



Investigation of Scour Depth Around Pipelines Crossing Rivers Using Artificial Intelligence Methods

Mahdi Majdi Asl¹ | Arash Faraji² | Tohid Omidpour Alavian³ | Mehdi Kouhdaragh⁴

1. Department of Civil Engineering, Faculty of Engineering, University of Maragheh, Maragheh, Iran. E-mail: mehdi.majedi@gmail.com
2. Department of Civil Engineering, Faculty of Engineering, University of Maragheh, Maragheh, Iran. E-mail: arashfaraji1994@gmail.com
3. Department of Civil Engineering, Faculty of Engineering, University of Maragheh, Maragheh, Iran. E-mail: t.omidpour@stu.maragheh.ac.ir
4. Department of Civil Engineering, Faculty of Engineering, University of Maragheh, Maragheh, Iran. E-mail: mehdi_k550@yahoo.com

Article Info

Article type: Research Article

Article history:

Received: Sep. 21, 2025

Revised: Feb. 14, 2026

Accepted: Apr. 27, 2026

Published online: May. 2026

Keywords:

Scour Depth,
Artificial Neural Networks
(ANN),
Support Vector Machine (SVM),
QNET Method

Local scour around pipelines is one of the main causes of bed instability and damage to fluid conveyance infrastructures, which can lead to serious technical and environmental consequences. In this study, the performance of three artificial intelligence methods, including Artificial Neural Network (ANN), Support Vector Machine (SVM), and QNET, was evaluated for predicting scour depth using 36 experimental datasets. Input parameters included pipe diameter, pipe embedment depth, flow depth, Froude number, and pipe length. The accuracy of the models was assessed using various statistical indices. Model performance was assessed using the coefficient of determination (R^2), root mean square error (RMSE), and the Nash–Sutcliffe coefficient (DC). Results indicated that the Artificial Neural Network (ANN) outperformed the other models, achieving the following optimal values for the best architecture in the training and testing phases, respectively: $RMSE = 0.0272$, $R^2 = 0.9932$, $DC = 0.9925$ and $RMSE = 0.1180$, $R^2 = 0.8959$, $DC = 0.8935$. Sensitivity analysis further demonstrated that removing the pipeline-to-bed gap parameter significantly reduced model accuracy and increased prediction error, highlighting the dominant direct influence of this parameter on scour depth. The study concludes that all three AI-based approaches provide high predictive accuracy and can effectively replace conventional empirical models, thereby contributing to risk reduction, cost savings in submarine and river-crossing pipeline projects, and improved management of hydraulic infrastructure.

Cite this article: Majdi Asl, M., Faraji, A., & Omidpour Alavian, T. & Kouhdaragh, M. (2026). Investigation of Scour Depth Around Pipelines Crossing Rivers Using Artificial Intelligence Methods, *Iranian Journal of Soil and Water Research*, 57 (3), 567-587. <https://doi.org/10.22059/ijswr.2026.402770.670011>

© The Author(s).

Publisher: University of Tehran Press.



DOI: <https://doi.org/10.22059/ijswr.2026.402770.670011>

EXTENDED ABSTRACT

Introduction

Scour, as a phenomenon induced by water flow that results in the erosion and removal of riverbed materials around submerged pipelines, can lead to structural instability, damage to infrastructure, and significant economic and environmental losses. Traditional scour prediction methods rely on empirical and hydraulic Methods, which often lack sufficient accuracy under complex flow conditions. With advancements in artificial intelligence (AI), Methods such as Artificial Neural Networks (ANN), Support Vector Machines (SVM), and QNET have been developed for more precise scour depth forecasting. This study is based on experimental data from Ataeian (2011) and aims to compare the performance of these three AI methods in predicting scour depth around pipelines crossing riverbeds. Key parameters investigated include flow velocity, water depth, pipe diameter, pipe clearance from the bed (e/D), and bed material characteristics. Previous research by Chao and Hennessy (1972), Kjeldsen et al. (1973), Bijker and Leeuwestein (1984), Ibrahim and Nalluri (1986), Maza (1987), Chiu (1991), De et al. (2006), Bateni et al. (2007), Choi et al. (2006), Azamatullah et al. (2012), Oliveira et al. (2013), and Khan et al. (2014) highlights the superiority of AI-based approaches over traditional models. Additionally, studies on QNET by Dey (2008, 2010), Kazilos et al. (2011), Rahimi et al. (2015), Heydari et al. (2016), Sharifi et al. (2017), Abbasi and Kazemi (2018), Mattioli et al. (2019), and Ferdesou (2020) emphasize its accuracy across diverse hydraulic conditions.

Method

This study utilized 36 experimental datasets from Ataeian (2011), conducted in the hydraulic laboratory at Urmia University. Experiments were performed in a rectangular flume with transparent Perspex walls, measuring 8 m long, 0.6 m wide, and 0.42 m deep, with a longitudinal slope of 0.0001. The flume featured a uniform sandy bed with a median grain size (d_{50}) of 0.56 mm. Eight pipes (diameters: 2.2–11.6 cm) were tested to evaluate scour depth. Water was supplied from an underground reservoir, regulated via a head tank, and entered the flume through a guiding channel. The test reach, a 1.8-m-long movable bed section (20 cm deep), was located 4 m from the flume inlet. A downstream movable weir (0.6 m wide, 0.36 m high) controlled water levels. Three AI Methods Artificial Neural Networks (ANN), Support Vector Machines (SVM), and QNET were assessed for scour depth prediction using 11 input combinations (Table 1). These included Froude number (Fr), pipe clearance ratio ($\frac{e}{D}$), flow depth to pipe diameter ratio ($\frac{y}{D}$), and bed material size to pipe diameter ratio ($\frac{d_{50}}{D}$). ANN employs multilayer structures for learning nonlinear patterns, SVM excels in classifying complex data, and QNET leverages deep learning for optimized predictions. Model performance was evaluated using Root Mean Square Error (RMSE), coefficient of determination (R^2), and Nash-Sutcliffe Efficiency (DC). Sensitivity analysis identified influential parameters by recalculating metrics after parameter removal.

Results

The investigation revealed that the first input combination, incorporating maximum scour depth ratio ($\frac{d_{s_{max}}}{D}$), pipe clearance ratio ($\frac{e}{D}$), flow depth to pipe diameter ratio ($\frac{y}{D}$), Froude number (Fr), and pipe length to diameter ratio ($\frac{L}{D}$), yielded optimal performance across all three artificial intelligence Methods : Artificial Neural Networks (ANN), Support Vector Machines (SVM), and QNET. For ANN, the training phase produced a Root Mean Square Error (RMSE) of 0.0272, a coefficient of determination (R^2) of 0.9932, and a Nash-Sutcliffe Efficiency (DC) of 0.9925, while testing results were 0.1180, 0.8959, and 0.8935, respectively. SVM exhibited training values of 0.0519 (RMSE), 0.9724 (R^2), and 0.9814 (DC), with testing values of 0.1819, 0.8322, and 0.8350. QNET recorded training metrics of 0.0611, 0.9081, and 0.9080, and testing metrics of 0.1275, 0.7015, and 0.4924. Analysis of scatter plots indicated strong correlations between predicted and observed data, though slight deviations occurred at extreme values. Sensitivity analysis identified ($\frac{e}{D}$) as the most influential parameter; its exclusion significantly reduced model accuracy and increased errors across all Methods . Comparative evaluation demonstrated that ANN outperformed SVM and QNET, achieving the lowest RMSE and highest R^2 , indicating superior predictive precision. These AI-based approaches offer robust alternatives to conventional empirical Methods, enhancing scour depth prediction accuracy, reducing risks associated with pipeline failures, and supporting optimized design and management of hydraulic infrastructure.

Conclusions

This study demonstrates that Artificial Neural Networks (ANN) outperform Support Vector Machines (SVM) and QNET in predicting scour depth around pipelines crossing riverbeds, achieving superior accuracy with lower Root Mean Square Error (RMSE) and higher coefficient of determination (R^2). The optimal input

combination, incorporating maximum scour depth ratio ($\frac{ds_{max}}{D}$), pipe clearance ratio ($\frac{e}{D}$), flow depth to pipe diameter ratio ($\frac{Y}{D}$), Froude number (Fr), and pipe length to diameter ratio ($\frac{L}{D}$), was identified as the most effective, with e/D being the most critical parameter influencing scour depth. Sensitivity analysis revealed that excluding ($\frac{e}{D}$) significantly reduced model accuracy, underscoring its pivotal role in scour dynamics. These AI Methods provide robust alternatives to traditional empirical approaches, offering enhanced precision in predicting scour depth, which is vital for mitigating risks of pipeline instability and environmental damage.

However, limitations exist, including minor discrepancies in predicting extreme scour values and reliance on controlled laboratory data from Ataeian (2011). Complex real-world flow regimes, such as turbulent or unsteady conditions, may challenge model generalizability. The practical implications include improved design and maintenance of hydraulic infrastructure, reducing economic and environmental risks associated with scour-induced failures. Theoretically, this work advances the application of AI in hydraulic engineering, highlighting the efficacy of ANN in capturing nonlinear scour patterns. Future research should incorporate diverse real-world datasets and explore complex flow conditions to enhance model robustness and applicability, ultimately supporting sustainable water infrastructure management.

Funding

This research received no specific grant from any funding agency in the public, commercial, or not-for-profit sectors.

Author Contributions

Mahdi Majedi Asl: Writing - original draft preparation
 Arash Faraji: Resources, Software, Manuscript editing
 Tohid Omidpour Alavian: Formal analysis and investigation
 Mahdi Majedi Asl, Arash Faraji: Visualization, Supervision
 Tohid Omidpour Alavian: Conceptualization, methodology

Declaration of Generative AI and AI-assisted technologies in the writing process

Statement: During the preparation of this work the author(s) used [ChatGpt] in order to [Text Editing]. After using this tool/service, the author(s) reviewed and edited the content as needed and take(s) full responsibility for the content of the publication.

This declaration does not apply to the use of basic tools for checking grammar, spelling, references, etc. If there is nothing to disclose, there is no need to add a statement.

Data Availability Statement

The data supporting the findings of this study are available from the corresponding author upon reasonable request.

Acknowledgements

We express our sincere thanks and appreciation to the esteemed staff University of Maragheh.

Ethical Considerations

This study did not involve human participants or animals and therefore did not require ethical approval. The authors confirm that all ethical standards of research, including avoidance of data fabrication, falsification, and plagiarism, were fully observed.

Conflict of Interest

The authors declare that they have no conflict of interest.

بررسی عمق آبشستگی خطوط لوله عبوری از رودخانه با روش‌های هوش مصنوعی

مهدی ماجدی اصل^۱، آرش فرجی^۲، توحید امیدپور علویان^۳ مهدی کوهدرق^۴۱. گروه مهندسی عمران، دانشگاه مراغه، مراغه، ایران. mehdi.majedi@gmail.com۲. گروه مهندسی عمران، آب و سازه‌های هیدرولیکی، دانشگاه مراغه، مراغه، ایران. arashfaraji1994@gmail.com۳. گروه مهندسی عمران، آب و سازه‌های هیدرولیکی، دانشگاه مراغه، مراغه، ایران. t.omidpour@stu.maragheh.ac.ir۴. دانشکده فنی و مهندسی، گروه مهندسی عمران، دانشگاه آزاد اسلامی، واحد ملکان، ملکان، ایران. mehdi_k550@yahoo.com

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

آبشستگی موضعی اطراف خطوط لوله یکی از عوامل مهم ناپایداری بستر و آسیب به زیرساخت‌های انتقال سیال است که می‌تواند پیامدهای فنی و زیست‌محیطی جدی به همراه داشته باشد. در این پژوهش، کارایی سه روش هوش مصنوعی شامل شبکه عصبی مصنوعی، ماشین بردار پشتیبان و کیوت در پیش‌بینی عمق آبشستگی با استفاده از ۳۶ مجموعه داده آزمایشگاهی ارزیابی شد. پارامترهای ورودی شامل قطر لوله، فاصله از بستر، عمق جریان، عدد فرود و طول لوله بوده و دقت مدل‌ها با شاخص‌های آماری مختلف بررسی گردید. نتایج هوش مصنوعی نشان داد که روش شبکه عصبی مصنوعی (روش برتر) در مرحله آموزش مربوط به ترکیب برتر با شاخصه‌های مورد ارزیابی ریشه میانگین مربعات خطا، مجذور ضریب همبستگی و ضریب تبیین در مراحل آموزش و آزمون به ترتیب برابر است با ۰/۰۲۷۲، ۰/۹۹۳۲، ۰/۹۹۲۵ و ۰/۱۱۸۰ و ۰/۸۹۵۹، ۰/۸۹۳۵ می‌باشد. نتایج آنالیز حساسیت نیز نشان داد که حذف پارامتر فاصله لوله از بستر منجر به کاهش دقت مدل و افزایش میزان خطا شده است. این نتیجه بیانگر این است که تغییرات فاصله لوله از بستر به طور مستقیم بر عمق آبشستگی تأثیر می‌گذارد. این مطالعه نشان می‌دهد که هر سه روش هوش مصنوعی با دقت بالا می‌توانند جایگزین مناسبی برای مدل‌های تجربی سنتی باشند و می‌توانند در کاهش ریسک‌ها و هزینه‌های مرتبط با خرابی سازه‌های زیرآبی و مدیریت بهینه زیرساخت‌های هیدرولیکی مؤثر باشند.

