

Production of Potential Blockage Event Map for Urban Sewer Networks Using Neural Network and GIS (Case Study: Region 2 of ABFA of Tehran City)

F. Bakhshizadeh¹, M. R. Jelokhani-Niaraki², S. Mahmoudi¹

1. PhD Student, Dept. of Remote Sensing and Geographic Information System, Faculty of Geography, University of Tehran, Tehran, Iran
2. Assoc. Prof., Dept. of Remote Sensing and Geographic Information System, Faculty of Geography, University of Tehran, Tehran, Iran
(Corresponding Author) mrjelokhani@ut.ac.ir

(Received May 10, 2021 Accepted Sep. 25, 2021)

To cite this article:

Bakhshizadeh, F., Jelokhani-Niaraki, M. R., Mahmoudi, S. 2022. "Production of potential blockage event map for urban sewer networks using neural network and GIS (case study: region 2 of ABFA of Tehran city)" Journal of Water and Wastewater, (In press). Doi: 10.22093/wwj.2021.285679.3142. 32(6), 115-129.

Abstract

Wastewater network as one of the most important infrastructure facilities can play an important role in achieving sustainable development by improving public health and environmental protection by preventing pollution of surface and groundwater resources. One of the most common incidents that occurs significantly in this network is blockage of the sewer pipes. Recognizing the factors influencing the occurrence of network blockage has a significant impact on accurately predicting what may happen to the network in the future. In the present study, GIS tools and artificial neural network were used to predict and mapping the potential for blockage in the sewer network. Important factors in the occurrence of blockage including, land use, siphon diameter, siphon depth, depth, materials and age of the pipe were used in neural network analysis. From input data of 70%, 15% and 15%, respectively, were used for training, validation and model testing. The results of the simulation using a neural network with a Performance Indicator of $R^2=0.9$ showed a high fitness between the predicted and observed locations of the blockage. Also, in the blockage potential map, areas with high population density, worn texture and unauthorized constructions (due to the installation of unauthorized branches) were observed blockage potential.

Keywords: Wastewater Network, GIS, Blockage Map, Region Two of the ABFA, Artificial Neural Network.

مجله آب و فاضلاب، دوره ۳۲، شماره ۶، صفحه: ۱۲۹-۱۱۵

تولید نقشه پتانسیل وقوع گرفتگی شبکه فاضلاب شهری با استفاده از شبکه عصبی و GIS (مطالعه موردی: منطقه ۲ آبفای تهران)

فریمه بخشی‌زاده^۱، محمدرضا جلوخانی نیارکی^۲، سمیه محمودی^۱

۱- دانشجوی دکترا، گروه سنجش از دور و سیستم اطلاعات جغرافیایی،

دانشکده جغرافیا، دانشگاه تهران، تهران، ایران

۲- دانشیار، گروه سنجش از دور و سیستم اطلاعات جغرافیایی،

دانشکده جغرافیا، دانشگاه تهران، تهران، ایران

mrjelokhani@ut.ac.ir (نویسنده مسئول)

(دریافت ۱۴۰۰/۲/۲۰ پذیرش ۱۴۰۰/۷/۳)

برای ارجاع به این مقاله به صورت زیر اقدام فرمایید:

بخشی‌زاده، ف.، جلوخانی نیارکی، م. ر.، محمودی، س.، ۱۴۰۰، "تولید نقشه پتانسیل وقوع گرفتگی شبکه فاضلاب شهری با استفاده از شبکه عصبی و GIS (مطالعه موردی: منطقه ۲ آبفای تهران)" مجله آب و فاضلاب، ۳۲(۶)، ۱۲۹-۱۱۵. Doi: 10.22093/wwj.2021.285679.3142

چکیده

شبکه فاضلاب به‌عنوان یکی از مهم‌ترین تأسیسات زیربنایی، می‌تواند نقش مهمی را در دستیابی به توسعه پایدار از طریق ارتقای سطح بهداشت عمومی و حفاظت از محیط‌زیست با جلوگیری از آلودگی منابع آبهای سطحی و زیرزمینی داشته باشد. یکی از شایع‌ترین حوادثی که به مقدار قابل توجهی در این شبکه اتفاق می‌افتد، گرفتگی در لوله‌های جمع‌آوری فاضلاب است. شناخت عوامل تأثیرگذار در وقوع گرفتگی در شبکه، تأثیر قابل توجهی در پیش‌بینی صحیح حوادثی که در آینده برای شبکه ممکن است اتفاق بیفتد، دارد. در این پژوهش، به‌منظور پیش‌بینی و تهیه نقشه پتانسیل وقوع گرفتگی در شبکه فاضلاب، از ابزارهای GIS و شبکه عصبی مصنوعی استفاده شد. فاکتورهای مهم در بروز گرفتگی شامل، کاربری، قطر سیفون، عمق سیفون، عمق و جنس و سن لوله در تحلیل شبکه عصبی استفاده شدند. از داده‌های ورودی به ترتیب ۷۰، ۱۵ و ۱۵ درصد برای آموزش، اعتبارسنجی و تست مدل استفاده شد. نتایج حاصل از شبیه‌سازی با استفاده از شبکه عصبی با شاخص توافق $R^2=0/9$ تناسب زیادی بین مکان‌های پیش‌بینی شده و مشاهده شده گرفتگی را نشان داد و همچنین در نقشه پتانسیل گرفتگی، محدوده‌هایی با تراکم جمعیت زیاد، بافت فرسوده و ساخت‌وسازهای غیرمجاز (به‌دلیل نصب انشعابات غیرمجاز) پتانسیل زیاد گرفتگی مشاهده شد.

واژه‌های کلیدی: شبکه فاضلاب، GIS، نقشه گرفتگی، آبفای منطقه ۲، شبکه عصبی مصنوعی

۱- مقدمه

دفع انواع فاضلاب‌های خانگی، صنعتی، تجاری و عمومی استفاده می‌شود (Grigg, 2012). اجرای کارآمد شبکه جمع‌آوری فاضلاب علاوه بر ایفای نقش اساسی در دستیابی به توسعه پایدار، ارتقای سطح بهداشت عمومی و

هم‌زمان با توسعه صنعتی اغلب کشورهای جهان، نیاز به اجرای شبکه‌های جمع‌آوری فاضلاب به‌ویژه در کلان‌شهرها حائز اهمیت شده است. شبکه جمع‌آوری فاضلاب یکی از مهم‌ترین زیرساخت‌های شهری است که به منظور جمع‌آوری، انتقال، تصفیه و

مستعد آسیب‌پذیری تا حد قابل توجهی در کاهش آسیب‌ها و مدیریت به موقع بحران می‌تواند مؤثر واقع شود (Laakso et al., 2018)

شبکه‌های عصبی مصنوعی^۱ با الهام از عملکرد مغز انسان و با استفاده از مدل‌های ریاضی پیچیده به‌طور گسترده به‌منظور پیش‌بینی در طیف وسیعی از علوم مختلف به‌کار می‌روند. یک شبکه عصبی با در نظر گرفتن یک ساختار ریاضی، پارامترهای ورودی و یک الگوریتم یادگیری به‌نحوی تنظیم و بهینه می‌شود تا رفتار مناسبی را از خود نشان دهد. از طرفی سامانه اطلاعات جغرافیایی^۲ به‌عنوان یک ابزار توانمند، نقش به‌سزایی برای مدیریت در ثبت و بررسی اطلاعات مکانی حوادث و اتفاقات شبکه، بررسی خسارات وارده به مشترکین و بررسی نواحی پر حادثه شبکه دارد. هدف از این پژوهش به‌کارگیری ابزارهای GIS و شبکه عصبی مصنوعی به‌منظور تولید نقشه پتانسیل وقوع گرفتگی شبکه فاضلاب در شهر تهران است.

تاکنون پژوهش‌های متعددی در زمینه تحلیل و مدل‌سازی مکانی حوادث، پهنه‌بندی آسیب‌پذیری و بررسی عوامل مؤثر در وقوع حوادث شبکه‌های فاضلاب شهری، انجام شده است. در این زمینه می‌توان به پژوهشی که توسط نوروزی و قهرودی به‌منظور پهنه‌بندی آسیب‌پذیری شبکه فاضلاب شهری در برابر مخاطرات طبیعی با استفاده از تصمیم‌گیری چندمعیاره انجام شد، اشاره کرد. در این بررسی قطر لوله، جنس لوله و منهول فاضلاب، تراکم جمعیت، کاربری اراضی و بعضی از فاکتورهای زمین‌شناسی مانند شیب و ارتفاع منطقه مورد مطالعه به‌عنوان معیارهای اصلی در نظر گرفته شدند. این معیارها با استفاده از روش AHP-Fuzzy^۳ وزن‌دهی و با استفاده از مدل TOPSIS^۴ ترکیب شدند. نتایج به‌دست آمده از تحلیل‌ها بیانگر آن بود که منطقه یک تهران نسبت به سایر مناطق آب و فاضلاب تهران با توجه به تجمع بالای تأسیسات شبکه فاضلاب (لوله و منهول)، شیب و تراکم جمعیت زیاد، بافت فرسوده در بخشی از منطقه و شرایط تأسیسات شبکه (قطر و عمق کارگزاری) و وجود چاه‌ها در مسیرهای شمال تهران، در هنگام

حفاظت محیط‌زیست با جلوگیری از آلودگی منابع سطحی و زیرزمینی می‌تواند ضمن فراهم ساختن امکان استفاده مجدد از فاضلاب‌های تصفیه شده، منافع اقتصادی قابل توجهی در پی داشته باشد (Sullivan, 1977).

