۱۹ یک مدل جدید شبکه عصبی کانولوشن را پیشنهاد داده اند. در این مدل، شبکه عصبی کانولوشن با ماشین بردار پشتیبان ترکیب و مدل RCNN-SVR پیشنهاد شده است. این ساختار دارای دو مرحله اصلی است که شامل مرحله استخراج ویژگی ها توسط مدل شبکه عصبی و مرحله پیش بینی توسط ماشین بردار پشتیبان می باشد (۲۰). استخراج ویژگی ها توسط سه لایه کانولوشن (Conv3)، سه لایه (Conv1, Conv2, Maxpool1, Maxpool3)، سه لایه (Maxpool2, ReLU) و یک لایه نرمالیزه کننده (Norm) صورت می پذیرد. مرحله پیش بینی نیز شامل یک لایه تماما متصل ۴ و یک لایه رگرسیون ماشین بردار پشتیبان است. ساختار این شبکه در شکل (۱) نشان داده شده است. لایه های کانولوشن فیلترهای کانولوشن را به ورودی اعمال کرده و با اعمال فیلترها به صورت عمودی و افقی و محاسبه ضرب نقطه ای اوزان و ورودی، و جمع حاصل با یک مقدار بایاس، ورودی را به لایه های بعدی متصل می کنند. لایه های maxpool نیز صرفا یک نمونه برداری ساده و موثر انجام می دهند. این لایه ها با تقسیم ورودی به نواحی مستطیل شکل و محاسبه حداکثر مقدار در هر ناحیه، نمونه برداری را انجام می دهند. لایه ReLU نیز وظیفه فعال سازی لایه های مخفی را بر عهده دارد که یک عملیات آستانه را برای هر عنصر ورودی انجام می دهد. در این تابع، اگر فرضا مقدار X بزرگتر از صفر باشد، خروجی X است و اگر مقدار X کوچکتر یا مساوی صفر باشد، خروجی صفر است. مزیت اصلی استفاده از ReLU این است که تمام ورودی های بزرگتر از صفر، یک مشتق ثابت دارند که به یادگیری شبکه سرعت می بخشد. در مرحله بعد، لایه تماما متصل از ضرب ماتریسی و جمع نتیجه حاصل شده با بایاس جهت محاسبه خروجی استفاده می نماید. در نهایت رگرسیون ماشین بردار پشتیبان (SVR) از ویژگی های استخراج شده از RCNN استفاده می نماید.



شکل ۱- ساختار شبکه عصبی کانولوشن و ماشین بردار پشتیبان (RCNN-SVR)

ماشین های بردار پشتیبان نیز (۲۱، ۲۲ و ۲۳) مدل های یادگیری نظارت شده به همراه الگوریتم های آموزش مربوطه هستند. ایده اساسی ماشین بردار پشتیبان بر مبنای ساختار یک ابرصفحه بهینه می باشد که بهترین جداسازی را برای دو کلاس را ایجاد می کند. این روش با استفاده از نگاشت غیرخطی، داده ها را در یک فضای مشخصه با ابعاد بالا ترسیم نموده و رگرسیون خطی را در این فضا انجام می دهد. لذا داریم:

$$f(x) = W^T \varphi(x) + b \quad (2)$$

داده های حذف شده، آن را برای برنامه ریزی مدیریت سرمایه بلند مدت مناسب تر می سازد (۱۸). ژو و همکاران نیز نشان داده اند مکان دقیق شکست لوله را حتی با عدم قطعیت های بالا می توان به دست آورد. این چارچوب برای یک شبکه واقعی نیز به کار گرفته شد، که در آن ۵۷ مورد از ۵۸ شکست به درستی مکان شکست را نشان داده است. در این بین، تنها یک مورد به دلیل قطر بسیار کوچک لوله و موقعیت دوردست، اشتباه بود. مقایسه با شبکه عصبی خطی نشان می دهد که این چارچوب می تواند به طور موثر منطقه شکست را به یک یا چند لوله محدود کند (۱۹).