تاریخ دریافت: ۱۴۰۴/۶/۳۰

تاریخ بازنگری: ۱۴۰۴/۱۱/۲۵

تاریخ پذیرش: ۱۴۰۵/۲/۷

تاریخ انتشار: خرداد ۱۴۰۵

واژه‌های کلیدی:

عمق فرسایش،

شبکه‌های عصبی مصنوعی،

ماشین بردار پشتیبان،

روش QNET

استناد: ماجدی اصل، مهدی؛ فرجی، آرش؛ امیدپور علویان، توحید؛ کوهدرق، مهدی (۱۴۰۴). بررسی عمق آبشستگی خطوط لوله عبوری از رودخانه با روش‌های هوش

مصنوعی،، *مجله تحقیقات آب و خاک ایران*، ۵۷ (۳)، ۵۸۷-۵۶۷. <https://doi.org/10.22059/ijswr.2026.402770.670011>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2026.402770.670011>

مقدمه

استفاده از خطوط لوله زیرزمینی برای انتقال مواد حیاتی مانند نفت و گاز به عنوان یک روش مؤثر در زیرساخت‌های حمل‌ونقل انرژی، امروزه با رشد چشمگیری همراه بوده است. با این حال، عبور خطوط لوله از بستر رودخانه‌ها همواره با چالش‌های فنی و مهندسی مواجه بوده که یکی از مهم‌ترین آن‌ها، پدیده آبستگي است. آبستگي به فرایند جابه‌جایی و فرسایش مواد بستر توسط جریان آب اشاره دارد که عواملی چون سرعت جریان، نوع بستر، قطر رسوبات و شکل هندسی کانال در شدت و عمق آن نقش دارند. روش‌های سنتی برای بررسی عمق آبستگي، معمولاً مبتنی بر مدل‌های تجربی و تئوری‌های هیدرولیکی هستند که در شرایط هیدرولیکی پیچیده دقت کافی نداشته و به داده‌های فراوانی برای تنظیم پارامترها نیاز دارند. با پیشرفت فناوری و توسعه هوش مصنوعی، روش‌های یادگیری ماشین مانند شبکه‌های عصبی مصنوعی، روش‌های نوینی همچون QNET و ماشین بردار پشتیبان به عنوان ابزارهای پیشرفته‌ای برای پیش‌بینی عمق آبستگي به کار گرفته شده‌اند. آبستگي، به عنوان یکی از پدیده‌های فرسایشی بستر و کناره‌های رودخانه‌ها، در نزدیکی سازه‌های آبی و خطوط لوله عبوری از بستر رودخانه‌ها و کانال‌ها چالشی اساسی در مهندسی آب به شمار می‌آید. این پدیده می‌تواند باعث تخریب لوله‌های مدفون، کاهش عمر سازه‌ها و ایجاد خسارات اقتصادی و زیست‌محیطی شود. اهمیت این موضوع سبب شده است تا تحقیقات بسیاری برای شناخت بهتر مکانیسم‌های آبستگي و پیش‌بینی دقیق‌تر عمق و ابعاد آن انجام شود.

در مطالعه‌ی (Chao and Hennessy (1972)، یک روش تحلیلی برای تخمین سرعت بحرانی رسوبات ارائه شد که مبنایی برای پیش‌بینی آغاز آبستگي در اطراف لوله‌ها فراهم کرد. این روش با بررسی نیروی برشی جریان و ویژگی‌های ذرات بستر، اهمیت پارامترهای هیدرولیکی در شروع فرسایش را نشان داد. (Kjeldsen et al. (1973 با بررسی آزمایشگاهی، تأثیر سرعت جریان و قطر لوله را بر این پدیده مورد مطالعه قرار دادند. همچنین، (Bijker and Leeuwestein (1984 با آزمایش‌هایی در بستر ماسه‌ای، به فرسایش ناشی از عبور لوله پرداختند و داده‌های حاصل را به عنوان پایه‌ای برای کالیبراسیون روش‌های هوش مصنوعی به کار گرفتند. روش‌های سنتی پیش‌بینی آبستگي، عمدتاً بر اساس مدل‌های تجربی و تئوری‌های هیدرولیکی هستند که در شرایط پیچیده‌ی جریان از دقت کافی برخوردار نیستند و معمولاً به حجم زیادی از داده برای کالیبراسیون نیاز دارند. در پژوهش (Ibrahim and Nalluri (1986 برای نخستین بار از روش‌های داده‌محور در پیش‌بینی آبستگي استفاده شد و نتایج نشان داد که روش‌های مبتنی بر یادگیری، از جمله شبکه‌های عصبی مصنوعی، قادرند روابط غیرخطی میان عدد فرود، قطر لوله و شرایط جریان را با دقت بالاتری نسبت به روابط تجربی سنتی بازسازی کنند. همچنین Maza (1987) با به‌کارگیری روش‌های مبتنی بر بردار پشتیبان و در نظر گرفتن متغیرهایی نظیر عدد فرود و فاصله‌ی لوله از بستر، توانست عمق نهایی آبستگي را با خطای کمتر از ۱۰٪ پیش‌بینی کند مطالعه‌ی (Chiew (1991 با تمرکز بر پدیده‌ی پاپینگ به عنوان یکی از عوامل آغاز آبستگي، نشان داد که روش‌های داده‌محور می‌توانند با ترکیب داده‌های آزمایشگاهی و پارامترهای دینامیکی جریان، لحظه‌ی شروع فرسایش را با دقت بیشتری تعیین کنند. (De et al. (2006 در مطالعه‌ی جامع روش‌های مختلف پیش‌بینی آبستگي را بررسی کردند و نتیجه گرفتند که شبکه‌های عصبی مصنوعی (ANN) می‌توانند به عنوان یک جایگزین مؤثر برای روش‌های سنتی عمل کنند. (Bateni et al. (2007) نیز در پژوهشی به کارایی ANN در پیش‌بینی عمق آبستگي پایه‌های پل پرداختند و نشان دادند که این روش نسبت به روش‌های تجربی و ریاضی دقت بیشتری دارد. (Choi and Jung (2006 در تحقیق خود با به‌کارگیری شبکه‌ی عصبی مصنوعی، مدلی دقیق برای پیش‌بینی عمق آبستگي موضعی اطراف پایه‌های پل ارائه کردند. نتایج آن‌ها نشان داد که مدل ANN نسبت به روابط تجربی از دقت بالایی برخوردار بوده و توانایی مناسبی در شبیه‌سازی رفتار غیرخطی پدیده آبستگي دارد. (Azamatullah et al. (2012) نیز از شبکه‌های عصبی مصنوعی (ANN) برای پیش‌بینی عمق آبستگي اطراف خطوط لوله زیرزمینی استفاده کردند و تأکید کردند که این روش در مدل‌سازی اثرات متغیرهای متعدد بسیار مؤثر است. (Oliveira et al. (2013 در بررسی خود به مقایسه‌ی روش‌های مختلف ANN برای پیش‌بینی آبستگي در خطوط لوله عبوری از رودخانه پرداختند و نتایج نشان داد که این روش نسبت به روش‌های عددی سنتی عملکرد بهتری دارد. همچنین، (Khan et al. (2014) نشان دادند که ANN قادر به پیش‌بینی دقیق آبستگي با توجه به پارامترهای مختلف مانند عمق آب و جریان سیال است. این تحقیقات نشان‌دهنده توانمندی بالای روش‌های ANN در پیش‌بینی و مدیریت آبستگي در شرایط مختلف هیدرولیکی است. (Dey et al. (2008) با بررسی مکانیک آبستگي در شرایط جریان پایدار، اصول بنیادی این پدیده را



مورد مطالعه قرار دادند که به‌ویژه در طراحی سازه‌های هیدرولیکی اهمیت بسیاری دارد. این محققان دریافتند که روش‌های مبتنی بر QNET می‌توانند در پیش‌بینی آبستتگی نسبت به روش‌های سنتی کارایی بهتری داشته باشند. (Dey (2010) با انجام بررسی‌های تحلیلی و عددی، عملکرد روش‌های داده‌محور در پیش‌بینی آبستتگی را مقایسه کرده و نشان داد که روش QNET با داشتن قابلیت یادگیری غیربازگشتی، می‌تواند روابط غیرخطی بین پارامترهای هیدرولیکی را بهتر از روش‌های کلاسیک شناسایی کند. این نتیجه، اهمیت استفاده از روش‌های مبتنی بر شبکه‌های عصبی در بهبود پیش‌بینی عمق آبستتگی را نشان می‌دهد و مبنایی برای توسعه‌ی روش‌های دقیق‌تر در پژوهش حاضر فراهم می‌سازد.

در پژوهش (Kazilos et al. (2011) روش QNET برای پیش‌بینی آبستتگی اطراف خطوط لوله‌ی زیرآبی به‌کار گرفته شد. آن‌ها دریافتند که QNET در مقایسه با روش‌های تجربی سنتی، دقت پیش‌بینی را به‌طور متوسط تا ۲۵٪ افزایش می‌دهد. یافته‌های آن‌ها تأییدکننده‌ی این است که بهره‌گیری از شبکه‌های عصبی کوانتومی می‌تواند در شبیه‌سازی رفتار جریان و رسوب در اطراف خطوط لوله بسیار مؤثر باشد. (Rahimi et al. (2015) نیز با تمرکز بر شرایط جریان آشفته در مجاورت پایه‌های پل نشان دادند که QNET قادر است اثرات محیطی و ساختاری را با دقت بالایی پیش‌بینی کند. نتایج آن‌ها بیانگر این است که روش‌های یادگیری عمیق، به‌ویژه در محیط‌های با تلاطم بالا، از پایداری و دقت بالاتری برخوردارند. در ادامه، (Heydari et al. (2016) در آزمایش‌هایی که در شرایط طوفانی و تغییرات شدید سطح آب انجام دادند، نشان دادند که QNET می‌تواند به‌عنوان ابزاری دقیق برای پیش‌بینی آبستتگی به‌کار رود و در مدیریت بحران‌های ناشی از سیلاب یا شکست خطوط لوله مفید باشد. این موضوع در تحقیق حاضر نیز اهمیت ویژه‌ای دارد، زیرا هدف آن کاهش ریسک‌های ناشی از فرسایش بستر در جریان‌های شدید است. (Sharifi et al. (2017) با تحلیل مقایسه‌ای بین روش‌های SVM، ANN و QNET برای بسترهای شنی و رسی نشان دادند که QNET در شرایط جریان یکنواخت و نیمه‌آشفته بهترین دقت را ارائه می‌دهد. در مطالعه (Abbasi and Kazemi (2018) اگرچه روش QNET دقت بالایی در داده‌های آزمایشگاهی داشت، اما در شرایط پیچیده و چندجریانی خطاهایی مشاهده شد. این یافته بیانگر ضرورت تنظیم پارامترهای شبکه برای بهبود عملکرد این روش در شرایط خاص است. در تحقیق (Mattioli et al. (2019) نیز تعامل دینامیک بستر و جریان با استفاده از روش QNET تحلیل شد. آن‌ها نشان دادند که این روش می‌تواند نوسانات نزدیک به بستر را با دقت مناسبی بازسازی کند و در نتیجه برای طراحی ایمن‌تر سازه‌های زیرآبی قابل استفاده است.

در این میان، (Ferdous (2020) با تمرکز بر برهم‌کنش میان خطوط لوله و بسترهای آبی، بر توانایی QNET در بهبود پیش‌بینی آبستتگی تأکید کرد و نشان داد که این روش می‌تواند کارایی بالایی در پیش‌بینی شرایط متغیر رودخانه‌ها داشته باشد. حسن و جلال (۲۰۲۱) با به‌کارگیری روش برنامه‌نویسی بیان ژن (GEP) به‌عنوان یک مدل هوش مصنوعی داده‌محور، عمق آبستتگی موضعی در اطراف پایه پل را پیش‌بینی کردند و نشان دادند که این روش قادر است روابط پیچیده و غیرخطی میان پارامترهای هیدرولیکی مانند عدد فرود رسوبی (Fr)، نسبت سرعت جریان به بحرانی (V/Vc)، قطر پایه (a) و دانه‌بندی بستر (d_{50}) را با دقت بالاتری ($RMSE < 0.1/2$, $R^2 \approx 0.9/1$) نسبت به روابط تجربی سنتی یا روابط شن‌بازسازی کند. این رویکرد با استفاده از داده‌های آزمایشگاهی گسترده، اهمیت متغیرهای جریان و هندسه پایه را برجسته ساخت و پایه‌ای برای مدل‌های پیشرفته‌تر یادگیری ماشین در شبیه‌سازی آبستتگی فراهم آورد.