بیش از ۷۰ درصد فاضلاب شهری را فاضلاب خانگی تشکیل می‌دهد. مراکز شهری با تراکم جمعیتی زیاد و گستردگی تأسیسات آب‌رسانی و شبکه‌های جمع‌آوری فاضلاب، همواره در معرض حوادث و عواقب غیرمنتظره ناشی از این حوادث قرار دارند (Hahn et al., 2002).

شبکه جمع‌آوری فاضلاب شهری مانند سایر زیرساخت‌های زیربنایی از این امر مستثنی نیست (Hahn et al., 1999).

با توجه به حساسیت زیاد شبکه‌های جمع‌آوری فاضلاب، فراوانی بسیار زیاد وقوع حوادث در این شبکه‌ها، منجر به خسارات اقتصادی و محیط‌زیستی جبران‌ناپذیری می‌شود. علی‌رغم هزینه‌های هنگفت نوسازی شبکه‌های آب و فاضلاب، هنوز سالانه به‌طور میانگین بیش از هزاران حادثه در شبکه آب و فاضلاب شهری گزارش می‌شود (Davies et al., 2001).

عواملی مانند فرسودگی و جنس نامرغوب لوله‌ها، اجرای نادرست شبکه فاضلاب، نفوذ ریشه گیاهان و درختان از درز و اتصالات شبکه، آسیب‌پذیری را به مقدار قابل توجهی افزایش می‌دهد (Ugarelli et al., 2010a).

بروز حوادث در شبکه‌های فاضلاب تأثیرات محیط‌زیستی جبران‌ناپذیری بر پیکره شهری وارد می‌کند. شیوع بیماری‌های ویروسی، بوی ناخوشایند، نفوذ پساب‌های آلوده به آبهای سطحی و زیرسطحی از جمله برخی عواقب شکستگی، گرفتگی و نشت در شبکه است (Norouzi and Ghahroudi, 2018).

یکی از شایع‌ترین حوادث که با فراوانی زیادی در شبکه جمع‌آوری فاضلاب رخ می‌دهد، گرفتگی لوله‌ها ناشی از عوامل مختلف است. از مهم‌ترین عوامل گرفتگی لوله‌های فاضلاب می‌توان به رسوب و ته‌نشینی مواد معلق، شن یا ماسه، ورود اشیاء، مواد زائد، آشغال و نخاله‌های بنایی به داخل لوله از طریق انشعابات مشترکین، فرسودگی و تخریب لوله‌ها با گذشت زمان اشاره کرد (Sullivan, 1977).

تحلیل مناسب از عوامل تهدیدکننده شبکه فاضلاب که منجر به این حوادث می‌شوند و همچنین پیش‌بینی و شناسایی مناطق

¹ Artificial Neural Networks

² Geographic Information System (GIS)

³ Analytical Hierarchy Process-Fuzzy (AHP-Fuzzy)

⁴ Technique for Order Preference by Similarity to Ideal Solution (TOPSIS)

روش‌های وزن‌دهی، الگوریتمی هوشمند مبتنی بر GIS را ارائه کردند. نتایج حاصل شده حاکی از آن بود که شاخص‌های آسیب‌پذیری لرزه‌ای خطوط لوله فاضلاب شهرکرد در حد کم و متوسط است و در بخش‌های جنوبی شهر با بافت فرسوده به دلیل شکنندگی لوله‌ها بیشتر از سایر نقاط شهر است (Rahgozar et al., 2016).

قوامی و همکاران از یک روش ترکیبی جدید بر مبنای ترکیب GIS، AHP و روش تحلیل پوششی داده‌ها^۵، برای ارائه یک برنامه مناسب برای اولویت‌بندی تعمیر و بازسازی خطوط لوله فاضلاب در یکی از مناطق شهر تهران استفاده کردند. در این پژوهش، احتمال خرابی یا شکست^۶ همرا با نتیجه خرابی^۷ برای تمامی خطوط لوله محاسبه شد. BN به‌عنوان یک روش احتمالی برای محاسبه پارامتر PoF استفاده شد، در حالی که سهم اصلی پژوهش در استفاده از روش‌های ترکیبی مبتنی بر GIS، AHP و DEA برای ارزیابی مقدار کمی CoF بود. نتایج حاصل از این بررسی نشان داد در منطقه مورد مطالعه خطوط لوله فاضلاب در وضعیت مطلوبی قرار داشتند و از بین ۱۶۰۵ خط لوله فاضلاب، فقط ۴۸ مورد (تقریباً ۳ درصد) در وضعیت بحرانی قرار داشتند (Ghavami et al., 2020).

به‌منظور ارزیابی خطر خرابی در شبکه جمع‌آوری فاضلاب شهر دوحه قطر، الماسری و همکاران، مدلی بر مبنای سیستم استنتاج فازی سوگنو^۸ برای ایجاد یک شاخص خطر، که بر مبنای این شاخص عملیات بازرسی اولویت‌بندی می‌شوند، ارائه کردند. شبکه بیزین پویا^۹ برای پیش‌بینی PoF در خط لوله فاضلاب بر اساس پارامترهایی مانند نقص احتمالی و برخی ویژگی‌های لوله‌ها به‌کار برده شد. در این پژوهش، عواقب خرابی لوله‌های فاضلاب و هزینه‌های ناشی از آن و منافع حاصل از جلوگیری از چنین خرابی، با استفاده از یک مدل ضرر اقتصادی^{۱۰} برآورده شد. برای پیاده‌سازی روش استنتاج فازی سوگنو از زبان برنامه‌نویسی پایتون، ارائه خروجی‌ها، از نرم‌افزار GIS استفاده شد. نتایج حاصل از این پژوهش نشان داد که استفاده از GIS می‌تواند به‌عنوان یک ابزار

وقوع مخاطرات طبیعی مانند سیلاب در معرض آسیب‌پذیری بیشتری قرار دارد (Norouzi and Ghahroudi, 2018).

محمدی و نوری با استفاده از تکنیک‌های آمار فضایی مانند رگرسیون وزنی جغرافیایی^۱ و روش تعیین الگوی پراکنش عوارض^۲ به تحلیل فضایی حوادث شبکه جمع‌آوری فاضلاب شهر اردبیل پرداختند. یافته‌های پژوهش نشان داد که اغلب حوادث شبکه در محله‌های مرکزی با تراکم جمعیت زیاد، بافت‌های فرسوده و سکونتگاه‌های حاشیه شهر به وقوع پیوسته است (Mohammadi and Noori, 2018).

تهذیبی و همکاران با استفاده از روش خوشه‌بندی، آسیب‌پذیری شبکه انتقال آب را ارزیابی کردند. در این پژوهش با استفاده از روش تحلیل سلسله مراتبی^۳ متشکل از دو مرحله خوشه‌بندی و بازگشایی و با به‌کارگیری نتایج این دو مرحله، نقشه بخش‌های آسیب‌پذیر شبکه تهیه و راهکار مناسب برای کاهش پیامدهای خرابی با توجه به آسیب‌های اولیه ارائه شد (Tahzibi et al., 2015).

عنبری و تابش میزان احتمال وقوع شکست در شبکه‌های جمع‌آوری فاضلاب را بررسی کردند. در این پژوهش به‌منظور محاسبه احتمال وقوع شکست در شبکه‌های جمع‌آوری فاضلاب، مدلی با استفاده از شبکه بیزین^۴ معرفی شد. آماده‌سازی ورودی‌های مدل، آموزش BN، صحت‌سنجی شبکه آموزش دیده و دریافت نتایج خروجی، ۴ مرحله اصلی مدل ارائه شده معرفی شد. بخشی از شبکه جمع‌آوری فاضلاب شهر تهران به‌عنوان مطالعه موردی انتخاب شد و با استفاده از احتمال وقوع شکست به‌دست آمده از مدل، فاضلاب‌روها در پنج گروه از نظر اولویت بازرسی و نگهداری تقسیم شدند. ۳۷ درصد از آبروهای فاضلاب در کلاس خیلی کم و کم و ۶۰ درصد در کلاس متوسط قرار گرفتند که نو بودن بخش عمده‌ای از شبکه فاضلاب اجرا شده جزء عوامل اصلی آن بود (Anbari and Tabesh, 2016).

برای ارزیابی شاخص آسیب‌پذیری لرزه‌ای شبکه جمع‌آوری فاضلاب شهری در شهرکرد، رهگذر و همکاران با استفاده از

⁵ Data Envelopment Analysis (DEA)

⁶ Probability of Failure (PoF)

⁷ Consequence of Failure (CoF)

⁸ Sugeno

⁹ Dynamic Bayesian Network (DBN)

¹⁰ Economic Loss

¹ Geographically Weighted Regression (GWR)

² Multi-Distance Spatial Cluster Analysis

³ Analytical Hierarchy Process (AHP)

⁴ Bayesian Network (BN)

به طور مجزا منحنی خرابی زنجیره مارکو جدیدی تولید شود که باعث دشواری و پیچیدگی کار می شود (Baik et al., 2006).