در تحقیق حاضر، ضمن گردآوری اطلاعات هشت ساله حوادث شهر جوپار، مدل های هوش مصنوعی RCNN-SVR^۱ و FCMR^۲ به منظور تخمین نرخ شکست سالانه لوله های آب معرفی شده است. طول لوله (L)، قطر (Dim)، فشار هیدرولیکی متوسط (Pa)، حداکثر فشار هیدرولیکی (Pm)، سن (A) و عمق نصب (ID) نیز پس از آنالیز همبستگی پیرسون با نرخ سالانه شکست لوله (PBR^۳) به عنوان ورودی مدل های رگرسیون در نظر گرفته شده اند. نتایج حاصل از این روش ها با استفاده از چند معیار ارزیابی مقایسه شده است. نتایج حاصل از این تحقیق در مدیریت بهینه بهره برداری شبکه های توزیع آب شهری کاربرد داشته و باعث بهبود آن می گردد.

مواد و روش ها

استفاده از رگرسیون های چند متغیره برای پیش بینی نرخ شکست لوله های شبکه توزیع آب، به لحاظ لزوم در نظر گرفتن عوامل متعددی است که در شکست لوله های آب موثر هستند تا بتوان مدل سازی جامع تر و دقیق تری را انجام داد. در این مطالعه نرخ شکست سالانه (PBR) به عنوان متغیر وابسته (خروجی) و عوامل مؤثر در شکست لوله ها نظیر طول (L)، قطر (Dim)، فشار هیدرولیکی متوسط (Pa)، حداکثر فشار هیدرولیکی (Pm)، سن (A) و عمق نصب (ID) به عنوان متغیرهای مستقل (ورودی) در نظر گرفته شده است. مقدار PBR با استفاده از رابطه زیر محاسبه می شود:

$$PBR = \frac{\text{تعداد شکست سالانه لوله}}{\text{طول لوله (Km)}} \quad (1)$$

داده های جمع آوری شده به صورت تصادفی به دو دسته آموزش و آزمون تقسیم شده اند به طوری که ۸۰ درصد داده ها به منظور آموزش و مابقی برای آزمون مدل ها استفاده می شوند. با استفاده از مجموعه داده های آزمون، عملکرد مدل ها ارزیابی می شود. به منظور بررسی مناسب بودن ورودی های انتخابی نیز، یک تجزیه و تحلیل مقدماتی به صورت بررسی همبستگی نرخ شکست و متغیرهای ورودی، روی داده های جمع آوری شده انجام شده است.

روش RCNN-SVR

۴ Fully Connected layer (FC)

1 Regressive Convolution Neural Network and Support Vector

2 Fuzzy C-Means Regression

3 Pipe Burst Rate

رگرسیون استفاده می شود. که در آن وزن، مقادیر عضویت داده ها برای هر خوشه است. به این ترتیب ضرایب رگرسیون (β) برای هر خوشه به صورت زیر محاسبه می شود:

$$\beta_i = (X^T W_i X)^{-1} \cdot X^T W_i Y \quad (9)$$

که در آن $W_i = \text{diag}\{\mu_i\}$ برای داده های آموزش بوده و با محاسبه $\mu_{i,j}$ برای داده های تست، مقدار پیش بینی محاسبه می گردد:

$$y_{pre}(j) = \sum_{i=1}^c \mu_{i,j} \cdot x_{test}(j) \cdot \beta_i \quad (10)$$

که در آن $x_{test}(j)$ برای مشاهده j ام به صورت زیر می باشد:

$$x_{test}(j) = [1 \ X_{11} \ \dots \ X_{1p}] \quad (11)$$

معیارهای ارزیابی

در این مطالعه عملکرد مدل ها با استفاده از میانگین مربعات خطا (RMSE)، درصد خطای میانگین مطلق (MAPE)، شاخص تطابق (IOA) و ضریب تعیین (R^2) ارزیابی می شود که به صورت زیر تعریف می شوند:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (PBR_i^{obs} - PBR_i^{pre})^2} \quad (12)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{PBR_i^{pre} - PBR_i^{obs}}{PBR_i^{obs}} \right| \quad (13)$$

$$IOA = 1 - \frac{\sum_{i=1}^n (PBR_i^{obs} - PBR_i^{pre})^2}{\sum_{i=1}^n (|PBR_i^{pre} - PBR_i^{obs}| + |PBR_i^{obs} - PBR_i^{pre}|)^2} \quad (14)$$

$$R^2 = \frac{(\sum_{i=1}^n (PBR_i^{obs} - \overline{PBR^{obs}})(PBR_i^{pre} - \overline{PBR^{pre}}))^2}{\sum_{i=1}^n (PBR_i^{obs} - \overline{PBR^{obs}})^2 \sum_{i=1}^n (PBR_i^{pre} - \overline{PBR^{pre}})^2} \quad (15)$$

در روابط فوق، n تعداد کل نمونه ها، PBR^{obs} نرخ شکست مشاهده شده، PBR^{pre} نرخ شکست پیش بینی شده، $\overline{PBR^{obs}}$ میانگین نرخ خطاهای مشاهده شده، $\overline{PBR^{pre}}$ میانگین نرخ خطاهای پیش بینی شده، $\text{var}(PBR^{obs})$ واریانس نرخ خطای مشاهده شده است.