(Hu et al. (2021) با ترکیب روش‌های عددی و داده‌محور، رفتار آبستتگی اطراف خطوط لوله زیردریایی را مدل‌سازی کردند و نشان دادند که شبکه‌های عصبی مصنوعی قادرند عمق تعادلی آبستتگی را با دقت بالایی (ضریب همبستگی بیش از ۰/۹۵) پیش‌بینی کنند. حبیب و همکاران (۲۰۲۴) با توسعه و مقایسه‌ی چند روش داده‌محور شامل SVM، ANN و روش‌های مبتنی بر درخت، عملکرد این روش‌ها را در پیش‌بینی عمق آبستتگی در سازه‌های دفاع ساحلی شیب‌دار ارزیابی کردند. نتایج نشان داد که روش SVM با هسته‌ی RBF بالاترین دقت را در بازسازی رفتار آبستتگی داشته و بیشترین همبستگی ($R^2 = 0.986$) و کمترین خطا را در میان تمام روش‌ها ارائه داده است. (Marulasiddappa et al. (2024) با استفاده از شبکه‌های چندلایه و روش‌های تقویتی، پیش‌بینی عمق آبستتگی اطراف پایه‌های جانبی را انجام دادند و گزارش کردند که شبکه عصبی چهارلایه بهترین عملکرد را با $R^2 \approx 0.98$ ارائه می‌دهد. در تحقیق (Nandi and Das (2025) بیش از هزار داده آزمایشگاهی برای مقایسه روابط تجربی و روش‌های یادگیری ماشین تحلیل شد. نتایج نشان داد که روش‌های ANN و SVM به‌طور میانگین ۳۵ تا ۴۰ درصد دقت بالاتری نسبت به روش‌های تجربی دارند، که تأییدکننده مزیت به‌کارگیری این روش‌ها در پژوهش حاضر است. در نهایت، (Rahman and Chavan (2025) در مطالعه‌ی مروری، کاربرد روش‌های ANN و SVM

در پیش‌بینی آبستگي را تحلیل کرده و نتیجه گرفتند که ترکیب این روش‌ها با روش‌های بهینه‌سازی و انتخاب ویژگی، موجب بهبود چشمگیر دقت و پایداری روش‌ها می‌شود. این مطالعه به دنبال تحلیل کارایی و اثربخشی روش‌های هوش مصنوعی در پیش‌بینی عمق آبستگي، با تمرکز بر شناسایی پارامترهای موثر و بهینه‌سازی روش‌های پیش‌بینی است. هدف اصلی این تحقیق، شناسایی و پیش‌بینی عمق آبستگي با استفاده از داده‌ها و پارامترهای موثر و همچنین توسعه روشی است که بتواند به‌طور دقیق‌تر عمق آبستگي در شرایط مختلف جریان و بستر رودخانه را پیش‌بینی کند.

مواد و روش‌ها


این پژوهش با هدف مقایسه نتایج حاصل از داده‌های آزمایشگاهی عطائیان (۱۳۹۰) با استفاده از روش‌های هوش مصنوعی ماشین بردار پشتیبان، شبکه عصبی مصنوعی، QNET و بررسی عمق آبستگي در خطوط لوله عبوري از رودخانه‌ها انجام شده است. در این راستا، ۳۶ مجموعه داده مرتبط با عمق آبستگي خطوط لوله عبوري از رودخانه‌ها با استفاده از روش‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و QNET مورد بررسی قرار گرفته است. با توجه به اینکه هر یک از این روش‌ها دارای توانایی‌های منحصر به فردی در شناسایی الگوها و بهینه‌سازی پیش‌بینی‌ها هستند، پژوهش به شناسایی روش بهینه و بررسی دقت آن‌ها در شرایط مختلف می‌پردازد. به این منظور، ۱۱ ترکیب ورودی مختلف طراحی شده است که هر کدام شامل مجموعه‌ای از پارامترهای کلیدی برای روش‌سازی و تحلیل عمق آبستگي هستند. این ترکیبات، شامل متغیرهایی مانند سرعت جریان، قطر لوله، عمق آب، خصوصیات بستر و عوامل هیدرودینامیکی دیگر می‌شوند که تأثیر مستقیم بر عمق آبستگي دارند. شکل ۱ نمای شماتیک فلوام آزمایشگاهی دانشگاه ارومیه و موقعیت لوله در بستر متحرک (بر اساس عطائیان، ۱۳۹۰) نشان داده شده است. این شکل اجزای اصلی آزمایش مانند مخزن، کانال هدایت و... را نشان می‌دهد که برای شبیه‌سازی جریان و اندازه‌گیری آبستگي استفاده شد.



شکل ۱. فلوام آزمایشگاهی (Ataycian, 2011)

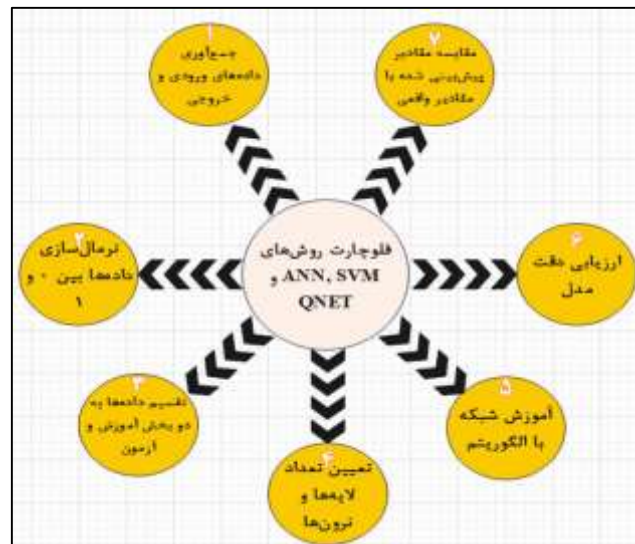
تاسیسات کانال مستطیلی

آزمایش‌ها در یک فلوام مستقیم با دیواره‌های شفاف از جنس پرسپکس با طول ۸ متر، عرض ۰/۶ متر و عمق ۰/۴۲ متر انجام شد. این فلوام به صورت جریان آزاد با شیب طولی ۰/۰۰۰۱ طراحی گردید. مشخصات هندسی فلوام و شرایط مرزی بر اساس داده‌های منتشر شده عطائیان (۲۰۱۱) انتخاب و با شرایط مشابه بازتولید شدند. برای شبیه‌سازی بستر رودخانه از رسوبات ماسه‌ای با دانه‌بندی یکنواخت و قطر متوسط $d_{50}=0.56$ میلی‌متر استفاده گردید. در این آزمایش‌ها لوله‌هایی با قطرهای مختلف از ۲/۲ تا ۱۱/۶ سانتی‌متر مورد استفاده قرار گرفتند. جریان از یک مخزن ذخیره به مخزن آرام‌کننده هدایت و وارد فلوام شد و در انتهای فلوام سرریز قابل تنظیمی برای کنترل عمق جریان نصب گردید. پارامترهای بی‌بعد شامل عدد فرود، نسبت قطر لوله به عمق جریان، نسبت عمق آبستگي به قطر، نسبت ارتفاع لوله از بستر به قطر و نسبت طول ناحیه آبستگي به قطر در تحلیل داده‌ها به کار رفتند. شکل ۲ نمایی شماتیک از فلوام آزمایشگاهی و آماده‌سازی فلوام را نشان می‌دهد.



شکل ۲. نمایی از فلوم و آماده‌سازی آن (عطائیان، ۱۳۹۰)

به‌منظور مدل‌سازی و پیش‌بینی عمق آبستگي اطراف خطوط لوله، از سه روش هوش مصنوعی شامل شبکه عصبی مصنوعی، ماشین‌بردار پشتیبان و روش QNET استفاده گردید. این روش‌ها با هدف شناسایی روابط غیرخطی میان پارامترهای ورودی هیدرولیکی و هندسی و خروجی مدل (عمق آبستگي) به کار گرفته شدند. در تمامی روش‌ها، داده‌های تجربی حاصل از آزمایش‌های فیزیکی در دو بخش آموزش و آزمون مورد استفاده قرار گرفتند تا دقت و تعمیم‌پذیری مدل‌ها ارزیابی گردد. فلوجارت شکل ۳، مراحل کلی توسعه و اجرای هر یک از روش‌ها، شامل جمع‌آوری داده‌های ورودی و خروجی، نرمال‌سازی داده‌ها بین ۰ و ۱، تقسیم داده‌ها به دو بخش آموزش و آزمون، تعیین لایه‌ها و نرون‌ها، آموزش شبکه با روش آموزش و آزمون، تعیین مقادیر مقایسه با مقادیر واقعی شده با مقادیر واقعی را نشان می‌دهند. استفاده از این سه رویکرد به منظور مقایسه میزان دقت و کارایی هر روش در پیش‌بینی پدیده آبستگي انجام شده است.



شکل ۳. فلوجارت روش‌های ANN, SVM, QNET در پژوهش انجام یافته

هر کدام از این روش‌ها، با ویژگی‌های منحصر به فرد خود، به شناسایی الگوهای پیچیده و ارتباطات میان پارامترهای مختلف در پیش‌بینی عمق آبستگي کمک می‌کنند. روش ماشین‌بردار پشتیبان با توانایی ویژه در تشخیص الگوهای پیچیده و مدیریت داده‌های غیرخطی و چندبعدی، به‌ویژه در شرایطی که داده‌ها دارای توزیع پیچیده هستند، ابزاری ایده‌آل برای پیش‌بینی آبستگي محسوب می‌شود. هدف اصلی این مطالعه، شناسایی دقیق‌تر الگوهای آبستگي و پیش‌بینی عمق آن بر اساس داده‌ها و پارامترهای مؤثر بر این پدیده است. روش شبکه عصبی مصنوعی نیز به دلیل ساختار چندلایه و قابلیت یادگیری از داده‌ها، امکان تحلیل دقیق‌تری از روابط غیرخطی و دینامیکی در بین پارامترهای مؤثر را فراهم می‌کند. این روش با پردازش و تطبیق داده‌ها، به بهبود دقت پیش‌بینی و کاهش خطاها کمک می‌کند و در نتیجه کارایی بالایی در شرایط پیچیده جریان و ساختارهای آبی از خود نشان می‌دهد.

روش QNET نیز به عنوان یکی از روش‌های پیشرفته مبتنی بر یادگیری ماشین، با بهره‌گیری از تکنیک‌های یادگیری عمیق و بهینه‌سازی پیشرفته، امکان پیش‌بینی عمق آبستتگی را به‌طور دقیق‌تری فراهم می‌سازد. این روش قادر است الگوهای پنهان و ارتباطات پیچیده میان پارامترهایی همچون سرعت جریان، قطر لوله، عمق آب، فاصله لوله تا بستر، و شرایط بستر را شناسایی کرده و پیش‌بینی‌های دقیقی ارائه دهد. در راستای این هدف، ۱۱ ترکیب ورودی مختلف از پارامترهای کلیدی طراحی شده است که هر یک از آن‌ها به دقت برای مدل‌سازی بهینه انتخاب شده‌اند. جدول ۱ در این تحقیق، ترکیبات ورودی مختلف را برای هر سه روش نشان می‌دهد و به خوانندگان کمک می‌کند تا با ساختار و ویژگی‌های داده‌های مورد استفاده در مدل آشنا شوند. این جدول با ارائه جزئیات مربوط به پارامترهای ورودی و نحوه ترکیب آن‌ها، به‌ویژه برای محققان و مهندسان هیدرولیک مفید است، زیرا امکان پیگیری روند تحقیق و ارزیابی عمق آبستتگی با استفاده از داده‌های کلیدی را فراهم می‌آورد.

جدول ۱. ترکیبات مختلف ورودی مربوط به روش‌های ANN, SVM, QNET

ترکیب	پارامترهای موثر
ترکیب ۱	$\frac{ds_{max}}{D}, \frac{L}{D}, \frac{y}{D}, Fr, \frac{e}{D}$
ترکیب ۲	$\frac{ds_{max}}{D}, \frac{L}{D}, \frac{y}{D}, Fr$
ترکیب ۳	$\frac{ds_{max}}{D}, \frac{L}{D}, \frac{y}{D}, \frac{e}{D}$
ترکیب ۴	$\frac{ds_{max}}{D}, \frac{L}{D}, Fr, \frac{e}{D}$
ترکیب ۵	$\frac{ds_{max}}{D}, \frac{y}{D}, Fr, \frac{e}{D}$
ترکیب ۶	$\frac{ds_{max}}{D}, \frac{L}{D}, Fr$
ترکیب ۷	$\frac{ds_{max}}{D}, \frac{L}{D}, \frac{y}{D}$
ترکیب ۸	$\frac{ds_{max}}{D}, \frac{y}{D}, Fr$
ترکیب ۹	$\frac{ds_{max}}{D}, \frac{L}{D}, \frac{e}{D}$
ترکیب ۱۰	$\frac{ds_{max}}{D}, \frac{y}{D}, \frac{e}{D}$
ترکیب ۱۱	$\frac{ds_{max}}{D}, Fr, \frac{e}{D}$

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان (SVM) نخستین بار توسط Vapnik and Chervonenkis (1963) معرفی شد و در ۱۹۹۵ توسط واپنیک توسعه یافت. این روش برای پیش‌بینی عمق آبستتگی با مدیریت روابط غیرخطی ایده‌آل است. روابط SVM از بهینه‌سازی لاگرانژ بدست می‌آیند و فرم کامل رابطه به صورت زیر است:


$$f(x) = \sum_{i=1}^n \alpha_i y_i K(x_i, x) + b \quad \text{رابطه (۱)}$$

جدول ۲ روابط ریاضی کلیدی ماشین بردار پشتیبان (SVM)، پارامترها و توضیحات که بر پایه اصول بهینه‌سازی مقید و شرایط KKT تدوین شده، روابط اصلی SVM را برای کاربرد در مدل‌سازی هیدرولیکی خلاصه می‌کند.