بررسی پژوهش های انجام شده نشان می دهد در اغلب موارد به منظور بررسی آسیب پذیری شبکه جمع آوری فاضلاب از انواع روش های آمار فضایی، تصمیم گیری های چند معیاره^۳، استنتاج فازی و یا سایر تحلیل های غیر مکانی استفاده شده است. بنابراین با توجه به این امر که تاکنون تحلیل مکانی که با در نظر گرفتن فاکتورهای مهم در گرفتگی شبکه فاضلاب و ترکیب الگوریتم های یادگیری ماشین و GIS، قادر به تهیه نقشه مکانی که نشان دهنده مکان های با پتانسیل وقوع گرفتگی باشد، انجام نشده است. از طرفی دیگر پژوهش های زیادی نشان می دهد که الگوریتم های مبتنی بر یادگیری ماشین به ویژه شبکه عصبی مصنوعی از طریق مشاهده وقایع گذشته در قالب سری های زمانی پیوسته و بررسی آنها امکان پیش بینی وقایع جدید را فراهم می کند. در دهه های اخیر با بهره گیری از هوش مصنوعی و مدل های مبتنی بر آن مانند یادگیری ماشین^۴، در خصوص تحلیل، بررسی و پیش بینی با استفاده از مجموعه داده های سری زمانی، طیف وسیعی از پژوهش ها انجام شده است (Ahn et al., 2005, Arjun and Aneesh, 2015, Asnaashari et al., 2013, Jafar et al., 2010).

از این رو، با توجه به قابلیت زیاد شبکه های عصبی مصنوعی در حل مسائل غیر خطی و پیچیده از طریق برقراری ارتباط منحصر به فرد بین ورودی ها و خروجی های سیستم، در همین راستا این پژوهش به منظور پیش بینی گرفتگی در شبکه جمع آوری فاضلاب در آبفای منطقه ۲ آب و فاضلاب تهران سازمان دهی شد.

۲- منطقه مورد مطالعه و داده ها

منطقه ۲ آب و فاضلاب شهر تهران محدوده وسیعی بالغ بر ۹۳/۴۷ کیلومتر مربع را در بر می گیرد، به طوری که شامل مناطق ۸، ۷ و بخشی از مناطق ۴ و ۱۳ شهرداری تهران است. محدوده عملیاتی آبفای منطقه ۲ تهران از شمال به بزرگراه بابایی، از جنوب به خیابان دماوند، از غرب به خیابان ولی عصر و از شرق به بزرگراه تلو لشگرک محدود می شود و در مجموع نزدیک به ۶۵۰۰۰ مشترک را تحت پوشش خود قرار داده است. شکل ۱ نقشه محدود

کارآمد در تهیه نقشه ریسک خطر، شناسایی خطوط لوله با وضعیت بحرانی از نظر آسیب پذیری، تا ۷۷ درصد نسبت به سایر روش ها در مدیریت بحران و برنامه ریزی های آتی بازرسی خطوط شبکه فاضلاب و مدیریت هزینه مؤثر واقع شود (Elmasry et al., 2018).

عبری و همکاران برای ارزیابی ریسک در اولویت بندی بازرسی لوله های شبکه جمع آوری فاضلاب، مدلی ترکیبی مبتنی بر BNs، به عنوان یک روش احتمالی برای محاسبه میزان خرابی در لوله های شبکه فاضلاب و روش میانگین وزنی^۱ ارائه کردند. از سیستم های استنتاج فازی برای در نظر گرفتن عدم قطعیت ها در PoF در لوله های جمع آوری فاضلاب استفاده شد. نتایج حاصل از این پژوهش حاکی از آن بود که حدود ۶۲ درصد لوله های جمع آوری فاضلاب خطر متوسط و ۱۲ درصد در وضعیت بحرانی قرار دارند. با شناسایی مناطق با خطر زیاد، بازرسی های منظم بر اساس اولویت بندی وضعیت خطوط لوله فاضلاب، می تواند به طور قابل توجهی عملکرد شبکه فاضلاب را افزایش داده و در مدیریت هزینه های بازسازی و تعمیر شبکه جمع آوری فاضلاب مؤثر واقع شود (Anbari et al., 2017).

باه و همکاران به منظور تهیه ارزیابی نتیجه و خطر خرابی در شبکه جمع آوری فاضلاب، تلفیقی از GIS و روش های تصمیم گیری چند معیاره (میانگین وزنی) را به کار بردند. نتایج بررسی آنها نشان داد که ۶ درصد از تأسیسات شبکه فاضلاب پیامدهای زیادی در CoF دارند این در حالی است که ۴ درصد از تأسیسات در ریسک زیادی از خطر خرابی قرار دارند و همچنین نقشه ریسک به دست آمده از این پژوهش می تواند در برنامه ریزی های آتی در مدیریت هر چه بهتر تجهیزات شبکه فاضلاب مفید واقع شود (Baah et al., 2015).

بایک و همکاران با استفاده از مدل زنجیره مارکو^۲ و با در نظر گرفتن فاکتورهایی مانند طول، قطر، جنس، سن و شیب لوله، شرایط سیستم های لوله فاضلاب را ارزیابی کردند. در این روش فرض می شود که نرخ خرابی به زمان وابسته نیست که این امر موجب کاهش دقت تحلیل ها می شود و از طرفی دیگر برای استفاده از این روش داده های موجود باید به چند گروه تقسیم شوند و برای هر گروه

³ Multi Criteria Decision Making

⁴ Machine Learning

¹ Weighted Average

² Markov Chain

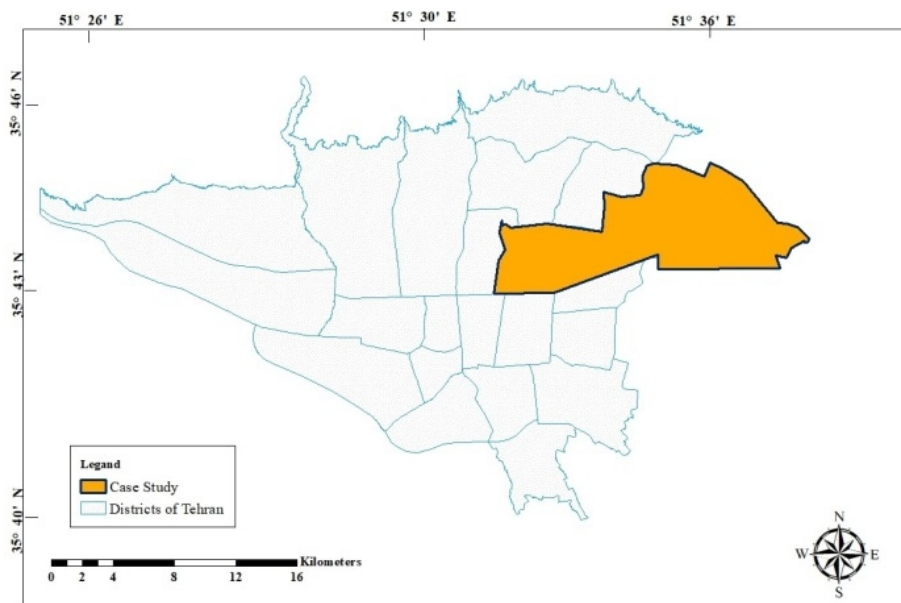


Fig. 1. Location of the study area

شکل ۱- موقعیت مکانی محدوده مورد مطالعه

به همراه داده‌های مکانی شبکه جمع‌آوری فاضلاب (خط لوله‌ها، منهول و انشعاب مشترکین) و بلوک‌های ساختمانی گردآوری شد. بعد از تکمیل اطلاعات توصیفی مربوط به هر یک از مکان‌های وقوع حادثه، داده‌ها به سه دسته Train-Validation-Test تقسیم و فرایند پیش‌بینی با استفاده از شبکه عصبی انجام شد. شکل ۲ مراحل کلی پژوهش را نشان می‌دهد.

۳-۱- پارامترهای گرفتگی

گرفتگی^۱ در خطوط جمع‌آوری فاضلاب از جمله شایع‌ترین حوادثی است که به کرات مشاهده می‌شود. برطبق آمار حوادث ثبت شده در بازه زمانی مورد مطالعه، بیش از ۹۰ درصد از گرفتگی‌های گزارش شده مربوط به کاربری‌های خانگی است. گرفتگی در مسیر جریان ممکن است ناشی از ته‌نشینی خاک و گل‌ولای در کف لوله، رسوبات چرب، رسوبات ناشی از مواد معلق موجود در آبهای زیرزمینی، جرم گرفتگی داخل لوله، رشد و نفوذ ریشه گیاهان به داخل فاضلابرو و مسدود کردن مسیر فاضلابرو توسط انواع زباله‌ها باشد (Khan et al., 2009).

شکل ۳ مکان وقوع گرفتگی را در محدوده مورد مطالعه نشان

عملیاتی آبفای منطقه ۲ تهران را نشان می‌دهد. عمده کاربری‌های مطرح در منطقه در درجه اول کاربری مسکونی و در درجات بعدی کاربری‌های تجاری، عمومی و در بخش‌هایی از شرق منطقه، کاربری صنعتی را شامل می‌شود. جمعیت ساکن این محدوده تقریباً حدود ۱۴۵۰۰۰۰ نفر، تعداد واحدهای مسکونی ۱۳۵۰۰۰ واحد و مقدار آب مصرفی منطقه حدوداً ۱۴۰ میلیون مترمکعب است (امور مشترکین آبفای منطقه ۲). در این پژوهش به منظور پیش‌بینی گرفتگی در شبکه جمع‌آوری فاضلاب از دو مجموعه داده استفاده شد. مجموعه اول شامل حوادث ثبت شده مربوط به شبکه جمع‌آوری فاضلاب منطقه ۲ تهران در بازه زمانی بین سال‌های ۹۵ تا ۹۹ و دسته دوم شامل داده‌های مکانی و یا نقشه خطوط جمع‌آوری فاضلاب، آدروها و بلوک‌های ساختمانی است.