مطالعه موردی: شبکه آب شهر جویبار

در این مقاله، شبکه توزیع آب شهر جویبار به عنوان مطالعه موردی برای پیش بینی خرابی لوله انتخاب شده است. شهر جویبار با ارتفاع ۱۹۴۰ متر در حدود ۲۵ کیلومتری جنوب کرمان واقع شده است. مساحت این شهر ۸ کیلومتر مربع است و ۲۶۲۲ مشترک آب را با ۵۱/۶ کیلومتر لوله توزیع پوشش می دهد. در این مطالعه ۱۵۸ مورد خرابی لوله برای لوله های پلی اتیلن (PE) با قطر ۱۰۱/۴-۲۹/۴ میلی متر و ۱۲۴ مورد برای لوله های سیمان آریست (AC) با قطر ۲۰۰-۱۰۰ میلی متر استفاده شده است که توسط نویسنده طی سال های ۱۳۹۱ الی ۱۳۹۸ جمع آوری شده است. همان گونه که بیان شد، قطر، طول، عمق نصب، سن، فشار هیدرولیکی حداکثر و متوسط لوله ها به عنوان متغیرهای اصلی اثرگذار بر نرخ شکست لوله ها در نظر گرفته می شوند. شکل های ۲ و

که در آن W با به حداقل رساندن تابع هدف مقید زیر به دست می آید:

$$\min \zeta(W, \xi) = \frac{1}{2} W^T W + \gamma \frac{1}{2} \xi^T \xi \quad (3)$$

$$\text{s. t. } y = Z^T W + b1_1 + \xi$$

در این رابطه l تعداد مشاهدات است، $Z = (\varphi(x_1), \varphi(x_2), \dots, \varphi(x_l))$ (شاید بی نهایت) هیلبرت (\mathcal{H}) است. همچنین $\xi = (\xi_1, \xi_2, \dots, \xi_l)^T$ و γ یک عدد حقیقی مثبت است. برای حل این مسئله بهینه سازی، تابع لاگرانژ به صورت رابطه ۳ نوشته شده و با محاسبه مشتقات نسبت به α, ξ, b و W مسئله حل می شود.

$$\mathcal{L}(W, b, \xi, \alpha) = \zeta(W, \xi) - \alpha^T (Z^T W + b1_1 + \xi - y) \quad (4)$$

در این مقاله، الگوریتم RCNN-SVR با استفاده از تولباکس شبکه عصبی و رگرسیون ماشین بردار پشتیبان در محیط نرم افزار متلب R2019b کدنویسی شده است.

روش FCMR

مدل رگرسیون فازی (FCMR) توسط Bezdek و Hathaway در سال ۱۹۳۳ معرفی شد (۲۴). این روش گسترش رویکرد میانگین c در تئوری فازی است که یکی از محبوب ترین روش های خوشه بندی است. این طبقه بندی بر اساس به حداقل رساندن تکراری تابع هدف و محدودیت های زیر صورت می پذیرد: (۲۵، ۲۶ و ۲۷):

$$J_q(\mu, V, X) = \sum_{i=1}^c \sum_{j=1}^n (\mu_{i,j})^q D_{i,j}^2 \quad (5)$$

به قسمی که:

$$\begin{aligned} 0 &\leq \mu_{i,j} \leq 1 \\ \sum_{i=1}^c \mu_{i,j} &= 1 \\ \sum_{j=1}^n \mu_{i,j} &< 0 \\ \sum_{j=1}^n \mu_{i,j} &< n \end{aligned} \quad (6)$$