جدول ۲. روابط ریاضی کلیدی ماشین بردار پشتیبان (SVM)

شماره رابطه	رابطه ریاضی	توضیح رابطه	پارامترها و نحوه بدست آمدن
1	$f(x) = \sum_{i=1}^n \alpha_i y_i K(x_i, x) + b$	تابع پیش‌بینی عمق آبستتگی.	α_i : ضرایب لاگرانژ از SMO; y_i : هدف; K : هسته RBF: b : بایاس از KKT
2	$w = \sum_{i=1}^n \alpha_i y_i \phi(x_i)$	بردار وزنی.	ϕ : نگاشت از مشتق لاگرانژ.
3	$s.t. \mathbf{0} \leq \alpha_i \leq C, \max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j K(x_i, x_j)$ $\sum \alpha_i y_i = 0$	مسئله دوگان.	$C = 10$ (بهینه‌شده) از تبدیل پرایمِل.
4	$b = y_k - \sum_{i=1}^n \alpha_i y_i K(x_i, x_k)$	بایاس.	KKT از $x_k \in S$

شکل ۴ دیاگرام ابرصفحه SVM در فضای ویژگی شامل ابرصفحه $w \cdot x + b = 0$ ، بردار وزنی w (عمود بر ابرصفحه)، بایاس b (جابجایی)، حاشیه (margin با فاصله $\|w/2\|$)، بردارهای پشتیبان (نقاط روی خطوط نقطه‌چین) و کلاس‌های داده است.



شکل ۴. دیاگرام ابرصفحه SVM در فضای ویژگی

شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی از جمله روش‌های هوش مصنوعی هستند که با الهام از نحوه پردازش داده‌ها در سیستم عصبی انسان، توانایی شناسایی الگوهای پیچیده و مدل‌سازی روابط غیرخطی را دارند. این شبکه‌ها از مجموعه‌ای از گره‌ها یا نورون‌ها تشکیل شده‌اند که از طریق وزن‌های قابل تنظیم به یکدیگر متصل می‌شوند. با آموزش شبکه و به‌روزرسانی وزن‌ها بر اساس روش‌های یادگیری، مدل می‌تواند رفتار سیستم‌های فیزیکی و هیدرولیکی را با دقت بالا پیش‌بینی کند. به‌ویژه در مسائل هیدرولیکی نظیر پیش‌بینی عمق آبستگي، ANN توانسته است با استفاده از داده‌های تجربی، روابط غیرخطی بین پارامترهای جریان، هندسه بستر و شرایط مرزی را به‌طور مؤثری شبیه‌سازی کند. این ویژگی موجب شده است تا شبکه‌های عصبی به‌عنوان جایگزینی کارآمد برای مدل‌های تجربی سنتی در تحلیل پدیده‌های پیچیده مهندسی آب معرفی شوند. در شبکه عصبی مصنوعی، خروجی هر نرون بر اساس ترکیب وزنی ورودی‌ها و تابع فعال‌سازی محاسبه می‌شود: در شبکه عصبی مصنوعی، خروجی هر نود بر اساس ترکیب وزنی ورودی‌ها و تابع فعال‌سازی محاسبه می‌شود:

$$b + X_i W_i \sum_i^N = net \quad \text{رابطه ۲}$$

$$f(net) = y \quad \text{رابطه ۳}$$

که در آن X_i ورودی‌ها، W_i وزن‌ها و f تابع فعال‌سازی است.

ورودی خالص (Net Input)

محاسبه مجموع وزنی ورودی‌ها:

$$net = \sum_{i=1}^N w_i x_i + b \quad \text{رابطه ۴}$$

که در آن X_i ورودی‌ها، w_i وزن‌های قابل یادگیری، و b بایاس (عرض از مبدا) می‌باشد.

خروجی نرون (Output Activation):

اعمال تابع فعال‌سازی غیرخطی (f) به ورودی خالص:

$$y = f(net) \quad \text{رابطه ۵}$$

که در آن y خروجی نهایی نرون و f تابع فعال‌سازی می‌باشد.

روش QNET

نرم افزار QNET، با تمرکز بر مدل سازی و پیاده سازی شبکه های عصبی مصنوعی، ابزاری تخصصی است که در این پژوهش به کار گرفته شده تا قابلیت های شبکه های عصبی در پیش بینی و تحلیل مسائل پیچیده، مانند عمق آبشستگی خطوط لوله عبوری از بستر رودخانه ها، به دقت بررسی شود. این نرم افزار، به ویژه برای کاربرانی که به دنبال تحلیل های دقیق و کاربردی در حوزه های مهندسی و علوم داده هستند، انتخاب مناسبی است. یکی از ویژگی های بارز QNET، امکان طراحی و تنظیم شبکه های عصبی از نوع پس انتشار خطا است که به عنوان مدل پایه در بسیاری از تحلیل های شبکه عصبی مصنوعی شناخته می شود. این نرم افزار با به کارگیری این روش به صورت بهینه، قابلیت یادگیری دقیق تر و سریع تر را فراهم می آورد. در این نرم افزار، پارامترهای یادگیری قابل تنظیم بوده و کاربر می تواند بر اساس نوع داده و پیچیدگی مسئله، پارامترهایی نظیر نرخ یادگیری، تعداد لایه های پنهان و نرون ها را به صورت سفارشی تنظیم کند. QNET، از طریق رابط کاربر پسند و سیستم راهنمای پیشرفته، امکان مدیریت آسان داده های ورودی و خروجی را برای پژوهشگران مهیا می سازد. این نرم افزار همچنین با دارا بودن ماژول های تحلیل خودکار و تست های متنوع برای بهینه سازی مدل ها، به کاربر امکان می دهد تا مدل های خود را از نظر دقت و عملکرد با داده های آزمایشی و واقعی اعتبارسنجی کند. این قابلیت ها، به ویژه در پروژه های تحقیقاتی که نیازمند صحت و دقت بالایی هستند، بسیار کاربردی بوده و به کاربران کمک می کند تا کارایی مدل های خود را بهینه سازی کنند. قابلیت تحلیل فرایند یادگیری از دیگر ویژگی های قابل توجه QNET است که از طریق نمودارها و گزارش های مختلف، اطلاعات جامعی در مورد فرایند و میزان خطا در هر مرحله از آموزش فراهم می آورد. این ابزار به پژوهشگران کمک می کند تا روند یادگیری شبکه را به دقت دنبال کرده و تغییرات لازم را برای بهبود مدل اعمال کنند. از دیگر مزایای این نرم افزار می توان به حافظه گذاری خودکار در طی فرایند آموزش، قابلیت ذخیره و بارگذاری مدل ها و همچنین امکان به کارگیری چندین مدل آموزشی اشاره کرد. این ویژگی ها به کاربران اجازه می دهد تا شبکه های عصبی خود را به صورت پیوسته بهبود دهند و از ظرفیت های پردازشی سیستم های خود بهره برداری بهینه کنند. در نتیجه، QNET به عنوان یک ابزار کامل و قدرتمند برای مدل سازی، تحلیل و پیش بینی داده ها به کار می رود و به پژوهشگران این امکان را می دهد تا به طور مؤثری از قابلیت های شبکه عصبی مصنوعی در پروژه های تحقیقاتی و عملی استفاده کنند. این نرم افزار علاوه بر حل مسائل پیچیده در پژوهش های علمی، امکان تحلیل آنالیز حساسیت نسبت به تغییرات پارامترهای ورودی را نیز فراهم می کند. این قابلیت برای پژوهشگرانی که به دنبال تحلیل رفتار سیستم تحت شرایط مختلف هستند، بسیار حائز اهمیت است. علاوه بر این، QNET به واسطه طراحی ساختار مقیاس پذیر قوی خود، قادر است با داده های حجیم و متغیرهای پیچیده کار کرده و تحلیل های چندبعدی را به آسانی مدیریت کند. این نرم افزار نه تنها در پیش بینی عمق آبشستگی و مسائل هیدرولیکی، بلکه در بسیاری از حوزه های دیگر مانند مهندسی محیط زیست، بهداشت و علوم پایه نیز قابلیت استفاده دارد و به یک ابزار علمی جامع برای توسعه و کاربرد شبکه های عصبی تبدیل شده است.

در روش QNET، رابطه ورودی خروجی به صورت یک تابع چندجمله ای مرتبه دوم بیان می شود:

$$W_j X_{ij} X_i \sum_{j=1}^n \sum_{i=1}^n + W_i X_i \sum_{i=1}^n + W_o = y \quad \text{(رابطه ۶)}$$

که شامل جملات خطی و مربعی برای مدل سازی رفتارهای غیرخطی است.

همچنین رابطه خروجی مدل QNET نیز به صورت زیر است:

$$y = \left(\sum_{i=0}^l w1_i x_i \right) + \left(\sum_{j=0}^l w2_j x_j \right) + wb \quad \text{(رابطه ۷)}$$

که در آن x_i و x_j ورودی ها، $w1_i$ و $w2_j$ وزن های قابل یادگیری برای هر بخش و wb بایاس نهایی مدل می باشد.

پیاده سازی مدل ها

مدل شبکه عصبی مصنوعی (ANN) و مدل ماشین بردار پشتیبان (SVM) با بهره گیری از نرم افزار Statistica نسخه 14.0.0.15 اجرا شد. همچنین، مدل QNET با استفاده از نرم افزار QNET v2000 پیاده سازی و آموزش داده شد.

شاخص های ارزیابی عملکرد

در این پژوهش، برای ارزیابی کارایی و دقت روش های شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و QNET، از



شاخص‌های عملکردی مختلفی مانند ریشه میانگین مربعات خطا (RMSE)، ضریب تبیین (DC) و مجذور ضریب همبستگی (R^2) استفاده شد (سلطانی ستوبادی، ۱۴۰۳).

۱- جذر مربع میانگین خطاها (RMSE)

۲- شاخص ضریب تبیین (DC)

۳- مربع ضریب همبستگی (R^2)

$$RMSE = \sqrt{\sum_{i=1}^N \frac{(ds \max/ Do - ds \max/ Dp)^2}{N}} \quad \text{رابطه ۸}$$

$$Dc = 1 - \frac{\sum_{i=1}^N (ds \max/ D_i^o - ds \max/ D_i^p)^2}{\sum_{i=1}^N (ds \max/ D_i^o - ds \max/ Dp)^2} \quad \text{رابطه ۹}$$

$$R^2 = \left(\frac{\sum_{i=1}^N (ds \max/ D_i^o - ds \max/ D^o)(ds \max/ D_i^p - ds \max/ D^p)}{\sqrt{\sum_{i=1}^N (ds \max/ D_i^o - ds \max/ D^o)^2 \sum_{i=1}^N (ds \max/ D_i^p - ds \max/ D^p)^2}} \right) \quad \text{رابطه ۱۰}$$

نتایج و بحث

این مقاله به بررسی و پیش‌بینی عمق آبستگي در خطوط لوله عبوری از بستر رودخانه‌ها با استفاده از روش‌های ANN، SVM و QNET پرداخته و در تلاش است تا دقت و کارایی هر یک از این روش‌ها را در تخمین عمق آبستگي ارزیابی کند. پژوهش حاضر بر پایه داده‌های آزمایشگاهی عطائیان (۱۳۹۰) استوار بوده و با تحلیل نتایج پیش‌بینی شده توسط این روش‌ها در مقایسه با داده‌های تجربی، تلاش دارد تا میزان تطابق و دقت هر روش را به‌ویژه در شرایط مختلف جریان و بستر مورد ارزیابی قرار دهد. این مطالعه همچنین پارامترهای کلیدی مؤثر در مدل‌سازی آبستگي، شامل سرعت جریان، عمق آب، و ویژگی‌های بستر را بررسی کرده و تأثیر هر یک از متغیرهای ورودی را در بهبود دقت مدل مشخص می‌کند. در ادامه، پژوهش به مقایسه جامع نتایج پیش‌بینی‌های ANN، SVM و QNET از نظر شاخص‌های آماری و قابلیت تعمیم‌دهی به شرایط مشابه می‌پردازد. این تحلیل‌ها می‌توانند برای شناسایی روشی دقیق و کاربردی در پیش‌بینی آبستگي به کار روند و مدل بهینه‌ای را برای مدیریت و طراحی زیرساخت‌های لوله‌های عبوری از رودخانه‌ها در شرایط محیطی متنوع پیشنهاد کنند. نتایج این تحقیق به مهندسان و میران پروژه کمک می‌کند تا با اطمینان بیشتری به مدیریت ریسک‌های مرتبط با آبستگي و ارتقاء عمر سازه‌های هیدرولیکی بپردازند.