۳- مواد و روش‌ها

در این پژوهش، ابتدا منطقه مورد مطالعه تعیین و پارامترهای مؤثر در وقوع گرفتگی شبکه فاضلاب شهری به روش کتابخانه‌ای بررسی شد. در ادامه، بعد از تعیین فاکتورهای مهم در میزان وقوع حادثه گرفتگی در شبکه جمع‌آوری فاضلاب، آمار و اطلاعات مرتبط با حوادث رخ داده در بازه زمانی ۵ ساله بین سال‌های ۹۵ تا ۹۹،

¹ Blockage

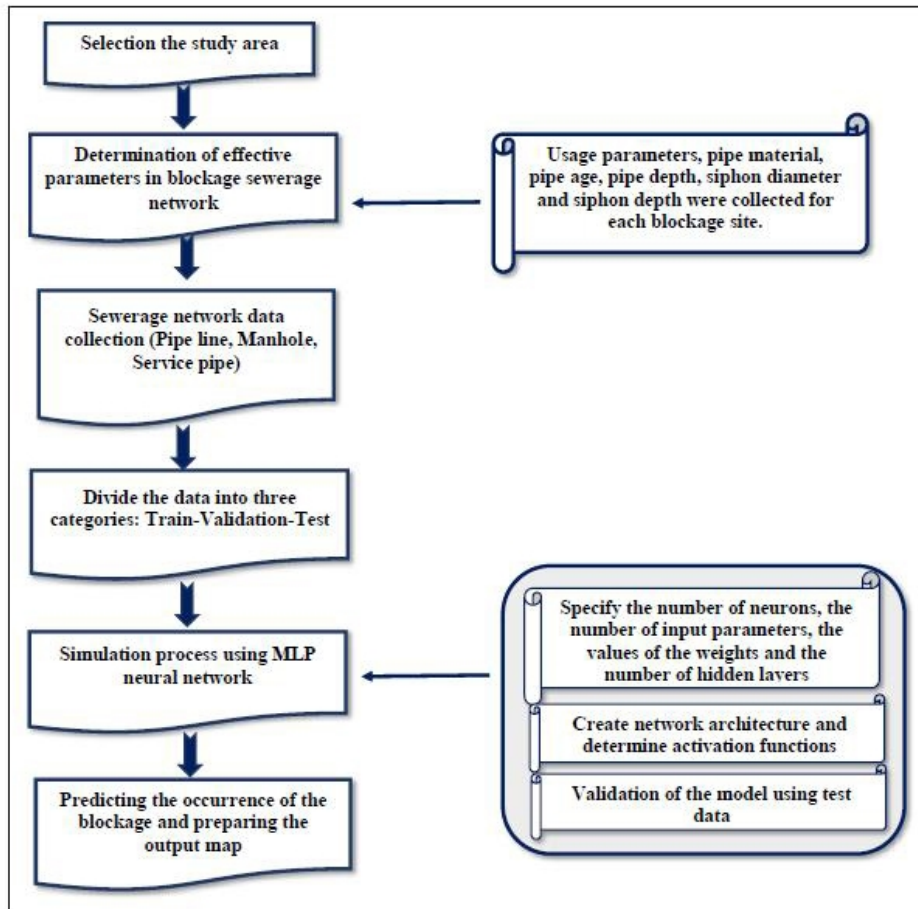


Fig. 2. Flowchart predicting the possibility of blockage using the MLP neural network

شکل ۲- فلوجارت پیش‌بینی احتمال وقوع گرفتگی با استفاده از شبکه عصبی MLP

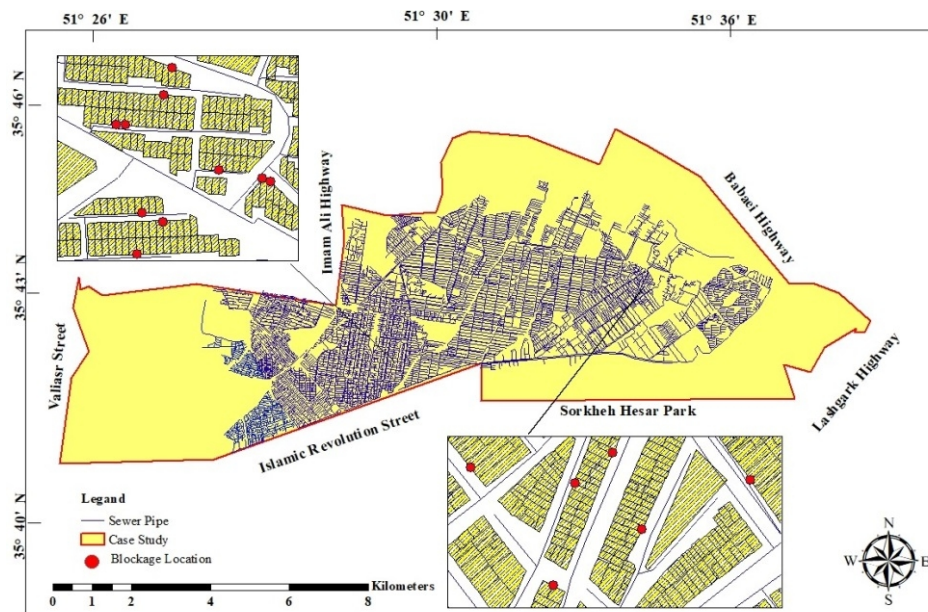


Fig. 3. Location of the blockage in the study area

شکل ۳- مکان وقوع گرفتگی در محدوده مورد مطالعه

هم گفته می‌شود. واحدهای محاسباتی یک شبکه عصبی را تشکیل می‌دهند. در این نوع شبکه، خروجی‌های لایه اول به‌عنوان ورودی‌های لایه بعدی در نظر گرفته می‌شوند و به لایه‌هایی که بین لایه ورودی و خروجی قرار می‌گیرند، لایه‌های پنهان گفته می‌شود (Despaigne and Massart, 1998).

هر لایه پنهان شامل نرون‌های غیرقابل مشاهده شبکه است. یک الگوریتم پرسپترون چند لایه می‌تواند یک یا دو لایه پنهان داشته باشد. الگوریتم MLP از تکنیک یادگیری نظارت شده^۸ به نام پس انتشار^۹ برای آموزش استفاده می‌کند (Hecht-Nielsen, 1992).

در الگوریتم‌های مبتنی بر یادگیری ماشین، هدف از آموزش شبکه این است که شبکه قانون کار را یاد بگیرد و پس از آموزش صحیح شبکه، به‌ازای هر ورودی، خروجی مناسب ارائه دهد که این امر مستلزم تنظیم صحیح وزن‌های شبکه است (Despaigne and Massart, 1998).

فرایند پیش‌بینی از طریق شبکه‌های عصبی مستلزم حجم زیادی از داده‌ها برای آموزش شبکه است. تعیین نرخ یادگیری شبکه عصبی گاهی اوقات کار دشوار و چالش‌برانگیزی است. با تعیین یک نرخ یادگیری مطلوب می‌توان به حداقل خطا دست یافت. عملکرد مناسب یک شبکه عصبی MLP نسبت به نرخ یادگیری بسیار حساس است. اگر نرخ یادگیری کم انتخاب شود، شبکه به درستی آموزش نمی‌بیند و به جواب مطلوبی نمی‌توان رسید، در صورتی که نرخ یادگیری زیاد در نظر گرفته شود، ممکن است شبکه به حالت نوسانی و ناپایدار تبدیل شود و در نتیجه هم‌گرا نشده و آموزش نمی‌بیند (Caudill, 1988).

برای دست یافتن به کمترین مقدار خطا، در هر بار اجرای شبکه، بردار مقدار پیش‌بینی شده با بردار مقدار مشاهده شده (داده‌های واقعی) مقایسه و در صورت وجود خطا، ضرایب وزنی بردارهای ورودی اصلاح می‌شود. بردار ورودی نرمال شده (نرون‌ها در لایه ورودی) در وزن‌های مربوطه ضرب می‌شوند. نرون‌های موجود در یک لایه پنهان با یک بایاس طبق معادله ۱ جمع می‌شوند (Caudill, 1988)

$$y_0 = \sum_{i=1}^n w_i x_i + b \quad (1)$$

⁷ Neuron

⁸ Supervised Learning

⁹ Backpropagation

می‌دهد. در مورد کاربری‌های مسکونی، از عمده دلایل گرفتگی می‌توان به رسوب چربی، انباشت زباله‌ها و عدم رعایت استانداردهای لازم در نصب انشعاب مشترکین اشاره کرد (Ugarelli et al., 2010b, Greene et al., 1999).