که $\{1, \dots, c\}$ ، $i \in \{1, \dots, n\}$ و $j \in \{1, \dots, n\}$ تعداد داده ها، c تعداد خوشه ها، μ ماتریس عضویت فازی، V بردار مرکز خوشه ها، q عدد حقیقی مثبت و $D_{i,j}$ فاصله بین داده i و مرکز خوشه j می باشد. با تشکیل تابع لاگرانژ V و μ به صورت زیر بیان می شوند:



$$\mu_{i,j} = \frac{1}{\sum_{k=1}^c \left(\frac{D_{i,j}}{D_{k,j}} \right)^{\frac{2}{q-1}}} \quad (7)$$

$$V_i = \frac{\sum_{j=1}^n [(\mu_{i,j})^q x_j]}{\sum_{j=1}^n (\mu_{i,j})^q} \quad (8)$$

برای کمینه سازی تابع هدف رابطه (۵)، ابتدا ماتریس μ به صورت تصادفی مقدار دهی شده و سپس مراکز خوشه ها محاسبه می گردند. این مراکز و خوشه ها به طور تکراری به روز می شوند تا اینکه حداکثر تغییر در $\mu_{i,j}$ کمتر یا برابر آستانه مشخص شده (۸) باشد (۲۸). در نهایت با داشتن ماتریس عضویت، از حداقل مربعات وزن دار^۱ برای مدل


¹ weighted least square

۳ شبکه توزیع آب شهر جوپار و شکل ۴ نمایشی گرافیکی این ویژگی ها را برای هر دو نوع لوله به تصویر می کشد.

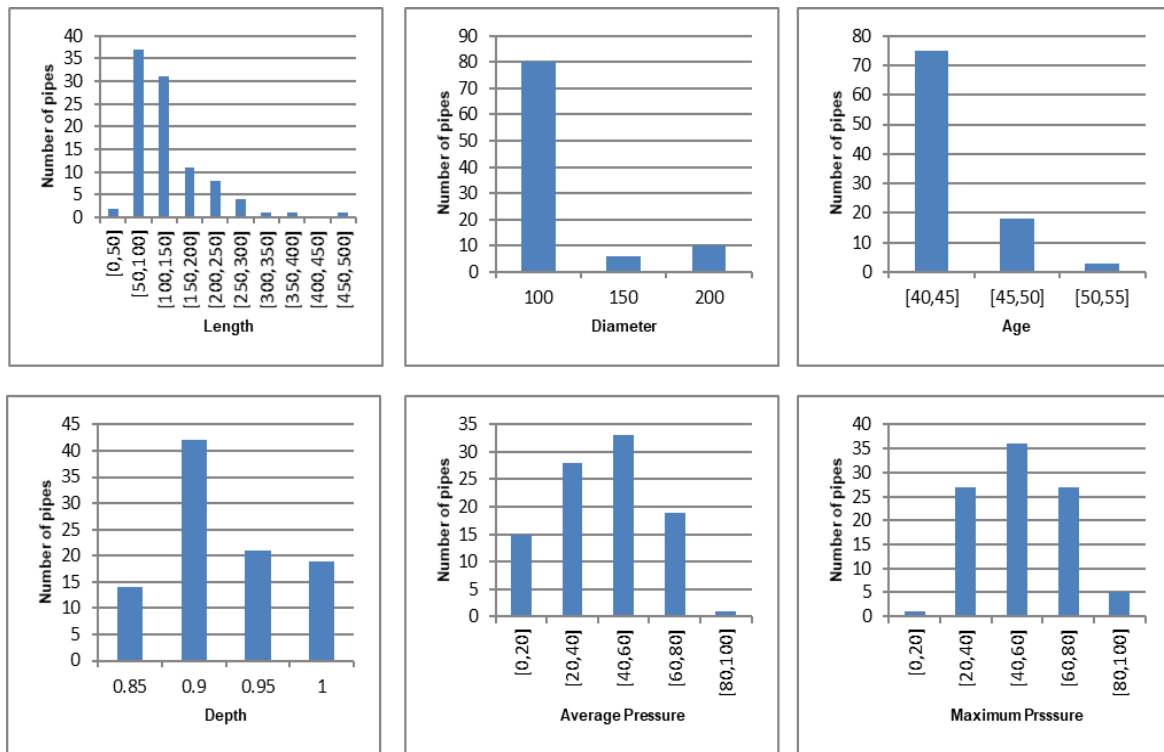


شکل ۳- مدل WaterGEMS شبکه آب شهر جوپار(خطوط آبی برای لوله های PE و خطوط قرمز برای لوله های AC)