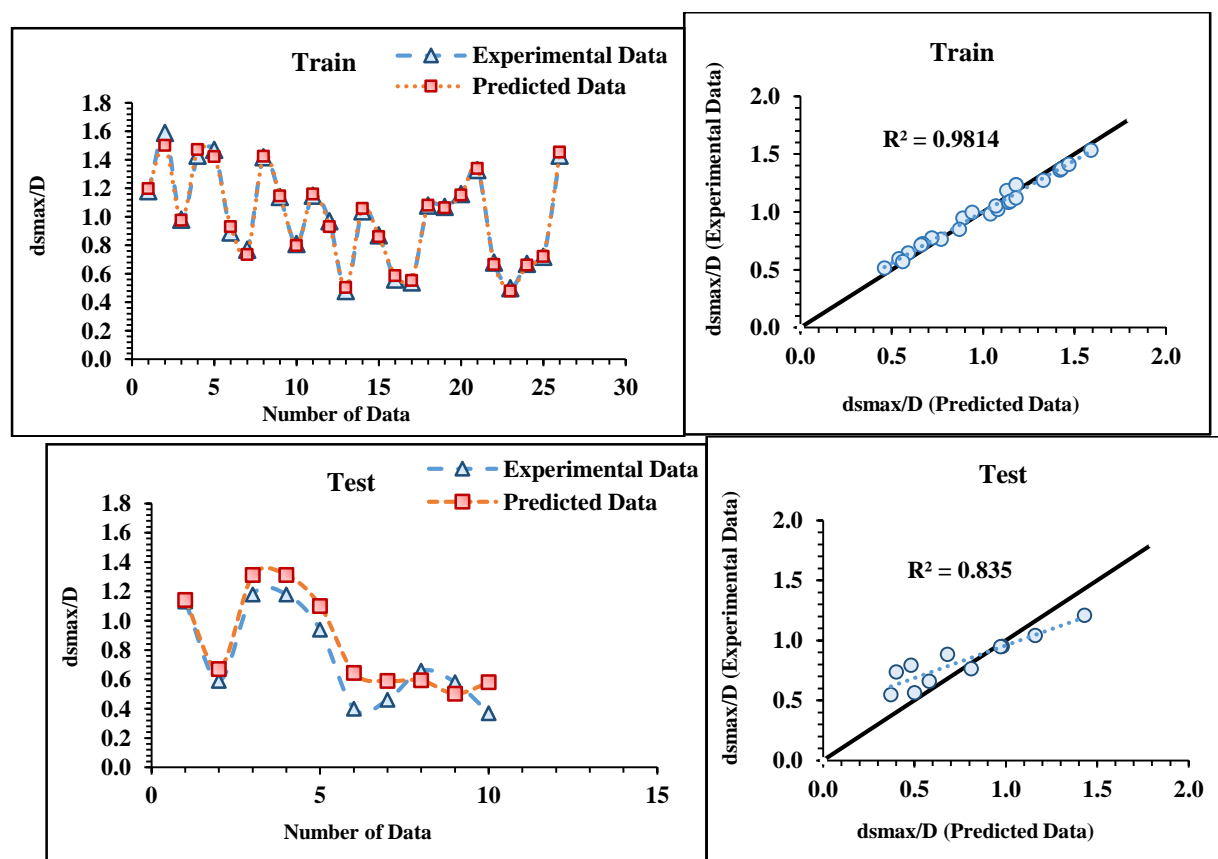
نتایج روش ANN

جدول ۳ نتایج ارزیابی آماری شامل شاخص‌های DC، R^2 ، RMSE را برای تمامی ترکیب‌ها با استفاده از نرم‌افزار ANN ارائه می‌دهد. از بین تمامی ترکیب‌ها، ترکیب اول در مراحل آموزش و آزمون، با عملکرد برتر خود در هر سه شاخص آماری، به عنوان بهترین ترکیب شناخته شد. این ترکیب دارای دقت بالاتر، خطای کمتر و تطابق بهتری با داده‌های واقعی نسبت به سایر ترکیب‌ها بود، و توانست تغییرات داده‌ها را به خوبی بازتاب دهد. برای ترکیب اول، مقادیر شاخص‌های DC، R^2 ، RMSE در مراحل آموزش و آزمون به ترتیب برابر با ۰/۹۹۳۲، ۰/۹۹۲۵، ۰/۰۲۷۲، ۰/۸۹۵۹، ۰/۸۹۲۵ و ۰/۱۱۸۰ به دست آمد که نشان‌دهنده دقت بالای مدل در پیش‌بینی و تحلیل داده‌هاست. به طور کلی، ترکیب اول در تمامی شاخص‌های آماری، عملکرد برتری داشته و قدرت پیش‌بینی مدل را در مقایسه با سایر ترکیب‌ها تأیید می‌کند.

جدول ۳. ارزیابی ترکیبات مختلف ورودی برای تعیین عمق آبشستگی مربوط به روش ANN

TRAIN			TEST			نام ترکیب
DC	R ²	RMSE	DC	R ²	RMSE	
۰/۹۹۳۲	۰/۹۹۲۵	۰/۰۲۷۲	۰/۸۹۵۹	۰/۸۹۲۵	۰/۱۱۸۰	ترکیب ۱
۰/۸۵۸۹	۰/۸۵۹۸	۰/۱۱۶۸	۰/۶۸۴۴	۰/۶۶۷۶	۰/۲۲۲۹	ترکیب ۲
۰/۹۲۸۷	۰/۹۲۸۷	۰/۰۸۵۵	۰/۳۳۵۸	۰/۷۷۶۳	۰/۲۵۲۰	ترکیب ۳
۰/۸۶۳۹	۰/۸۶۳۹	۰/۱۱۸۲	۰/۸۱۱۹	۰/۸۵۸۹	۰/۱۳۴۶	ترکیب ۴
۰/۸۷۷۸	۰/۸۷۸۹	۰/۱۱۲۰	۰/۸۰۲۵	۰/۸۷۶۴	۰/۱۳۷۹	ترکیب ۵
۰/۸۰۰۸	۰/۸۰۶۷	۰/۱۴۴۹	۰/۲۷۶۲	۰/۵۴۷۰	۰/۳۱۰۴	ترکیب ۶
۰/۷۱۱۵	۰/۷۱۱۴	۰/۱۶۸۴	۰/۶۲۳۳	۰/۶۴۱۱	۰/۲۳۵۷	ترکیب ۷
۰/۵۳۷۳	۰/۵۴۰۰	۰/۲۰۹۲	۰/۳۶۵۸	۰/۴۹۵۶	۰/۲۵۸۴	ترکیب ۸
۰/۷۵۵۸	۰/۷۵۶۳	۰/۱۵۸۲	۰/۴۴۲۲	۰/۵۰۴۲	۰/۲۴۱۳	ترکیب ۹
۰/۶۷۷۲	۰/۶۸۰۲	۰/۲۰۰۱	۰/۵۹۱۳	۰/۶۴۳۵	۰/۱۷۹۸	ترکیب ۱۰
۰/۸۶۳۱	۰/۸۶۴۹	۰/۱۲۳۹	۰/۷۶۶۱	۰/۷۸۹۲	۰/۱۶۰۷	ترکیب ۱۱

شکل ۵ نمودار پراکنده داده‌های آزمایشگاهی و پیش‌بینی شده را برای ترکیب اول روش ANN در مراحل آموزش و آزمون به نمایش می‌گذارد. تحلیل این نمودار نشان می‌دهد که مدل عملکرد دقیقی داشته و به‌طور مؤثری توانسته است الگوهای موجود در داده‌های آزمایشگاهی را بازتاب دهد. مقادیر مربع ضریب همبستگی R² که در این تحلیل برای مراحل آموزش و آزمون به ترتیب ۰/۹۹۲۵ و ۰/۸۹۲۵ محاسبه شده‌اند، بر وجود همبستگی خطی قوی میان داده‌های واقعی و پیش‌بینی شده دلالت دارند. در مرحله آموزش، داده‌های پیش‌بینی شده به‌خوبی در محدوده مقادیر بیشینه و کمینه با داده‌های آزمایشگاهی منطبق است. در آزمون نیز، مدل با وجود اختلاف جزئی در مقادیر بیشینه و کمینه، به نتایج رضایت‌بخشی دست یافته است. این یافته‌ها نشان‌دهنده دقت بالای روش شبکه هوش مصنوعی در بازسازی روندهای موجود در داده‌های آزمایشگاهی و توانایی آن در پیش‌بینی تغییرات هستند.



شکل ۵. نمودار پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده مرحله آموزش و آزمون مربوط به روش ANN

نتایج روش SVM

جدول ۴ نتایج پارامترهای آماری (R^2 , RMSE, DC) برای تمام ترکیب‌ها با استفاده از روش SVM را ارائه می‌دهد. با تحلیل‌های انجام‌شده و بررسی مقادیر پارامترهای آماری، ترکیب ۱ به‌عنوان بهترین ترکیب شناخته شد. این ترکیب با مقادیر R^2 , RMSE, DC در مراحل آموزش و آزمون به ترتیب برابر با ۰/۹۷۲۴، ۰/۰۵۱۹، ۰/۸۳۲۲ و در مرحله آزمون برابر با ۰/۸۳۲۲، ۰/۱۸۱۹، ۰/۸۳۵۰، نشان‌دهنده دقت بالای مدل در پیش‌بینی داده‌ها و توانایی در توضیح تغییرات است. تنظیم پارامترها بر اساس مقایسه عملکرد مدل برای ترکیب‌های مختلف ورودی و انتخاب ساختار بهینه انجام پذیرفت. معیار انتخاب، حداقل‌سازی خطای پیش‌بینی (RMSE) و بیشینه‌سازی شاخص‌های دقت R^2 و DC در مراحل آموزش و آزمون بوده است. عملکرد ترکیب ۱ به وضوح از سایر ترکیب‌ها بهتر بوده و قدرت بیشتری در پیش‌بینی داده‌ها و دقت بالاتر در ارزیابی تغییرات دارد. به این ترتیب، این ترکیب نشان می‌دهد که روش SVM به‌خوبی قادر است الگوهای موجود در داده‌ها را یاد گرفته و آن‌ها را در مرحله آزمون با دقت بازتولید کند. در نتیجه، این ترکیب می‌تواند به‌عنوان یک ابزار مؤثر و قابل‌اطمینان در پیش‌بینی داده‌ها در کاربردهای مشابه مورد استفاده قرار گیرد، چرا که دقت بالای پارامترهای R^2 و DC نشان‌دهنده همبستگی قوی بین داده‌های مشاهده‌شده و پیش‌بینی‌شده است و مقادیر کم RMSE نیز نشان‌دهنده میزان خطای کمتر در مدل است. بنابراین، ترکیب ۱ به‌عنوان بهترین ترکیب، نشان می‌دهد که این مدل نه تنها از دقت بالایی برخوردار است، بلکه با خطای کمی که در پیش‌بینی دارد، می‌تواند به بهبود دقت در مسائل پیش‌بینی مشابه کمک کند.

جدول ۴. ارزیابی ترکیبات مختلف ورودی برای تعیین عمق آبتستگی مربوط به روش SVM

TRAIN			TEST			نام ترکیب
DC	R^2	RMSE	DC	R^2	RMSE	
۰/۹۷۲۴	۰/۹۸۱۴	۰/۰۵۱۹	۰/۸۳۲۲	۰/۸۳۵۰	۰/۱۸۱۹	ترکیب ۱
۰/۸۵۹۱	۰/۸۸۴۳	۰/۱۱۴۸	۰/۵۰۹۹	۰/۳۶۷۱	۰/۳۶۵۷	ترکیب ۲
۰/۹۷۰۹	۰/۹۸۰۱	۰/۰۵۴۷	۰/۶۰۷۱	۰/۶۱۱۹	۰/۲۲۶۲	ترکیب ۳
۰/۹۶۰۴	۰/۹۳۴۱	۰/۰۹۵۹	۰/۹۱۱۲	۰/۶۹۷۷	۰/۱۹۴۱	ترکیب ۴
۰/۹۷۴۵	۰/۹۷۹۷	۰/۰۵۱۹	۰/۵۷۳۱	۰/۷۱۷۰	۰/۲۱۴۷	ترکیب ۵
۰/۷۴۰۵	۰/۸۷۲۱	۰/۱۱۵۳	۰/۶۰۵۹	۰/۵۰۴۲	۰/۲۸۶۵	ترکیب ۶
۰/۷۹۴۶	۰/۷۷۰۵	۰/۱۶۷۹	۰/۷۸۴۲	۰/۴۶۸۱	۰/۳۳۴۸	ترکیب ۷
۰/۵۱۹۵	۰/۵۳۴۶	۰/۲۴۲۲	۰/۴۳۲۵	۰/۴۱۳۴	۰/۳۴۷۵	ترکیب ۸
۰/۸۳۴۳	۰/۸۳۵۳	۰/۱۲۶۸	۰/۴۶۲۳	۰/۴۶۲۴	۰/۳۵۳۹	ترکیب ۹
۰/۷۰۶۳	۰/۷۱۵۸	۰/۱۷۵۷	۰/۶۲۱۲	۰/۶۴۴۳	۰/۲۲۳۱	ترکیب ۱۰
۰/۸۳۱۵	۰/۸۴۴۳	۰/۱۳۷۴	۰/۶۷۹۲	۰/۷۳۷۸	۰/۱۵۹۰	ترکیب ۱۱