این گونه موانع در مسیر جریان فاضلاب قرار گرفته و از جریان معمول آن جلوگیری کرده و باعث انسداد در شبکه می‌شود. در مورد وقوع گرفتگی در شبکه جمع‌آوری فاضلاب و آسیب‌های ناشی از آن می‌توان عوامل و پارامترهایی را در نظر گرفت که به‌وسیله این پارامترها بتوان احتمال وقوع حادثه را پیش‌بینی کرد. در تدوین عوامل تأثیرگذار در وقوع حادثه، امکان دسترسی به داده‌های مربوطه نیز در نظر گرفته شد. به‌طور کلی در وقوع گرفتگی در لوله‌های فاضلاب، به‌عنوان مؤلفه اصلی سامانه‌های جمع‌آوری فاضلاب، عوامل متعددی مانند سن، قطر و جنس لوله‌ها، خوردگی جداره لوله، شرایط اجرا و نصب، شرایط اقلیمی و شرایط بهره‌برداری دخالت دارند که از بین این فاکتورها، تأثیرگذارترین آنها انتخاب شدند. فاکتورهای جنس، قطر، عمق و سن لوله، انواع کاربری، عمق و قطر سیفون فاضلاب به‌عنوان عوامل تأثیرگذار در وقوع حادثه در شبکه جمع‌آوری فاضلاب تعیین شدند (Ugarelli et al., 2010a, Ugarelli et al., 2010b).

۳-۲- شبکه عصبی مصنوعی پرسپترون چند لایه^۱

شبکه‌های عصبی برای مسائلی که ارتباط مشخصی بین متغیرهای وابسته و مستقل وجود دارد ولی ماهیت دقیق روابط بین این متغیرها مشخص نیست و حل این گونه مسائل با استفاده از تکنیک‌های متداول دشوار است، به‌کار برده می‌شود (Caudill, 1988).

یکی از پرکاربردترین مدل‌های شبکه عصبی در مسائل مربوط به مدل‌سازی و پیش‌بینی‌ها، MLP است. در یک شبکه عصبی MLP حداقل سه لایه^۲ از نودها^۳ وجود خواهند داشت: لایه ورودی^۴، لایه پنهان^۵ و لایه خروجی^۶. نودهای شبکه که به آن نرون^۷

¹ Multilayer Perceptron Neural Network (MLP)

² Layer

³ Node

⁴ Input Layer

⁵ Hidden Layer

⁶ Output Layer

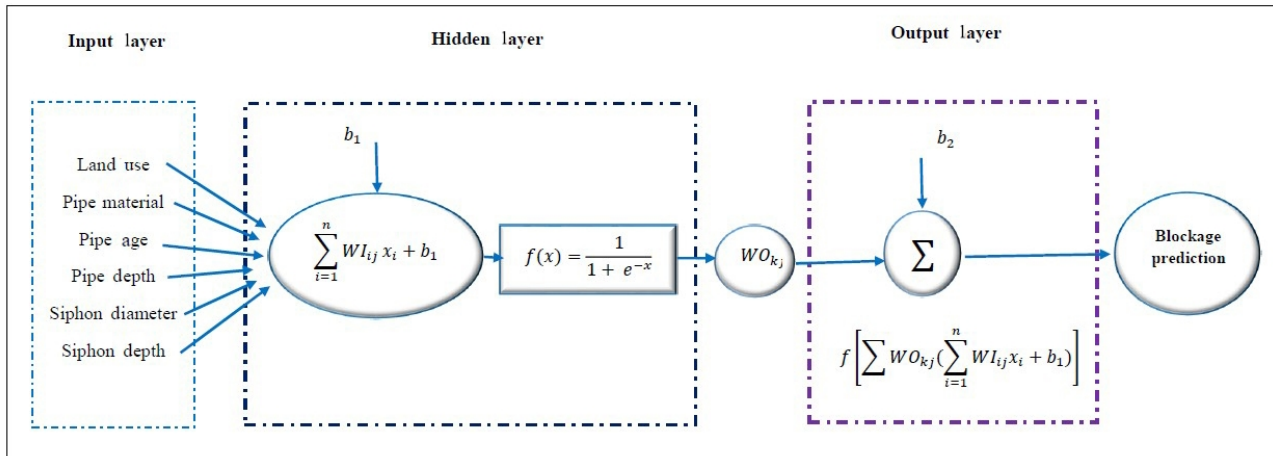


Fig. 4. Structure of the multi layer perceptron neural network for prediction blockage

شکل ۴- ساختار MLP برای پیش‌بینی وقوع گرفتگی

باعث پس برآزش^۱ و تعداد زیاد آن باعث بیش برآزش می‌شود (Caudill, 1988).

هیچ استاندارد مشخصی برای تعیین تعداد بهینه نرون‌ها در لایه پنهان وجود ندارد (Najjar and Basheer, 1996).

معمولاً برای تعیین تعداد بهینه نرون‌ها، خطای حداقل میانگین مربعات^۲ و مقدار ضریب هم‌بستگی^۴ (R^2) در نظر گرفته می‌شود (Najjar and Basheer, 1996). تا به مقدار میانگین خطای مطلوب رسید.

با استفاده از یک تابع فعال‌سازی^۵ ارتباط بین ورودی و خروجی در یک شبکه مشخص می‌شود. در اغلب موارد پیش‌بینی از توابع سیگموئید (لجستیک)، تانژانت هایپربولیک و خطی به‌عنوان تابع فعال‌سازی استفاده می‌شود. خروجی توابع فعال‌سازی مقداری بین صفر و ۱ یا بین -۱ و ۱ است (Despaigne and Massart, 1998).

شکل ۴ ساختار کلی MLP به‌منظور پیش‌بینی وقوع گرفتگی در شبکه جمع‌آوری فاضلاب را نشان می‌دهد. در لایه ورودی، داده‌ها برای فرایند پیش‌بینی به شبکه عصبی معرفی می‌شوند. لایه پنهان مبتنی بر یک یا چند لایه مخفی است و پردازش اطلاعات را انجام می‌دهد. پس از پردازش داده‌ها، نتایج حاصل از عملکرد شبکه

وزن‌ها از یک مدل خطی به‌دست می‌آیند و اگر از یک تابع فعال‌سازی غیرخطی استفاده کنیم (معادله ۲)، برای محاسبه وزن‌ها از مدل غیرخطی استفاده می‌شود (معادله ۳)

$$f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

$$y_0 = f(x) \left[\sum_{i=1}^n W_i x_i + b \right] \quad (3)$$

که در آن

y_0 مقدار خروجی، W_i بردار وزن، b مقدار بایاس، f تابع انتقال و x نشان‌دهنده مجموع وزن‌های ورودی است. پس از محاسبه میزان خطا، فرایند تناسب مدل به پایان می‌رسد. اختلاف بین مقدار واقعی و مقدار پیش‌بینی شده برای محاسبه میزان خطا در نظر گرفته می‌شود (Despaigne and Massart, 1998).

معادله یک الگوریتم MLP با معادله ریاضی زیر بیان می‌شود

$$y_0 = f \left[\sum W_{kj} \left(\sum W_{ij} x_i + b_1 \right) \right] + b_2 \quad (4)$$

که در آن

W_{ij} وزن‌های لایه ورودی و W_{kj} وزن لایه خروجی، b_1 و b_2 به‌ترتیب بایاس‌های لایه ورودی و خروجی است. تعیین تعداد نرون‌ها در لایه‌های پنهان اهمیت زیادی دارد. تعداد کم نرون‌ها

¹ Under-Fitting

² Over-Fitting

³ Root Mean Square Error (RMSE)

⁴ Correlation Coefficient

⁵ Fitness Function




Fig. 5. Optimal MLP network architecture to predict accident locations in the study period

شکل ۵- معماری بهینه شبکه MLP برای پیش‌بینی مکان‌های وقوع حادثه در بازه زمانی مورد مطالعه

۴- نتایج و بحث

این پژوهش با هدف استفاده از قابلیت شبکه‌های عصبی مصنوعی و ابزارهای GIS به منظور پیش‌بینی وقوع گرفتگی در شبکه جمع‌آوری فاضلاب در منطقه ۲ آبفای تهران انجام شد. در گام اول داده‌های مورد نیاز در قالب یک ماتریس با ابعاد ۲۲۹۰۴ سطر و ۶ ستون گردآوری شد (هریک از سطرها ماتریس بیانگر مکان وقوع حادثه و هر یک از ستون‌ها بیانگر پارامترهای مؤثر در وقوع گرفتگی در شبکه فاضلاب بود). از مجموع ۲۲۹۰۴ داده (۱۳۹۳۶ نمونه برای مناطقی که حادثه رخ نداده و ۸۹۶۸ نمونه برای مناطقی که حادثه رخ داده بود)، ۷۰ درصد داده‌ها برای آموزش شبکه، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای تست شبکه استفاده شد. برای تعیین ساختار مناسب برای شبکه عصبی، ساختارهای مختلف شبکه عصبی آموزش داده می‌شوند. هدف از آموزش یک شبکه عصبی، بهینه‌سازی مقدار وزن‌ها در لایه‌های پنهان و خروجی است. آموزش شبکه یکی از گام‌های مهم در مدل‌سازی با شبکه عصبی است که در واقع همان فرایند به‌روزرسانی ضرایب وزنی در لایه‌های میانی و خروجی است.