شکل ۲- تطابق شبکه توزیع آب شهر جوپار با نقشه گوگل



(الف)



شکل ۴- نمایشی گرافیکی ویژگی لوله ها (الف) آزیست (ب) پلی اتیلن

بودن لوله ها ضریب همبستگی مثبتی وجود دارد و تأیید میکند که با افزایش سن لوله ها، PBR افزایش می یابد. همچنین دیده میشود که بین PBR و Pmax و Pavg ضرایب همبستگی مثبت وجود دارد. طبق رابطه محاسبه نرخ شکست سالانه، PBR با طول لوله رابطه معکوس دارد و به دلیل تغییر کم آمار خرابی با طول در طول دوره بررسی، همبستگی منفی زیادی در لوله های PE و AC با PBR مشاهده می شود.


بحث و نتیجه گیری

در جدول ۱ ضرایب همبستگی پیرسون بر روی داده های جمع آوری شده محاسبه شده است. ضرایب همبستگی به ارتباط خطی دو متغیر اشاره دارد و بین هر متغیر ورودی و نرخ شکست سالانه لوله محاسبه شده است. از نتایج مشهود است که بین PBR و متغیرهای شکستگی لوله همبستگی وجود دارد. به طوری که به ازای فشار متوسط و حداکثر بالاتر، مقادیر PBR بالاتر برای لوله های PE بدست آمده است. برعکس، افزایش مقادیر طول، قطر و عمق نصب لوله های PE با کاهش مقادیر مربوط به PBR همراه بوده است. لازم به ذکر است که توسعه شبکه آب شهر چوپار با لوله های PE انجام شده است که دارای مقاومت نزدیک به فشار موجود در شبکه هستند. بنابراین انتظار می رود که همبستگی PBR با سن، کم بوده و همبستگی بین فشار و PBR زیاد باشد. همچنین ضریب همبستگی منفی بین قطر و PBR وجود دارد. بر اساس تحقیقات میدانی نیز مشخص شده است که لوله های آزیست قدیمی می توانند فشار بیشتری نسبت به فشار موجود در شبکه تحمل کنند. یافته ها نشان می دهد بین سن و PBR به دلیل قدیمی

جدول ۱- ضرایب همبستگی پیرسون نرخ شکستگی لوله و پارامترهای موثر برای لوله های PE و AC

متغیر های وابسته						ضرایب همبستگی
عمق نصب	سن	فشار بیشینه	فشار متوسط	قطر	طول	
-۰,۲۷۶	۰,۰۳۴	۰,۲۳۰	۰,۲۴۱	-۰,۱۳۰	-۰,۵۶۱	نرخ شکست لوله های PE
۰,۰۶۵	۰,۷۸۲	۰,۱۸۶	۰,۱۶۲	۰,۰۱۲	-۰,۵۷۶	نرخ شکست لوله های AC

در شکل ۵ نتایج جدول ۱ بر روی لوله های PE و لوله های AC به صورت گرافیکی نشان داده شده است.



شکل ۵- ضرایب همبستگی بین نرخ شکست و پارامترهای تاثیرگذار بر شکست برای لوله های PE و AC


طبق بررسی های صورت گرفته توسط نویسنده، پیاده سازی مدل RCNN-SVR تاکنون برای پیش بینی نرخ شکست لوله ها گزارش نشده است.