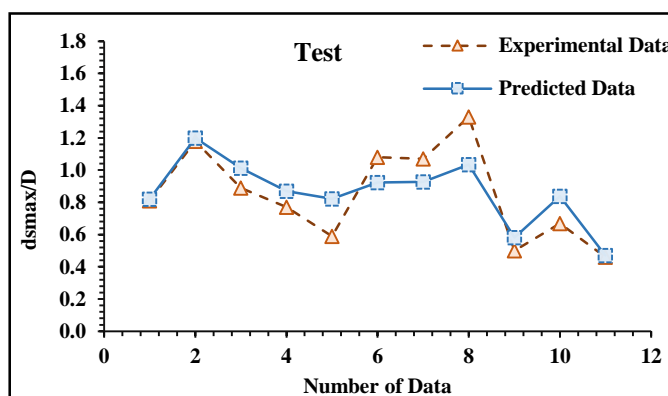
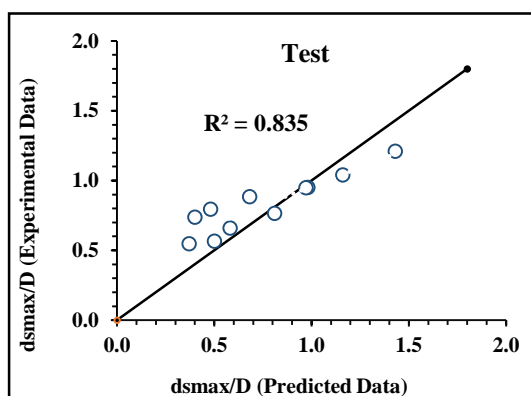

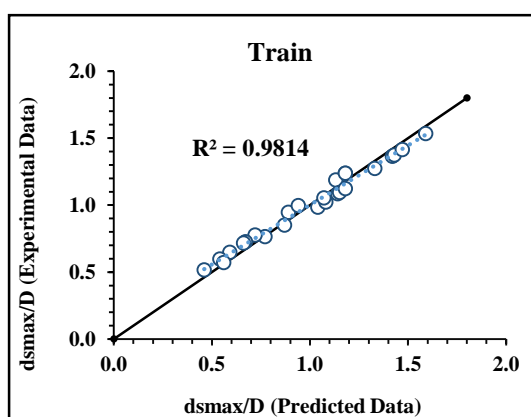
شکل ۶ نمودارهای پراکنش داده‌های آزمایشگاهی و پیش‌بینی‌شده برای بهترین ترکیب (ترکیب اول) را در هر دو مرحله آموزش و آزمون نشان می‌دهد. تحلیل نتایج بیانگر عملکرد مطلوب روش SVM است. مقادیر R^2 حاکی از وجود یک رابطه خطی قوی و دقت بالا میان داده‌های آزمایشگاهی و پیش‌بینی‌شده هستند. مقادیر R^2 برای نمودارهای پراکنش در مراحل آموزش و آزمون به ترتیب برابر با ۰/۹۸۱۴ و ۰/۸۳۵۰ است. در مرحله آموزش، مدل در پیش‌بینی مقادیر بیشینه کمی کمتر از داده‌های آزمایشگاهی عمل کرده و مقادیر کمینه را تقریباً برابر برآورد کرده است. در مرحله آزمون، در نقاط بیشینه، مقادیر پیش‌بینی‌شده کمتر از داده‌های آزمایشگاهی و در نقاط کمینه کمی بیشتر پیش‌بینی شده‌اند.

نتایج روش QNET

در جدول ۵، نتایج ارزیابی پارامترهای آماری (R^2 , RMSE, DC) برای تمامی ترکیب‌ها با استفاده از نرم‌افزار QNET ارائه شده است. در میان ترکیب‌های مختلف، ترکیب ۱ در هر سه شاخص آماری R^2 , RMSE، و DC عملکرد بهتری را هم در مراحل آموزش و هم در مراحل

آزمایش نشان داده است. این نتایج حاکی از دقت بالاتر، کاهش خطای پیش‌بینی و بهبود کارایی مدل در ترکیب ۱ نسبت به دیگر ترکیب‌ها است، به همین دلیل این ترکیب به‌عنوان بهترین گزینه در مدل‌سازی انتخاب شده است.

مقادیر R^2 ، RMSE و DC برای ترکیب ۱ در مراحل آموزش و تست به ترتیب برابر با: ۰/۰۶۱۱، ۰/۹۰۸۱، ۰/۹۰۸۰، ۰/۱۲۷۵، ۰/۷۰۱۵، ۰/۴۹۲۴ می‌باشد. مقادیر پایین‌تر RMSE نشان‌دهنده خطای کمتر در پیش‌بینی عمق آبستگي است، در حالی که مقادیر بالاتر R^2 و DC نشان می‌دهند که مدل با ترکیب ۱ توانایی بالاتری در تبیین و تشریح روابط میان متغیرها دارد. این نتایج اهمیت انتخاب ترکیب ورودی مناسب را در بهبود دقت مدل پیش‌بینی و کاهش خطاها تأکید می‌کند. عملکرد برتر ترکیب ۱ همچنین نشان‌دهنده قابلیت نرم‌افزار QNET در تنظیم پارامترها و ساختار شبکه عصبی بهینه است که به‌طور مؤثر می‌تواند به‌عنوان ابزاری کارآمد در پیش‌بینی عمق آبستگي در خطوط لوله به‌کار گرفته شود. انتخاب ترکیب بهینه در این تحقیق به مهندسان کمک می‌کند تا با اطمینان بیشتری به ارزیابی خطرات آبستگي بپردازند و اقدامات حفاظتی مؤثرتری برای زیرساخت‌های هیدرولیکی طراحی و اجرا کنند.

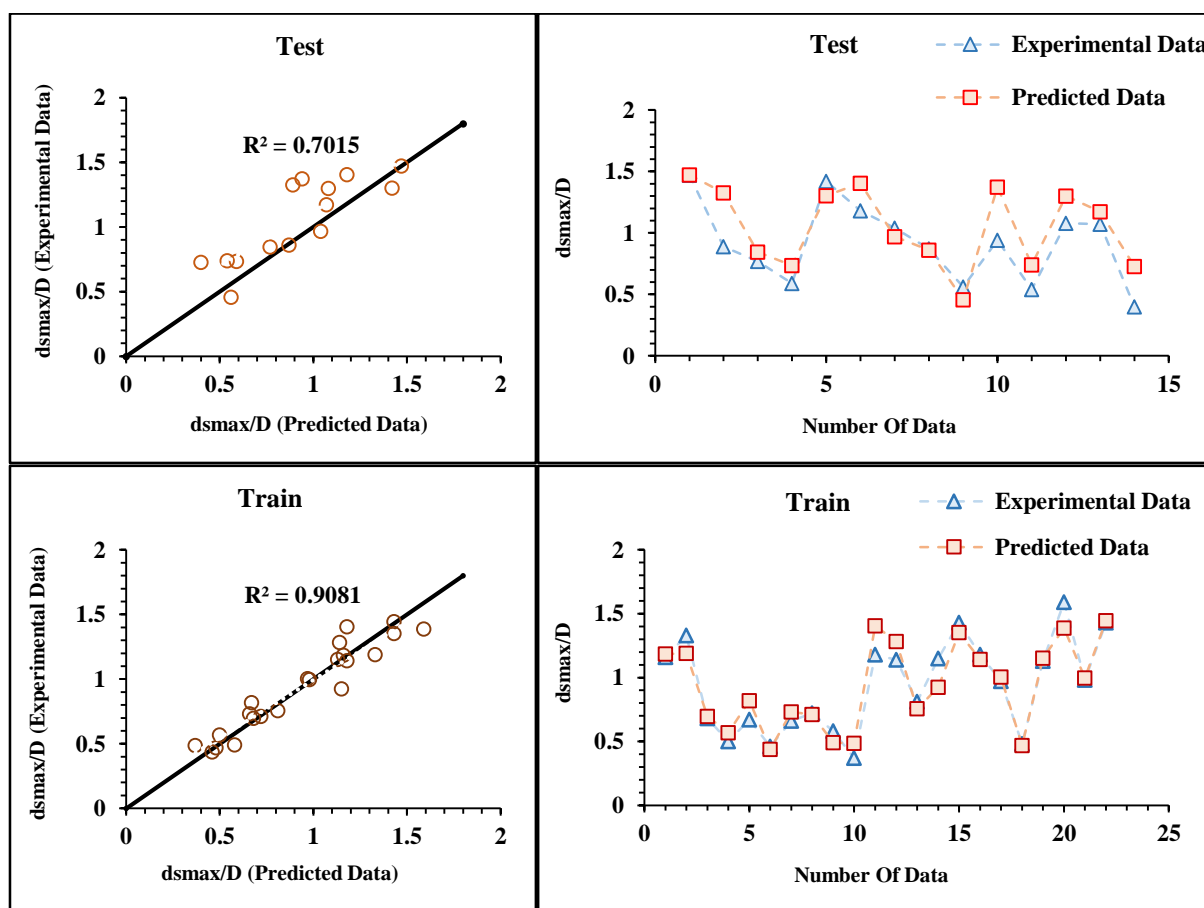


شکل ۶. نمودار پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده مرحله آموزش و آزمون مربوط به روش SVM

در شکل ۷، نمودارهای پراکنش داده‌های آزمایشگاهی و مدل‌سازی شده برای بهترین ترکیب (ترکیب اول) در مراحل آموزش و آزمون قابل مشاهده است. نتایج بدست آمده از این نمودارها حاکی از آن است که مدل توانسته است به‌خوبی داده‌های آموزش را یاد بگیرد و ارتباطات بین ورودی‌ها و خروجی‌ها را به‌طور دقیق درک کند با این حال، در نقاط بیشینه داده‌ها (مقادیر بزرگتر) در پارامتر R^2 ، مدل در برخی موارد مقادیری کمتر از داده‌های واقعی را برآورد کرده است، که نشان‌دهنده نیاز به بهینه‌سازی بیشتر برای مقادیر انتهایی است. روش QNET در مرحله آزمون نیز عملکرد مناسبی دارد، هرچند که اختلاف جزئی میان داده‌های پیش‌بینی شده و واقعی در نقاط بیشینه وجود دارد. در نقاط بیشینه، مدل مقادیر کمتری نسبت به واقعیت پیش‌بینی کرده و در نقاط کمینه مقداری بیشتر از داده‌های آزمایشگاهی پیش‌بینی شده است. در کل این نتایج نشان می‌دهد که روش QNET با دقت بالا و همبستگی قوی میان داده‌های واقعی و پیش‌بینی شده، به‌ویژه در مرحله آموزش، عملکرد مطلوبی دارد. مقادیر R^2 و نمودارهای پراکنش تأیید می‌کنند که این مدل توانایی بالایی در شبیه‌سازی دقیق عمق آبستگي دارد.

جدول ۵. ارزیابی ترکیبات مختلف ورودی برای تعیین عمق آبستنگی مربوط به روش QNET

TRAIN			TEST			نام ترکیب
DC	R ²	RMSE	DC	R ²	RMSE	
۰/۹۰۸۰	۰/۹۰۸۱	۰/۰۶۱۱	۰/۴۹۳۴	۰/۷۰۱۵	۰/۱۲۷۵	ترکیب ۱
۰/۶۹۹۷	۰/۷۰۰۹	۰/۱۱۳۳	۰/۳۳۵۴	۰/۱۶۴۸	۰/۱۹۵۷	ترکیب ۲
۰/۶۵۱۰	۰/۶۶۰۴	۰/۱۱۰۸	۰/۲۰۱۰	۰/۶۵۷۹	۰/۱۷۴۳	ترکیب ۳
۰/۶۸۱۷	۰/۶۸۱۸	۰/۱۰۲۹	۰/۱۷۰۰	۰/۴۱۵۱	۰/۱۸۹۹	ترکیب ۴
۰/۷۸۲۳	۰/۷۸۳۴	۰/۰۸۳۲	۰/۲۷۱۷	۰/۴۱۵۰	۰/۱۵۶۴	ترکیب ۵
۰/۴۳۷۹	۰/۴۳۸۳	۰/۱۴۹۵	۰/۱۷۲۴	۰/۴۱۱۷	۰/۱۷۶۲	ترکیب ۶
۰/۴۳۷۶	۰/۴۳۷۶	۰/۱۲۸۷	۰/۲۰۰۶	۰/۳۳۱۳	۰/۱۹۵۸	ترکیب ۷
۰/۳۷۴۹	۰/۳۷۵۴	۰/۱۴۵۲	۰/۱۴۷۲	۰/۱۶۶۲	۰/۲۱۲۱	ترکیب ۸
۰/۶۶۷۸	۰/۶۶۹۷	۰/۱۰۵۱	۰/۳۹۰۳	۰/۴۰۸۱	۰/۱۶۲۸	ترکیب ۹
۰/۶۰۳۵	۰/۶۰۳۹	۰/۱۱۴۸	۰/۳۰۳۱	۰/۳۳۳۲	۰/۱۹۳۶	ترکیب ۱۰
۰/۶۰۷۶	۰/۶۰۷۶	۰/۱۱۴۲	۰/۳۵۰۷	۰/۳۸۳۵	۰/۱۶۸۰	ترکیب ۱۱