در مسائل با درجه پیچیدگی زیاد و غیرخطی، شبکه‌های تک لایه کارایی لازم در فرایند پیش‌بینی را ندارند، به همین دلیل از شبکه‌های چند لایه که به مراتب توانایی زیادی دارند، استفاده می‌شود. تعداد لایه‌ها و تعداد نرون‌های لایه پنهان توسط خود کاربر تعیین می‌شود. شبکه‌ای با ۳ لایه پنهان که به ترتیب تعداد نرون‌ها در لایه اول و دوم ۲۰، در لایه سوم ۲ است، طراحی شد. افزایش تعداد لایه‌ها (یعنی بیش از ۳ لایه پنهان) موجب کاهش صحت می‌شود. برای تعیین معماری بهینه شبکه از روش سعی و خطا و با انجام آزمون‌های مختلف، شبکه‌ای که کمترین میزان خطا و بیشترین کارایی را دارد، انتخاب شد. معماری بهینه این شبکه به منظور پیش‌بینی مکان‌های وقوع گرفتگی در شکل ۵ نشان داده

عصبی MLP در لایه سوم یا لایه خروجی محاسبه می‌شود. ساختار یک شبکه عصبی از طریق تعیین تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، توابع فعال‌سازی، روش آموزش، نرخ یادگیری و الگوریتم تصحیح وزن‌ها تعیین می‌شود.

۳-۳- شاخص‌های عملکرد^۱ برای ارزیابی مدل

برای ارزیابی صحت پیش‌بینی مدل از PI استفاده می‌شود. این شاخص‌ها دو کمیت صحت و خطا را اندازه‌گیری می‌کنند. مقدار برآورد شده صحت اندازه‌گیری به وسیله شاخص‌های توافق بین مقدار صفر و ۱ قرار می‌گیرد. مقدار نزدیک به ۱، نشان‌دهنده بهترین برازش و عملکرد مدل هستند، در حالی که هرچه این مقدار به صفر نزدیک شوند، مقدار پیش‌بینی شده با درصد بیشتری از خطا همراه خواهند بود (Arjun and Aneesh, 2015). دو شاخص رایج و متداول در این زمینه، شاخص‌های RSME و R^2 هستند که با معادلات زیر محاسبه می‌شوند

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n [p_i - o_i]^2 \right)^{0.5} \quad (5)$$

$$R^2 = \left[\frac{1}{(n.S_{pred-S_{obs}})} \sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O}) \right]^2 \quad (6)$$

که در آنها

n تعداد کل داده‌ها، P_i مقدار پیش‌بینی شده، O_i مقدار مشاهده شده، \bar{P} متوسط مقدار پیش‌بینی شده، \bar{O} متوسط مقدار مشاهده شده، S_{pred} انحراف معیار مقدار پیش‌بینی شده و S_{obs} انحراف معیار مقدار مشاهده شده است. در این پژوهش از شاخص R^2 برای ارزیابی صحت مقدار پیش‌بینی شده استفاده شد.

¹ Performance Indicators (PI)

واقعی وقوع حادثه می‌توان بیان کرد که پارامترهایی مانند جنس و قطر لوله، نوع کاربری، سن لوله، جنس و قطر انشعاب از مهم‌ترین عوامل تأثیرگذار در وقوع گرفتگی شبکه جمع‌آوری فاضلاب در منطقه مورد مطالعه هستند.

بعد از اجرای الگوریتم و تعیین ساختار مناسب برای آموزش شبکه، یکی از مهم‌ترین مراحل پس از طراحی و ساخت یک مدل یا الگوریتم، ارزیابی کارایی^۴، دقت و صحت آن است. در حوزه الگوریتم‌های هوش مصنوعی ماتریس ابهام^۵ به ماتریسی گفته می‌شود که در آن عملکرد مدل با سه دسته داده‌های Train-Validation-Test ارزیابی می‌شود. معمولاً چنین نمایشی برای الگوریتم‌های یادگیری با ناظر استفاده می‌شود. یک ماتریس ابهام برای ارزیابی نتایج به صورت جزئی و کلی ارائه می‌شود. در این ماتریس هر یک از دسته‌بندی‌های مربوط به پارامتر پیش‌بینی که به صورت درست و نادرست پیش‌بینی شده‌اند و همچنین درصد کل حالت‌هایی که درست پیش‌بینی شده‌اند را نشان می‌دهد. شکل ۶ ماتریس ابهام را به‌طور جداگانه برای سه سری داده Train-Validation-Test و کل داده‌ها نشان می‌دهد. صحت کلی با استفاده از داده‌های تست (که هیچ مشارکتی در فرایند آموزش نداشتند) ۹۰/۱ درصد به دست آمد که نشان‌دهنده عملکرد صحیح شبکه عصبی در میزان پیش‌بینی وقوع گرفتگی در شبکه جمع‌آوری فاضلاب است. با توجه به دوسطحی بودن فرایند پیش‌بینی (وقوع گرفتگی و عدم وقوع گرفتگی)، یک معیار مناسب دیگری که می‌توان به منظور ارزیابی کیفیت مدل برازش داده شده و تعیین توان پیش‌بینی صحیح مدل به کار برد، سطح زیر منحنی مشخصه عملکرد سیستم^۶ است. شکل ۷ منحنی ROC حاصل از پیش‌بینی با استفاده از الگوریتم MLP را در این پژوهش نشان می‌دهد. در حالت ایده‌آل، مساحت زیر منحنی برابر با بیشترین مقدار خود، یعنی ۱ است. بنابراین، هر چه مساحت زیر منحنی به عدد ۱ نزدیک باشد، به معنای بهتر بودن عملکرد مدل برازش داده شده است. مقدار صفر تا ۰/۵ نشان‌دهنده تصادفی بودن پیش‌بینی و مقدار ۰/۵ تا ۱ بیانگر توانمندی زیاد مدل در پیش‌بینی است.

روشی دیگری که برای به دست آوردن اطلاعات بیشتر در مورد

| Training confusion matrix | | | Validation confusion matrix | | | | | | |
|---------------------------|---|---------------|-----------------------------|----------------|--------------|---|---------------|----------------|----------------|
| Output class | 0 | 8932 55.7% | 677 4.2% | 93.0% 7.0% | Output class | 0 | 1902 55.4% | 165 4.8% | 92.0% 8.0% |
| | 1 | 824 5.1% | 5590 34.9% | 87.2% 12.8% | | 1 | 186 5.4% | 1182 34.4% | 86.4% 13.6% |
| | | 91.6% 8.4% | 89.2% 10.8% | 90.6% 9.4% | | | 91.1% 8.9% | 87.8% 12.2% | 89.8% 10.2% |
| | | Target class | | | | | Target class | | |

| Test confusion matrix | | | All confusion matrix | | | | | | |
|-----------------------|---|---------------|----------------------|----------------|--------------|---|----------------|----------------|----------------|
| Output class | 0 | 1926 56.1% | 175 5.1% | 91.7% 8.3% | Output class | 0 | 12760 55.7% | 1017 4.4% | 92.6% 7.4% |
| | 1 | 166 4.8% | 1168 34.0% | 87.6% 12.4% | | 1 | 1176 5.1% | 7940 34.7% | 87.1% 12.9% |
| | | 92.1% 7.9% | 87.0% 13.0% | 90.1% 9.9% | | | 91.6% 8.4% | 88.6% 11.4% | 90.4% 9.6% |
| | | Target class | | | | | Target class | | |

Fig. 6. Train-Validation-Test data confusion matrix
شکل ۶- ماتریس ابهام داده‌های Train-Validation-Test

شده است. در تعیین معماری بهینه سعی شده از ساختارهای ساده با تعداد ورودی‌های مؤثر استفاده شود. در این بررسی از توابع فعال‌سازی تانژانت هایپربولیک^۱ و سیگموئید^۲ استفاده شد. ترکیبی از توابع فعال‌سازی Tansig-Tansig-Tansig-Logsig در لایه‌های پنهان و خروجی منجر به نتایج بهینه در فرایند پیش‌بینی شد. حداکثر تعداد مراحل تکرار^۳ ۱۰۰۰ مرحله در نظر گرفته شد و مدل ۴ بار اجرا شد تا مقدار میانگین به دست آید. نرخ یادگیری برای آموزش مطلوب شبکه و بهبود عملکرد مدل از طریق روش سعی و خطا، ۰/۰۵ تعیین شد. لازم به ذکر است که ساختار پیشنهاد شده، در صورت وجود اطلاعات قابل توجه از تمامی پارامترهای ورودی و خروجی، کارایی زیادی در مشخص کردن بهترین ساختار و کارآمدترین رابطه پیش‌بینی وقوع گرفتگی دارد. بر اساس نتایج حاصل شده، شبکه عصبی دقت قابل‌قبولی در پیش‌بینی وقوع گرفتگی شبکه جمع‌آوری فاضلاب دارد ($R^2 = 0/9$). نتایج حاصل از این پژوهش دلالت بر توانایی زیاد شبکه عصبی در پیش‌بینی میزان وقوع گرفتگی شبکه جمع‌آوری فاضلاب دارد. با توجه به نتایج عملکرد شبکه عصبی و نیز مقایسه نتایج حاصله با مکان‌های

⁴ Performance

⁵ Confusion Matrix

⁶ Receiver Operating Characteristic (ROC)