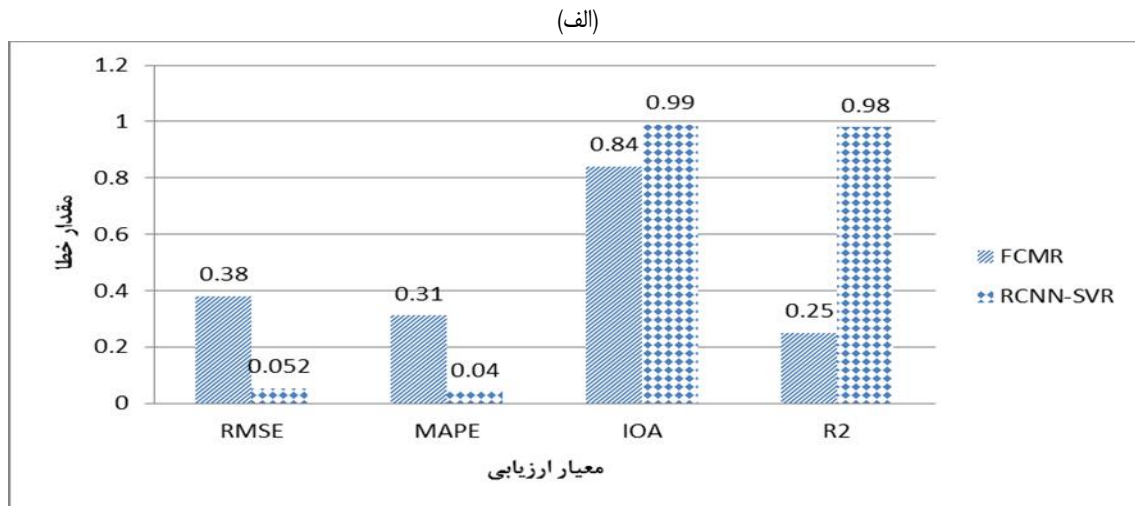
با توجه به تکنیک های رگرسیون ذکر شده برای پیش بینی نرخ شکست لوله های آزیست و پلی اتیلن در شهر جویبار، نتایج مقایسه عملکرد مدل های RCNN-SVR و FCMR در جدول ۲ ذکر شده است. با توجه به مقادیر محاسبه شده، مدل RCNN-SVR، با زمان محاسباتی نسبتاً طولانی تر، دقت پیش بینی بالاتری در تشخیص نرخ شکستگی دارد.

جدول ۲- ارزیابی روش های RCNN-SVR و FCMR بر روی داده های آزمون در مطالعه موردی

معیار ارزیابی	لوله های AC		لوله های PE	
	RCNN-SVR	FCMR	RCNN-SVR	FCMR
RMSE	۰,۰۵۲	۰,۳۸	۰,۰۷۱	۰,۲۰
MAPE	۰,۰۴۰	۰,۳۱	۰,۰۴	۰,۱۴
IOA	۰,۹۹	۰,۸۴	۰,۹۹	۰,۹۶
R ²	۰,۹۸	۰,۲۵	۰,۹۸	۰,۸۶

در شکل ۶ نتایج جدول ۲ بر روی لوله های PE و لوله های AC به صورت گرافیکی نشان داده شده است.



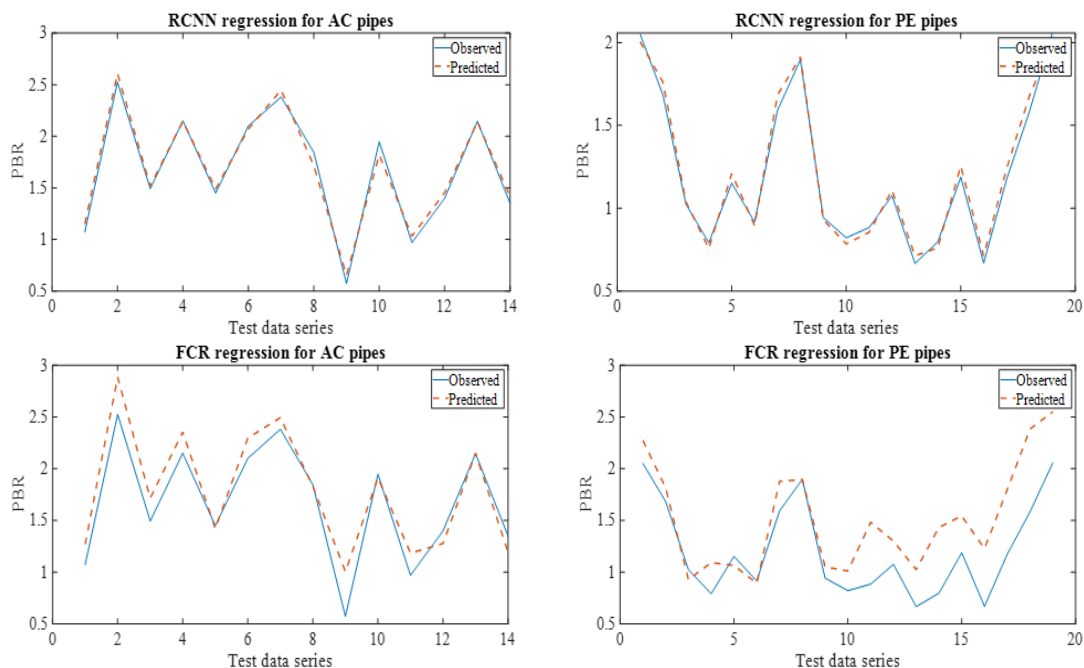


(ب)

شکل ۶- ارزیابی روش های RCNN-SVR و FCMR (الف) مربوط به لوله های AC و (ب) مربوط به لوله های PE در مطالعه موردی

نرخ شکست پیش بینی شده توسط مدل RCNN-SVR سازگاری مناسبی با نرخ شکست مشاهده شده دارد.