شکل ۷. نمودار پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده مرحله آموزش و آزمون مربوط به روش QNET

آنالیز حساسیت

آنالیز حساسیت یکی از روش‌های مهم برای ارزیابی اثرات تغییرات پارامترهای ورودی در خروجی یک مدل است. این تحلیل اثبات می‌کند که کدام متغیرها یا پارامترها تأثیر بیشتری بر نتایج مدل می‌گذارند و به بهبود درک از نقش پارامترهای مختلف در عملکرد مدل کمک می‌کند. به عبارت دیگر، در آنالیز حساسیت با تغییر هر یک از پارامترهای ورودی مشخص می‌شود که تا چه حد خروجی مدل دچار تغییر خواهد شد. در این پژوهش برای انجام آنالیز حساسیت با توجه به داده‌های موجود، مقادیر ضریب تبیین (DC) و ریشه میانگین مربعات خطا (RMSE) برای هر ترکیب مورد ارزیابی قرار گرفته‌اند. هدف از این انجام این آنالیز، شناسایی ترکیبی است که بالاترین دقت و کمترین

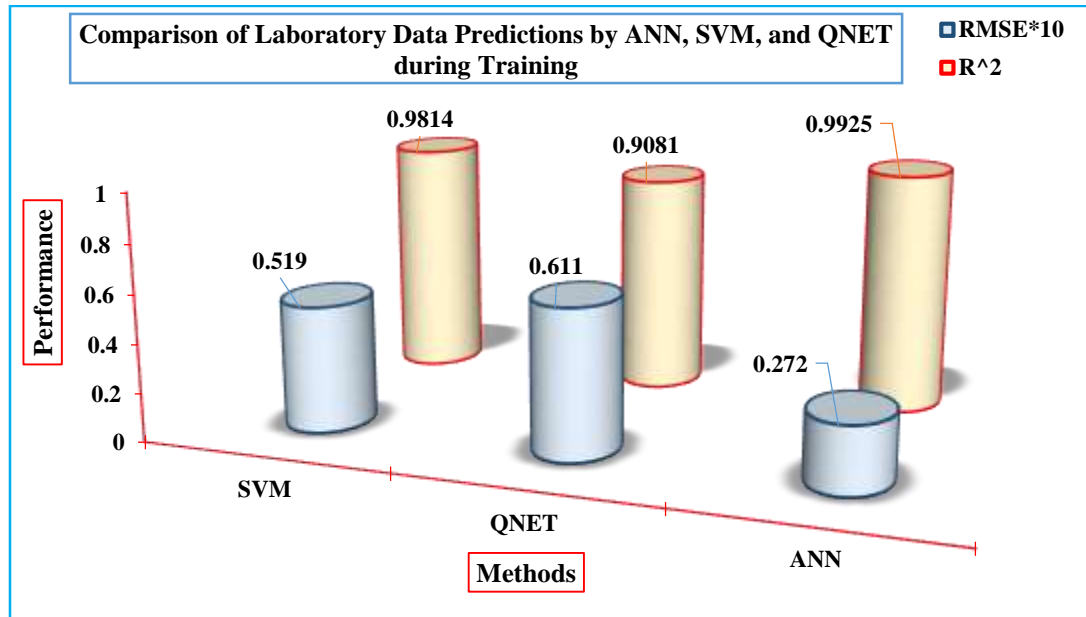
میزان خطا را در پیش بینی عمق آبستگي داشته باشد. نتایج حاصل از جدول ۶ نشان می دهند که حذف پارامتر $(\frac{e}{D})$ در هر سه روش شبکه عصبی مصنوعی، ماشین بردار پشتیبان و روش QNET منجر به کاهش دقت مدل و افزایش میزان خطا شده است. به بیان دیگر، معیارهای آماری در این شرایط عملکرد ضعیف تری را نشان داده اند. بر این اساس، نسبت بی بعد فاصله لوله از بستر $(\frac{e}{D})$ به عنوان مؤثرترین و مهم ترین پارامتر در پیش بینی عمق آبستگي در هر سه روش شبکه عصبی مصنوعی، ماشین بردار پشتیبان و روش QNET شناخته شد.

جدول ۶. آنالیز حساسیت مربوط به روش های ANN, SVM, QNET

روش ANN							حذف پارامتر	نام ترکیب
TRAIN			TEST					
DC	R ²	RMSE	DC	R ²	RMSE			
-/۰۹۹۳۵	-/۰۸۷۹۴	-/۰۲۷۲	-/۰۹۲۷۱	-/۰۷۹۷۶	-/۰۱۱۸۰	-	ترکیب ۱	
-/۰۸۵۸۹	-/۰۸۵۹۸	-/۰۱۱۶۸	-/۰۶۸۴۴	-/۰۶۶۷۶	-/۰۲۲۲۹	$\frac{e}{D}$	ترکیب ۱	
-/۰۹۲۸۷	-/۰۹۲۸۷	-/۰۸۵۵	-/۰۳۳۵۸	-/۰۷۷۶۳	-/۰۲۵۳۰	Fr	ترکیب ۱	
-/۰۸۶۳۹	-/۰۸۶۳۹	-/۰۱۱۸۲	-/۰۸۱۱۹	-/۰۸۵۸۹	-/۰۱۳۴۶	$\frac{y}{D}$	ترکیب ۱	
-/۰۸۷۷۸	-/۰۸۷۸۹	-/۰۱۱۲۰	-/۰۸۰۲۵	-/۰۸۷۶۴	-/۰۱۳۷۹	$\frac{L}{D}$	ترکیب ۱	
روش SVM							حذف پارامتر	نام ترکیب
TRAIN			TEST					
DC	R ²	RMSE	DC	R ²	RMSE			
-/۰۹۷۲۴	-/۰۸۱۱۴	-/۰۵۱۹	-/۰۸۳۲۲	-/۰۸۳۵۰	-/۰۱۸۱۹	-	ترکیب ۱	
-/۰۸۵۹۱	-/۰۸۸۴۳	-/۰۱۱۴۸	-/۰۵۰۹۹	-/۰۳۶۷۱	-/۰۳۶۵۷	$\frac{e}{D}$	ترکیب ۱	
-/۰۹۷۰۹	-/۰۹۸۰۱	-/۰۵۴۷	-/۰۶۰۷۱	-/۰۶۱۱۹	-/۰۲۲۶۲	Fr	ترکیب ۱	
-/۰۹۶۰۴	-/۰۹۳۴۱	-/۰۹۵۹	-/۰۹۱۱۲	-/۰۶۹۷۷	-/۰۱۹۴۱	$\frac{y}{D}$	ترکیب ۱	
-/۰۹۷۴۵	-/۰۹۷۹۷	-/۰۵۱۹	-/۰۵۷۳۱	-/۰۷۱۷۰	-/۰۲۱۴۷	$\frac{L}{D}$	ترکیب ۱	
روش QNET							حذف پارامتر	نام ترکیب
TRAIN			TEST					
DC	R ²	RMSE	DC	R ²	RMSE			
-/۰۹۰۸۰	-/۰۹۰۸۱	-/۰۶۱۱	-/۰۴۹۲۴	-/۰۷۰۱۴	-/۰۱۲۷۵	-	ترکیب ۱	
-/۰۶۹۹۷	-/۰۷۰۰۹	-/۰۱۱۳۳	-/۰۳۳۵۴	-/۰۱۶۴۸	-/۰۱۹۵۷	$\frac{e}{D}$	ترکیب ۱	
-/۰۶۵۱۰	-/۰۶۶۰۴	-/۰۱۱۰۸	-/۰۲۰۱۰	-/۰۶۵۷۹	-/۰۱۷۴۳	Fr	ترکیب ۱	
-/۰۶۸۱۷	-/۰۶۸۱۸	-/۰۱۰۲۹	-/۰۱۷۰۰	-/۰۴۱۵۱	-/۰۱۸۹۹	$\frac{y}{D}$	ترکیب ۱	
-/۰۷۸۲۳	-/۰۷۸۳۴	-/۰۸۳۲	-/۰۲۷۱۷	-/۰۴۱۵۰	-/۰۱۵۶۴	$\frac{L}{D}$	ترکیب ۱	

مقایسه نتایج سه روش بررسی شده (ANN, SVM, QNET)

شکل ۸ نمودارهای پراکنش داده های آزمایشگاهی و مقادیر پیش بینی شده مربوط به برترین ترکیب در مرحله آموزش را نشان می دهد. این ترکیب شامل پارامترهای $\frac{e}{D}$, $\frac{y}{D}$, Fr, $\frac{L}{D}$ بوده و برای هر سه روش شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و روش QNET در مرحله آزمون ارائه شده است. بررسی دقیق نمودارها نشان می دهد که روش شبکه عصبی مصنوعی در مقایسه با دو روش دیگر، مقادیر RMSE پایین تر و R² بالاتری ارائه می دهد، که نشان دهنده دقت بالاتر این مدل در بازتولید داده های آزمایشگاهی است.



شکل ۸. نمودار مقایسه‌ای با استفاده از روش‌های (ANN, SVM, QNET) مربوط به مرحله‌ی آموزش

مقایسه با تحقیقات پیشین

برای برجسته‌سازی نوآوری‌ها و ارزش علمی این پژوهش، یافته‌های آن با نتایج مطالعات پیشین معتبر در زمینه پیش‌بینی عمق آبستگي اطراف خطوط لوله مقایسه شده است تا تأیید، تکمیل یا تفاوت‌های آن‌ها با دقت آشکار شود.

(Parsaie et al., 2019) با استفاده از روش ماشین‌بردار پشتیبان (SVM) برای پیش‌بینی عمق آبستگي زیر خطوط لوله رودخانه‌ای، در مرحله آزمون به $R^2 = 0.94$ و $RMSE = 0.103$ دست یافتند. این مدل کمی برتر از ANN با $R^2 = 0.89$ ، $RMSE = 0.12$ و ANFIS با $R^2 = 0.92$ ، $RMSE = 0.13$ بود. تحلیل حساسیت نشان داد که e/D ، τ^* و Fr مؤثرترین پارامترها برای پیش‌بینی عمق آبستگي هستند.

(Hu et al., 2021) روش‌های یادگیری ماشین شامل GA-BP neural network، SVM و RBF را برای پیش‌بینی عمق آبستگي تعادلی زیر خطوط لوله زیرآبی (با در نظر گرفتن زاویه برخورد جریان) بررسی کردند. نتایج نشان داد که مدل بهترین عملکرد را دارد و بالاترین ضریب همبستگی و پایین‌ترین $RMSE$ را نسبت به SVM و RBF در شرایط live-bed به دست آورد. تحلیل حساسیت تأیید کرد که عدد فرود (Fr) مؤثرترین پارامتر است و با افزایش زاویه برخورد جریان، تأثیر آن بر نتایج پیش‌بینی بیشتر می‌شود. (Xiu et al., 2025) با ترکیب مدل عددی RANS و اصول انتقال رسوب، ۱۴۵ مورد شبیه‌سازی برای شرایط موج و جریان انجام دادند و سپس از مدل regression مبتنی بر درخت تصمیم برای پیش‌بینی استفاده کردند (داده‌ها نرمال‌سازی و به ۸۰٪ آموزش و ۲۰٪ آزمون تقسیم شدند). در مرحله آزمون، مدل برای عمق آبستگي (S) به $R^2 = 0.94$ و $RMSE = 0.43$ ، برای عمق بدون بعد (S/D) به $R^2 = 0.92$ و برای عرض گودال آبستگي (L) به $R^2 = 0.97$ و $RMSE = 0.267$ رسید. این مدل عملکرد خوب و کارایی محاسباتی بالایی برای پیش‌بینی سریع نشان داد.

در مقایسه، نتایج حاضر برای مدل ANN به‌عنوان روش برتر در ترکیب بهینه (ترکیب ۱) مقادیر زیر را کسب کرد:

مرحله آموزش: $DC = 0.9932$ ، $R^2 = 0.9925$ ، $RMSE = 0.272$

مرحله آزمون: $DC = 0.8959$ ، $R^2 = 0.8935$ ، $RMSE = 0.1180$

مدل SVM نیز عملکرد مناسبی نشان داد آموزش: $DC = 0.9724$ ، $R^2 = 0.9814$ ، $RMSE = 0.519$ ؛ آزمون: $DC = 0.919$ ، $RMSE \approx 0.1819$

، $DC \approx 0.8322$ ، $R^2 \approx 0.8350$ و مدل QNET با مقادیر آموزش $DC = 0.9081$ ، $R^2 = 0.9081$ ، $RMSE = 0.611$ و آزمون $DC = 0.7015$ ، $R^2 = 0.4924$ ، $RMSE = 0.1275$.