¹ Hyperbolic Tangent Sigmoid

² Log-Sigmoid

³ Epoch




Fig. 8. Neural network training error histogram using Train-Validation-Test data

شکل ۸- هیستوگرام خطای آموزش شبکه عصبی با استفاده از Validation-Test

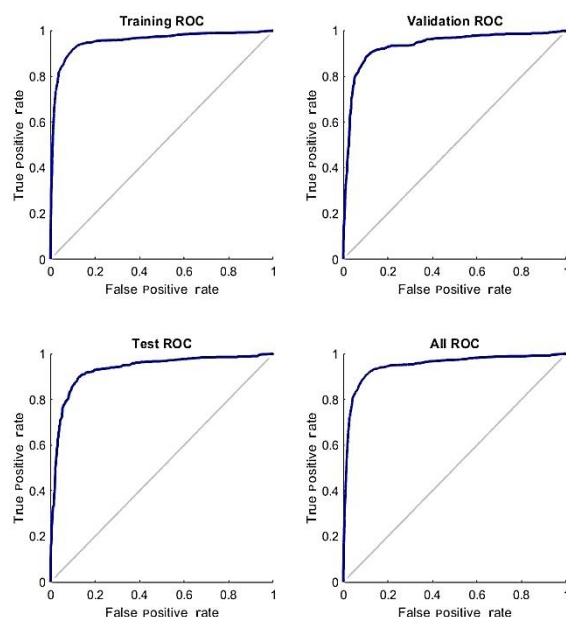


Fig. 7. ROC plot of the forecasting process with algorithm

شکل ۷- نمودار ROC فرآیند پیش‌بینی با الگوریتم MLP




Fig. 9. Performance plot of neural network training

شکل ۹- نمودار Performance آموزش شبکه عصبی داده‌های Train

آن آموزش متوقف شد. به علاوه، این رقم هیچ مشکل اساسی در طول آموزش نشان نمی‌دهد، و بهترین عملکرد اعتبارسنجی در تکرار ۵۳، 0.083261 بود.

۴-۱- داده‌های Train-Validation-Test

به‌طور کلی، با توجه به نتایج پیش‌بینی حاصل شده از شبکه عصبی و نقشه پتانسیل وقوع گرفتگی شبکه جمع‌آوری فاضلاب در بازه مورد مطالعه، می‌توان گفت که نقشه پتانسیل گرفتگی (شکل ۱۰)

عملکرد شبکه عصبی به‌کار برده می‌شود، هیستوگرام خطا^۱ است. هیستوگرام خطا رفتار شبکه عصبی را نسبت به داده‌های آموزشی نشان می‌دهد. هر چه نمودار هیستوگرام فراوانی خطای مربوط به یک روش مدل‌سازی به توزیع نرمال نزدیک باشد، عملکرد مطلوب‌تر روش استفاده شده را نشان می‌دهد. با توجه به نمودار نشان داده شده در شکل ۸، هیستوگرام خطا به توزیع نرمال نزدیک است و فراوانی خطا، بیشتر محدوده‌ی صفر محور خطا تجمع دارد.

این نمودار متقارن بوده و نشان می‌دهد که نتایج آزمون قابل قبول و توزیع خطا معقول است. یا به بیان دیگر، مدل صحت بالایی در پیش‌بینی نتایج خروجی داشته است. لازم به ذکر است که هیستوگرام خطا قادر به تشخیص داده‌های پرت^۲ است. در این برآورد، داده‌های پرت تأثیر چندانی در میزان پیش‌بینی ندارد زیرا از کل 22904 داده، میزان خطای داده‌های با فراوانی زیاد، حدود 0.05 است که مقدار بسیار ناچیزی است. شکل ۹ نمودار عملکرد آموزش شبکه را نشان می‌دهد. با توجه به نمودار، در تکرارهای بیش از ۵۰ تکرار، به کمترین مقدار خود رسید و بعد از

¹ Error Histogram

² Outlier

اما در لوله‌هایی با جدار زبر (لوله‌های بتنی) ته‌نشینی رسوبات به راحتی انجام می‌شود. در خصوص قطر لوله و سیفون، در قطرهای زیاد احتمال وقوع گرفتگی کمتر است، چون دبی جریان زیاد بوده و عواملی که باعث گرفتگی (مواد رسوبی، چربی‌ها و زباله‌ها) در لوله می‌شوند همراه با جریان فاضلاب حمل می‌شوند. شایان ذکر است که زباله‌ها در قسمت‌هایی از خط لوله با سرعت کم جمع می‌شوند و در سیستم‌های فاضلاب درهم، به دلیل ورود رواناب سطحی، زباله بیشتری وارد سیستم می‌شود. از طرفی دیگر سرعت‌های زیاد سیستم درهم در هنگام رویداد بارش، زباله‌ها را از سطح شبکه پاک کرده و زباله‌های بزرگتر را وارد سیستم می‌کند (Akhoondian and Tabesh, 2011, Anbari and Tabesh, 2016)

با توجه به اینکه گذشت زمان منجر به فرسودگی و افزایش میزان رسوب‌گیری لوله‌ها می‌شود، شکست و درز و ترک‌های ایجاد شده در جداره لوله‌ها باعث نفوذ ریشه گیاهان و درختان شده و منجر به گرفتگی‌های شدید و همراه با بالازدگی فاضلاب به سطح می‌شود. پس‌زدن آب در لوله‌های جمع‌آوری فاضلاب به علت گرفتگی در لوله، در روزهای بارندگی به کرات مشاهده شده است که علت اصلی آن اتصال غیرمجاز آبراه باران به شبکه جمع‌آوری فاضلاب و همچنین اتصال کانال‌های آب سطحی شهرداری سبب نفوذ به داخل شبکه جمع‌آوری شده و از طریق منهول‌ها بیرون زده و در سطح معابر جاری می‌شود. به علت بالا آمدن سطح آب، انواع زباله‌ها و فضولات در نقاط مختلف پخش شده که جمع‌آوری و دفع آنها نیز مشکلاتی را به همراه خواهد داشت. عمق و قطر انشعاب کار گذاشته شده با توجه به نوع کاربری و تعداد واحدهای ساختمانی متفاوت است. لازم به ذکر است، هرچه قطر لوله‌های جمع‌آوری فاضلاب کمتر باشد، احتمال وقوع حادثه در آن بیشتر خواهد بود. علت اصلی این امر ساخت‌وسازهای اخیر مجتمع‌های مسکونی با تراکم زیاد و عدم رعایت استانداردهای موجود در نصب انشعاب مشترکین است که خود این امر احتمال بروز پس‌زدگی و گرفتگی در لوله را افزایش می‌دهد.

۵- نتیجه‌گیری

در این پژوهش، نقشه پتانسیل وقوع حادثه (گرفتگی) لوله‌های جمع‌آوری شبکه فاضلاب شهر تهران با استفاده از ابزارهای GIS و شبکه عصبی مصنوعی تولید شد. در مدل پیشنهادی از شبکه‌های

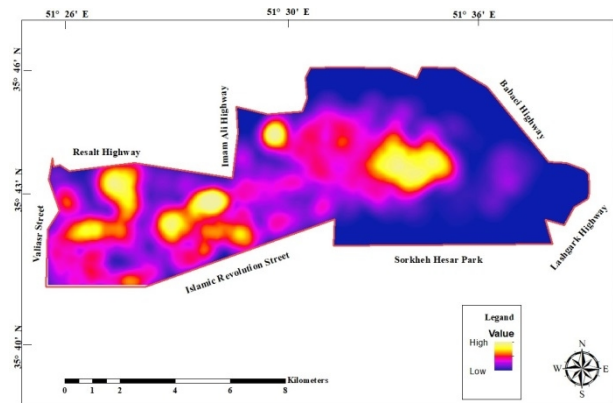


Fig. 10. Potential map of the occurrence of blockage in the study area

شکل ۱۰- نقشه پتانسیل وقوع گرفتگی در محدوده مورد مطالعه

می‌تواند بازتاب مناسبی از وضعیت عملکرد شبکه در جمع‌آوری فاضلاب، نقاط پرخطر نواحی مختلف آبفای منطقه ۲ تهران باشد. به طوری که نواحی با پتانسیل وقوع گرفتگی زیاد در بافت‌های فرسوده با تراکم جمعیتی زیاد قرار می‌گیرد. بدیهی است که تراکم نسبی جمعیت، احتمال وقوع گرفتگی را افزایش می‌دهد. بر اساس نقشه خروجی، بخش‌هایی از شبکه فاضلاب با پتانسیل وقوع گرفتگی زیاد برطبق فاکتورهای موردنظر و به‌طور پراکنده قسمت‌هایی از حد فاصل خیابان زهدی تا خیابان احسان در ضلع شرقی محدوده و بخش‌هایی از منطقه ۷ و ۸ شهرداری را در برگیرد. بافت فرسوده، تراکم جمعیت زیاد در یک سطح مشخص و عدم رعایت استانداردهای لازم در نصب انشعاب (نصب انشعاب غیرمجاز) از عمده دلایل گرفتگی در این بخش‌ها هستند. وقوع بارندگی‌های شدید و به دنبال آن پس‌زدن آب در لوله‌های فاضلاب، سبب سرریز شدن آموها، مخازن فضولات و چاه‌های فاضلاب می‌شود. در حالی که در بخش‌های شمالی، حد فاصل مجیدآباد و بزرگراه بابایی به دلیل تراکم جمعیت کم، ساخت‌وسازهای نسبتاً جدید و اجرای صحیح انشعاب فاضلاب، فراوانی وقوع گرفتگی به مراتب کمتر مشاهده می‌شود (Akhoondian and Tabesh, 2011, Mohammadi and Noori, 2018, Norouzi, and Ghahroudi, 2018)

از نظر جنس لوله، هر چه مقاومت و انعطاف مواد تشکیل‌دهنده بیشتر باشد، میزان وقوع گرفتگی به میزان قابل توجهی کاهش پیدا می‌کند. بر اساس آمار گرفتگی‌های گزارش شده در شبکه جمع‌آوری فاضلاب، لوله‌ها با جنس پلی‌اتیلن، پتانسیل گرفتگی کمتری دارند،

دقت‌های بهتری دست یافت. نقشه این پیش‌بینی را می‌توان در اولویت‌بندی بازرسی خطوط فاضلاب موجود در شبکه به‌کار برد و عملکرد و کارایی شبکه را افزایش داد.