شکل ۷ مقادیر اندازه گیری شده و مقادیر پیش بینی شده توسط مدل های رگرسیونی را نشان می دهد. همان گونه که مشخص است مقادیر



شکل ۷- مقایسه نرخ شکست مشاهده شده با مقادیر پیش بینی شده توسط روش های رگرسیون برای مطالعه موردی

واقعی شهر جوپار به عنوان یک مطالعه موردی واقعی استفاده گردید. اطلاعات خرابی لوله ها طی یک دوره هشت ساله جمع آوری شده و شامل ۱۲۴ مورد برای سیمان آریست (AC) و ۱۵۸ مورد برای لوله های پلی اتیلن (PE) به ترتیب با قطر ۲۰۰-۱۰۰ میلی متر و ۱۰/۴-۲۹/۴ میلی متر است. مدل سازی صورت گرفته با در نظر گرفتن سن، قطر، طول، عمق نصب، فشار هیدرولیکی حداکثر و متوسط لوله به عنوان متغیرهای ورودی و نرخ شکستگی لوله (PBR) به عنوان

نتیجه گیری

خرابی لوله ها در شبکه های توزیع آب اجتناب ناپذیر است. پیش بینی شکستگی لوله های آب به بهینه سازی تخصیص بودجه و برنامه ریزی مناسب توسعه و بهره برداری کمک می کند. در این مقاله رگرسیون شبکه عصبی کانولوشن با ماشین بردار پشتیبان (RCNN-SVR) و رگرسیون فازی براساس خوشه بندی میانگین c (FCMR) مقایسه و ارزیابی شده است. برای پیش بینی نرخ شکستگی لوله ها نیز از شبکه

همکاری مشارکت‌کنندگان در تحقیق حاضر به صورت داوطلبانه و با رضایت آنان بوده است.

حامی مالی

هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

مشارکت نویسندگان

طراحی و ایده‌پردازی: احمد روان بخش، مهدی مومنی؛
روش‌شناسی و تحلیل داده‌ها: احمد روان بخش، مهدی مومنی؛
نظارت و نگارش نهایی: احمد روان بخش، مهدی مومنی، امیر رباطی.

تعارض منافع

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.

References

1. ASCE. 2017. 2017 Report Card for America's Infrastructure, Drinking Water. American Society of Civil Engineers.
2. Watson, T. G., C. D. Christian, A. J. Mason, M. H. Smith, and R. Meyer. 2004. Bayesian-Based Pipe Failure Model. *Journal of Hydroinformatics* 6(4):259-64.
3. Pelletier, Geneviève, Alain Mailhot, and Jean-Pierre Villeneuve. 2003. Modeling Water Pipe Breaks—Three Case Studies. *Journal of Water Resources Planning and Management* 129(2):115-23.
4. Asnaashari, A., 2007. Water pipeline failure modeling: statistical, artificial neural network and survival modeling, PhD. Thesis, University of Science and Technology of Lille.
5. Soltani, J and Mohammad Rezapour Tabari, M., 2011. Determination of Effective Parameters in Pipe Failure Rate in Water Distribution System Using the Combination of Artificial Neural Networks and Genetic Algorithm. *Journal of water and wastewater*. [In Persian].
6. Dridi, Leila, Alain Mailhot, Marc Parizeau, and Jean-Pierre Villeneuve. 2009. Multiobjective Approach for Pipe Replacement Based on Bayesian Inference of Break Model Parameters. *Journal of Water Resources Planning and Management* 135(5):344-54.
7. Roozbahani, A., 2012. Risk-based decision making model for urban water systems management . PhD. Thesis, University of Tehran. [In Persian].
8. Randall-Smith, M., A. Russell, and R. Oliphant. 1992. *Guidance Manual for the Structural Condition Assessment of the Trunk Mains*. Swindon, UK: Water Research Centre.
9. Kutylowska, Małgorzata. 2019. Application of MARSplines Method for Failure Rate Prediction. *Periodica Polytechnica Civil Engineering* 63(1):87-92.
10. Achim, D., F. Ghotb, and K. J. McManus. 2007. Prediction of Water Pipe Asset Life Using Neural Networks. *Journal of Infrastructure Systems* 13(1):26-30.
11. Kutylowska, M. 2017. Regression Methods for Predicting Rate and Type of Failures of Water Conduits. *Ecological Chemistry and Engineering A* 24 (2): 193-205.
12. Kutylowska, M. 2019. Forecasting Failure Rate of Water Pipes. *Water Science and Technology: Water Supply* 19(1):264-73.
13. Rajani, B., and S. Tesfamariam. 2007. Estimating Time to Failure of Cast-Iron Water Mains. *Proceedings of the Institution of Civil Engineers: Water Management* 160(2):83-88.
14. Christodoulou, Symeon, Pooyan Aslani, and Annie Vanrenterghem. 2003. A Risk