مقایسه نشان می‌دهد که مدل ANN پیشنهادی در این پژوهش، به‌ویژه در مرحله آموزش، دقت بسیار بالایی دارد $R^2 = 0.9925$ و

$RMSE = 0.272$ که پایین‌تر از $RMSE = 0.43$ مدل Xiu et al در آزمون است. حتی در مرحله آزمون، مقادیر R^2 و $RMSE$ در محدوده

قابل قبول و نزدیک به بهترین مدل‌های گزارش شده در مطالعات پیشین مانند SVM در Parsaie et al. با $R^2 = 0/94$ و $RMSE = 0/103$ در آزمون یا Decision-tree در Xiu et al قرار می‌گیرد. این بهبود عمدتاً به دلیل مجموعه داده آزمایشگاهی واقعی (۳۶ مجموعه داده)، بهینه‌سازی دقیق پارامترهای ورودی و ساختار مدل و اهمیت ویژه پارامتر «فاصله لوله از بستر» (که تحلیل حساسیت آن را به‌عنوان متغیر غالب تأیید کرد) است. مدل SVM پیشنهادی نیز عملکردی نزدیک به SVM در Parsaie et al. 2019 نشان داد.

این مقایسه تأیید می‌کند که روش‌های هوش مصنوعی مورد استفاده در این تحقیق به‌خصوص ANN می‌توانند به‌عنوان جایگزین معتبر، دقیق و کارآمد برای مدل‌های سنتی، عددی یا ترکیبی ML/CFD پیشین در ارزیابی ریسک آبستگي خطوط لوله به‌کار گرفته شوند و به کاهش هزینه‌ها و خطرات زیست‌محیطی مرتبط با زیرساخت‌های هیدرولیکی کمک نمایند.

نتیجه‌گیری کلی

در این پژوهش، به منظور پیش‌بینی عمق آبستگي، از روش‌های هوش مصنوعی شامل شبکه عصبی مصنوعی، ماشین بردار پشتیبان و روش QNET بر مبنای داده‌های آزمایشگاهی عطائیان (۱۳۹۰) استفاده شد. عملکرد روش‌های هوش مصنوعی شبکه عصبی مصنوعی، ماشین بردار پشتیبان و روش QNET در پیش‌بینی عمق آبستگي به کمک ۳۶ سری داده به‌طور دقیق در این پژوهش مورد بررسی قرار گرفت. هرچند تعداد داده‌ها محدود (۳۶) است، اما به کارگیری داده‌های حاصل از آزمایش‌های کنترل‌شده در فلوم آزمایشگاهی و استفاده از سه روش هوش مصنوعی پیشرفته، تعمیم‌پذیری نتایج تضمین شده و صحت مدل‌ها با شاخص‌های آماری اعتبارسنجی گردیده است. نتایج آنالیز حساسیت نشان داد که حذف پارامتر $\left(\frac{e}{D}\right)$ منجر به کاهش دقت مدل و افزایش میزان خطا شده است. این نتیجه بیانگر این است که تغییرات $\left(\frac{e}{D}\right)$ به‌طور مستقیم بر عمق آبستگي تأثیر می‌گذارد. در این پژوهش، ترکیب بهینه‌ای از پارامترهای هیدرولیکی شامل $\left(\frac{e}{D}, \frac{ds_{max}}{D}, \frac{e}{D}, \frac{y}{D}, Fr, \frac{L}{D}\right)$ شناسایی شده است که به‌عنوان مؤثرترین ترکیب (ترکیب ۱) برای پیش‌بینی عمق آبستگي در سیستم‌های هیدرولیکی شناخته شد. بررسی‌های انجام‌شده نشان داد که این ترکیب نسبت به دیگر ترکیبات دارای دقت پیش‌بینی بالاتری است. با توجه به شکل ۳ می‌توان نتیجه گرفت که روش شبکه هوش مصنوعی در مقایسه با دیگر روش‌ها نتیجه بهتری از خود نشان داده است و عملکرد دقیق‌تری در پیش‌بینی عمق آبستگي داشته است. در نهایت، این تحقیق به درک بهتر از اهمیت انتخاب پارامترهای مناسب در مدل‌سازی هیدرولیکی کمک کرده و زمینه‌ساز توسعه روش‌های نوین در این حوزه خواهد بود.

منابع

- حبیب، آرمان؛ ابوالفتی، سروش؛ اوسالیوان، جان و صلاح‌الدین، محمد. (۱۴۰۳). مدل‌های کارآمد یادگیری ماشین برای پیش‌بینی عمق آبستگي در سازه‌های ساحلی شیب‌دار. پیشرفت‌ها در محیط ساخته شده، ۱۰، ۱۳۴۳۳۹۸.
- حسن، وقید و جلال، هاله. (۱۴۰۰). پیش‌بینی عمق آبستگي موضعی در پایه پل با استفاده از روش برنامه‌نویسی بیان ژنی. اس.ان. / اپلاید ساینسز، ۳(۲)، ۱۵۹.
- سلطانی ستوبادی، مهدی؛ امیدپور علویان، توحید و کاردان، نازیلا. (۱۴۰۴). پیش‌بینی عمق آبستگي موضعی اطراف پایه‌های پل استوانه‌ای در بسترهای با خاک چسبنده با استفاده از روش‌های فرامدلی. نشریه آبیاری و زهکشی ایران، ۱۹(۲)، ۲۷۵-۲۹۰.
- عطائیان، آتوسا. (۲۰۱۱). برآورد عمق آبستگي موضعی در زیر خط لوله عبوری از رودخانه [پایان‌نامه کارشناسی‌ارشد، دانشگاه ارومیه، دانشکده کشاورزی، ایران].

REFERENCES

- Abbasi, M., & Kazemi, F. (2018). Limitations and adjustments of QNET in complex flow scenarios. Applied Ocean Research, 75, 76–82.
- Atayeian, A. (2011). Estimation of local scour depth beneath a pipeline crossing a river [Master's thesis, University of Urmia, Faculty of Agriculture, Iran]. (In persian)
- Azamatullah, M. N., Deo, M. C., & Yadav, R. N. (2012). Prediction of pipeline scour using neural networks. Marine Structures, 25(1), 34–53.
- Batani, S. M., Borghai, S. M., & Jeng, D. S. (2007). Neural network and neuro-fuzzy assessments for scour depth around bridge piers. Advances in Engineering Software, 38(2), 102–111. <https://doi.org/10.1016/j.engappai.2006.06.012>



- Bijker, E. W., & Leeuwestein, W. (1984). Interaction between pipelines and the seabed under the influence of waves and currents. *Proceedings of the Conference on Behavior of Offshore Structures*, 3, 343–356. https://doi.org/10.1007/978-94-009-4958-4_28
- Chao, J. L., & Hennessy, P. V. (1972). Local Scour under Ocean Outfall Pipelines. *Journal (Water Pollution Control Federation)*, 44(7), 1443–1447. <http://www.jstor.org/stable/25037552>
- Chiew, Y. M. (1991). Prediction of maximum scour depth at submarine pipelines. *Journal of Hydraulic Engineering*, 117(4), 452–466. [https://doi.org/10.1061/\(ASCE\)0733429\(1991\)117:4\(452\)](https://doi.org/10.1061/(ASCE)0733429(1991)117:4(452))
- Choi, S. U., & Jung, S. (2006). Prediction of local scour around bridge piers using artificial neural networks. *Journal of the American Water Resources Association*, 42(2), 487–494. <https://doi.org/10.1111/j.1752-1688.2006.tb03852.x>
- De, D., Roy, S., & Chattopadhyay, S. (2006). Predicting scour depth using neural networks. *Journal of Hydrologic Engineering*, 11(2).
- Dey, X. (2010). Comparative analysis of scour prediction methods: The QNET approach. *International Journal of Hydraulic Research*, 52(1), 120–130.
- Dey, X., Zhao, Y., & Lu, Q. (2008). Mechanics of steady-state scour: a comparative study using QNET models. *Journal of Hydraulic Engineering*, 134(11), 1608–1616.
- Ferdesou, T. (2020). QNET model enhancement for pipeline-riverbed interaction analysis. *Journal of Marine Science and Engineering*, 8(11), 890.
- Habib, M. A., Abolfathi, S., O'Sullivan, John. J., & Salauddin, M. (2024). Efficient data-driven machine learning models for scour depth predictions at sloping sea defences. *Frontiers in Built Environment*, 10, 1343398. <https://doi.org/10.3389/fbuil.2024.1343398>. (In persian)
- Hassan, W. H., & Jalal, H. K. (2021). Prediction of the depth of local scouring at a bridge pier using a gene expression programming method. *SN Applied Sciences*, 3(2), 159. <https://doi.org/10.1007/s42452-020-04124-9>. (In persian)
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall.
- Heydari, S., et al. (2016). Scour prediction under storm conditions using QNET: A tool for natural disaster management. *Natural Hazards Review*, 17(2), 04016006.
- Hu, K., Bai, X., Zhang, Z., & Vaz, M. A. (2021). Prediction of submarine pipeline equilibrium scour depth based on machine learning applications considering the flow incident angle. *Applied Ocean Research*, 112, 102717. <https://doi.org/10.1016/j.apor.2021.102717>
- Hu, R., Wang, X., Liu, H., Leng, H., & Lu, Y. (2022). Scour Characteristics and Equilibrium Scour Depth Prediction around a Submarine Piggyback Pipeline. *Journal of Marine Science and Engineering*, 10(3), 350. <https://doi.org/10.3390/jmse10030350>
- Ibrahim, A., & Nalluri, C. (1986). Scour prediction around marine pipelines. In *International offshore mechanics and arctic engineering. Symposium*. 5 (pp. 679–684).
- Kazilos, P., et al. (2011). Utilization of QNET for enhanced scour prediction around submarine pipelines. *Marine Structures*, 24(3), 318–329.
- Khan, Z., Nanda, S., & Goel, A. (2014). Prediction of scour depth around submerged pipelines using artificial neural networks. *Journal of Pipeline Systems Engineering and Practice*, 5(1), 04013009.
- Kjeldsen, S. P., Einstein, H. H., & Christensen, B. A. (1973). Local scour near offshore pipelines. In *Paper available only as part of the complete Proceedings of the Second International Conference on Port and Ocean Engineering Under Arctic Conditions (POAC)*, August 27-30, 1973.
- Marulasiddappa, S. B., Patil, A. P., Kuntoji, G., et al. (2024). Prediction of scour depth around bridge abutments using ensemble machine learning models. *Neural Computing and Applications*, 36, 1369–1380. <https://doi.org/10.1007/s00521-023-09109-4>
- Mattioli, P., et al. (2019). Bed dynamics and QNET modeling accuracy in close-bed interactions. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 145(5), 04019012.
- Maza, J. A. (1987). *Introduction to river engineering*. Advanced Course on Water Resources Management, Universita Italiana per Stranieri.
- Nandi, B., & Das, S. (2025). Prediction of maximum scour depth at clear water conditions: *Multivariate analysis*. *Journal of Environmental Management*, 354, 120349. <https://doi.org/10.1016/j.jenvman.2024.120349>
- Oliveira, A., Melo, M. S., & Tormena, J. M. (2013). Application of artificial neural networks for scour prediction at submerged pipeline crossings. *Applied Ocean Research*, 40, 75–82.
- Parsaie, A., Haghiabi, A. H., & Moradinejad, A. (2019). Prediction of Scour Depth below River Pipeline using Support Vector Machine. *KSCE Journal of Civil Engineering*, ۲۳(۶), ۲۵۶۲–۲۵۷۱.

<https://doi.org/10.1007/s12205-019-1327-0>

Qnet v2000 (Trial Version). (2000). Developed by Vesta Services, Inc., Winnetka, IL, USA. Archival information and download links available at: <https://qnet-2000.software.informer.com/> and <https://qnetv2kt.software.informer.com>

Rahimi, A., et al. (2015). Application of QNET for turbulent flow conditions: Environmental and structural impact analysis. *Journal of Hydraulic Engineering*, 141(8), 04015019.

Rahman, F., & Chavan, R. (2025). Machine Learning Application in Prediction of Scour Around Bridge Piers: A Comprehensive Review. *Archive of Computational Methods in Engineering*, 32, 1299–1322. <https://doi.org/10.1007/s11831-024-10167-7>

Sharifi, M., et al. (2017). Evaluating QNET for scour depth prediction across varied flow and substrate conditions. *Journal of Coastal Research*, 34(1), 1–10.

Soltani Sotobadi, M., Omidpour Alavian, T., & Kardan, N. (2025). Forecasting the Local Scour Depth around Cylindrical Bridge Foundations on Cohesive Soil Utilizing Meta Models. *Iranian Journal of Irrigation and Drainage*, 19(2), 275–290. (In persian)

Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag. <https://doi.org/10.1007/978-1-4757-2440-0>

Xiu, Z., Luo, C., Liu, L., Du, X., Gao, W., Song, Y., Shi, B., & Chi, W. (2025). CFD and machine learning approach based-predictive modeling of scouring below submarine pipeline under wave and current condition. *Marine Georesources & Geotechnology*, 43(9), 1779-1795.

<https://doi.org/10.1080/1064119X.2024.2434954>