به‌طور کلی، تجزیه و تحلیل حوادث شبکه می‌تواند به تعیین دلایل اصلی برای گرفتگی در خطوط لوله جمع‌آوری فاضلاب در بخش‌های خاصی از شبکه کمک کرده و تغییرات در اجرای شبکه را ساماندهی کند. با توجه به تفاوت‌های کمی و کیفی موجود در فاضلاب‌های تولید شده از منابع مختلف و پاسخ‌گو بودن این تأسیسات نسبت به نیاز مشترکین، ضروری است که اتصالات و انشعابات متناسب با نوع محل تولید فاضلاب طراحی و اجرا شود.

با توجه به اینکه گذشت زمان منجر به فرسودگی تخریب‌جداره لوله‌ها می‌شود، بنابراین برای جلوگیری از گرفتگی‌های متوالی تدابیری برای نوسازی لوله‌ها باید در نظر گرفته شود. شایان ذکر است که نتایج حاصل از این پیش‌بینی را می‌توان در زمینه اقدامات پیشگیرانه، اولویت‌بندی در بازرسی شبکه فاضلاب به‌کار برد و در نتیجه از وقوع شرایط بحرانی جلوگیری کرد.

عصبی مصنوعی به‌منظور تعیین پارامترهای مؤثر در وقوع گرفتگی لوله‌های فاضلاب استفاده شد. تأسیسات آب و فاضلاب در کلان‌شهر تهران از سازه‌های مهم و شریان‌های حیاتی محسوب می‌شود. در پی وقوع هر نوع حادثه‌ای در شبکه جمع‌آوری فاضلاب به‌طور طبیعی تأسیسات شبکه در معرض آسیب‌پذیری قرار می‌گیرند. اگرچه مقدار این آسیب‌پذیری بسیار ناچیز است، ولی می‌تواند علاوه بر صدمات و خسارات مستقیم وارده در ترکیب با دیگر تأسیسات و ابنیه‌ها، خطرات و خسارات ثانویه‌ای را به‌دنبال داشته باشد که باعث ایجاد شرایط بحرانی می‌شود (Norouzi and Ghahroudi, 2018).

لازم به ذکر است که عدم‌رعایت استانداردها و اصول پایه‌ای در طراحی شبکه جمع‌آوری فاضلاب منجر به وقوع حوادث متعددی در شبکه شده و به دنبال آن بار اقتصادی سنگینی به‌منظور رفع این حوادث در پی خواهد داشت. با توجه به شاخص‌های ارزیابی، دقت پیش‌بینی ۰/۹ ارزیابی شد. البته در صورت امکان استفاده از داده‌های بیشتر، با دوره زمانی طولانی‌تر، با دقت بیشتر و در منطقه جغرافیایی وسیع‌تر برای آموزش شبکه عصبی، قطعاً می‌توان به

References

- Ahn, J., Lee, S., Lee, G. & Koo, J. 2005. Predicting water pipe breaks using neural network. *Water Science and Technology: Water Supply*, 5, 159-172.
- Akhoondian, S. & Tabesh, M. 2011. Optimal performance-based design of wastewater collection systems. *Journal of Civil and Surveying Engineering*, 45(3), 267-278. (In Persian)
- Anbari, M. J. & Tabesh, M. 2016. Failure event probability calculation in wastewater collection systems using the bayesian network. *Journal of Water and Wastewater*, 27(3), 48-61. (In Persian)
- Anbari, M. J., Tabesh, M. & Roozbahani, A. 2017. Risk assessment model to prioritize sewer pipes inspection in wastewater collection networks. *Journal of Environmental Management*, 190, 91-101.
- Arjun, K. & Aneesh, K. 2015. Modelling studies by application of artificial neural network using matlab. *Journal of Engineering Science and Technology*, 10, 1477-1486.
- Asnaashari, A., Mcbean, E. A., Gharabaghi, B. & Tutt, D. 2013. Forecasting watermain failure using artificial neural network modelling. *Canadian Water Resources Journal*, 38, 24-33.
- Baah, K., Dubey, B., Harvey, R. & Mcbean, E. 2015. A risk-based approach to sanitary sewer pipe asset management. *Science of the Total Environment*, 505, 1011-1017.
- Baik, H. S., Jeong, H. S. & Abraham, D. M. 2006. Estimating transition probabilities in Markov chain-based deterioration models for management of wastewater systems. *Journal of Water Resources Planning and Management*, 132, 15-24.
- Caudill, M. 1988. Neural networks primer, Part III. *AI Expert*, 3(6), 53-59.
- Davies, J., Clarke, B., Whiter, J. & Cunningham, R. 2001. Factors influencing the structural deterioration and collapse of rigid sewer pipes. *Urban Water*, 3, 73-89.

- Despagne, F. & Massart, D. L. 1998. Neural networks in multivariate calibration. *Analyst*, 123, 157R-178R.
- Elmasry, M., Zayed, T. & Hawari, A. 2018. Defect-based ArcGIS tool for prioritizing inspection of sewer pipelines. *Journal of Pipeline Systems Engineering and Practice*, 9, 04018021.
- Ghavami, S. M., Borzooei, Z. & Maleki, J. 2020. An effective approach for assessing risk of failure in urban sewer pipelines using a combination of GIS and AHP-DEA. *Process Safety and Environmental Protection*, 133, 275-285.
- Greene, R., Agbenowosi, N. & Loganathan, G. 1999. GIS-based approach to sewer system design. *Journal of Surveying Engineering*, 125, 36-57.
- Grigg, N. S. 2012. *Water, Wastewater and Stormwater Infrastructure Management*, (2nd Ed.) CRC Press. Florida, USA.
- Hahn, M. A., Palmer, R. N., Merrill, M. S. & Lukas, A. B. 2002. Expert system for prioritizing the inspection of sewers: knowledge base formulation and evaluation. *Journal of Water Resources Planning and Management*, 128, 121-129.
- Hahn, M., Palmer, R. N. & Merrill, M. S. 1999. Prioritizing sewer line inspection with an expert system. 29th *Annual Water Resources Planning and Management Conference*, Arizona, USA.
- Hecht-Nielsen, R. 1992. Theory of the backpropagation neural network. *Neural Networks for Perception*. Computation, Learning and Architectures, 1992, 65-93.
- Jafar, R., Shahrour, I. & Juran, I. 2010. Application of Artificial Neural Networks (ANN) to model the failure of urban water mains. *Mathematical and Computer Modelling*, 51, 1170-1180.
- Khan, Z., Zayed, T. & Moselhi, O. 2009. Simulating impact of factors affecting sewer network operational condition. *Canadian Society for Civil Engineering Annual Conference*. Newfoundland, Canada.
- Laakso, T., Kokkonen, T., Mellin, I. & Vahala, R. 2018. Sewer condition prediction and analysis of explanatory factors. *Water*, 10, 1239.
- Mohammadi, E. P. & Noori, S. 2018. Spatial analysis of urban sewage network events using GIS. a case study of Ardabil city. *Urban Planning*, 34(9), 105-118.
- Najjar, Y. M. & Basheer, I. A. 1996. A neural network approach for site characterization and uncertainty prediction. *Uncertainty in the Geologic Environment: from Theory to Practice*, Proceeding, Wisconsin, USA.
- Norouzi, R. & Ghahroudi, T. M. 2018. Zoning sewage network vulnerability against natural hazards. *Journal of Regional Planning*, 34(9), 149-162. (In Persian)
- Rahgozar, M. A., Zare, M. R. & Hashemi Fesharaki, S. M. 2016. An intelligent network proposed for assessing seismic vulnerability index of sewerage networks within a GIS framework (a case study of Shahr-e-Kord). *Journal of Water and Wastewater*, 26(6), 5-15. (In Persian)
- Sullivan, R. H. 1977. *Economic Analysis, Root Control and Backwater Flow Control as Related to Infiltration/Inflow Control*. Municipal Environmental Research Laboratory, Office of Research and Development, US Environmental Protection Agency, USA.
- Tahzibi, K. M. N., Mashoof, B. & Nasibi, M. 2015. Evaluation of vulnerability in water conveyance systems using the clustering method. *Crisis Management*, 4(7), 97-104. (In Persian)
- Ugarelli, R., Venkatesh, G., Brattebø, H., Di Federico, V. & Sægrov, S. 2010a. Asset management for urban wastewater pipeline networks. *Journal of Infrastructure Systems*, 16, 112-121.
- Ugarelli, R., Venkatesh, G., Brattebø, H., Di Federico, V. & Sægrov, S. 2010b. Historical analysis of blockages in wastewater pipelines in Oslo and diagnosis of causative pipeline characteristics. *Urban Water Journal*, 7, 335-343.



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).