- Analysis Framework for Evaluating Structural Degradation of Water Mains in Urban Settings, Using Neurofuzzy Systems and Statistical Modeling Techniques. Pp. 681–89 in World Water and Environmental Resources Congress.
15. Tabesh, M., J. Soltani, R. Farmani, and D. Savic. 2009. Assessing Pipe Failure Rate and Mechanical Reliability of Water Distribution Networks Using Data-Driven Modeling. *Journal of Hydroinformatics* 11(1):1–17.
 16. Berardi, L., O. Giustolisi, Z. Kapelan, and D. A. Savic. 2008. Development of Pipe Deterioration Models for Water Distribution Systems Using EPR. *Journal of Hydroinformatics* 10(2):113–26.
 17. Konstantinou, Charalampos, and Ivan Stoianov. 2020. A Comparative Study of Statistical and Machine Learning Methods to Infer Causes of Pipe Breaks in Water Supply Networks. *Urban Water Journal* 17(6):534–48.
 18. Snider, Brett, and Edward A. McBean. 2020. Improving Urban Water Security through Pipe-Break Prediction Models: Machine Learning or Survival Analysis. *Journal of Environmental Engineering* 146(3).
 19. Zhou, Xiao, Zhenheng Tang, Weirong Xu, Fanlin Meng, Xiaowen Chu, Kunlun Xin, and Guangtao Fu. 2019. Deep Learning Identifies Accurate Burst Locations in Water Distribution Networks. *Water Research* 166.
 20. Zhang Youshan, Guo Liangdong, Li Qi, and Li Junhui. 2019. Electricity consumption forecasting method based on mpso-bp neural network model. *PROCEEDINGS OF THE 2019 4TH INTERNATIONAL CONFERENCE ON ELECTRICAL ELECTRONICS ENGINEERING AND COMPUTER SCIENCE (ICEECS 2016)*, 50:674-678, 2019.
 21. Vapnik V., 1995. *The nature of statistical learning theory*, Springer-Verlag, New-York.
 22. Vapnik, Vladimir N. 1999. An Overview of Statistical Learning Theory. *IEEE Transactions on Neural Networks* 10(5): 988–99.
 23. Vapnik V., 1998. The support vector method of function estimation, In *Nonlinear Modeling: advanced black-box techniques*, Suykens J.A.K., Vandewalle J. (Eds.), Kluwer Academic Publishers, Boston, pp.55-85.
 24. Hathaway, Richard J., and James C. Bezdek. 1993. Switching Regression Models and Fuzzy Clustering. *IEEE Transactions on Fuzzy Systems* 1(3):195–204.
 25. Bezdek, James C., Robert Ehrlich, and William Full. 1984. FCM: The Fuzzy c-Means Clustering Algorithm. *Computers and Geosciences* 10(2–3):191–203.
 26. Bezdek, J.C., 1981. *Pattern Recognition with Fuzzy Objective Function Algorithm*, New York: Plenum Press.
 27. Dave, R.N., 1992. Boundary detection through fuzzy clustering. *IEEE International Conference on Fuzzy Systems*. pp. 127-134.
 28. Ali, Ameer M.; Karmakar, Gour C. and Dooley, Laurence S. 2008. Review on Fuzzy Clustering Algorithms. *Journal of Advanced Computations*, 2(3) pp. 169–181.

