

# A Monte Carlo-LSTM Framework for Realistic Assessment and Predictive Management of Urban Canal Dredging

Mohammadreza Masoudi Moghaddam<sup>1\*</sup>, Jafar Yazdi<sup>2</sup>

1- PhD Candidate, Department of Water Resources Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran.

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

\* [m\\_masoudimoghaddam@sbu.ac.ir](mailto:m_masoudimoghaddam@sbu.ac.ir)

Received: 9 August 2025  
Revised: 3 February 2026  
Accepted: 12 February 2026  
Discussion: 23 September 2026



J. Hydraul.  
Iranian Hydraulic Association  
Homepage: [www.jhyd.iha.ir](http://www.jhyd.iha.ir)

## Abstract

**Introduction:** Flood-control canals are essential for protecting urban and agricultural areas, but maintaining their hydraulic capacity through dredging is costly and continuous. Traditionally, dredging effectiveness is evaluated after completion using hydrographic data and observed performance. This reactive “dredge-and-see” approach is inefficient and risky because it focuses on past outcomes rather than future needs.

A more effective approach is to shift toward a predictive management framework that accounts for uncertainty. Deterministic hydraulic models often imply unrealistic precision, while real systems are affected by uncertainties in parameters, input data, and model structure. Monte Carlo simulation can quantify these uncertainties by producing a range of possible outcomes, but it cannot forecast future conditions. In contrast, deep learning models, especially LSTM networks, are effective for predicting complex time-series variables such as river flow and water levels.

This paper addresses the research gap by integrating Monte Carlo uncertainty analysis with LSTM-based forecasting, transforming dredging evaluation from a retrospective process into a strategic, forward-looking management tool.

**Methodology:** This study was conducted on the Abu Dhar canal in Tehran, Iran, a key component of the city's urban runoff network. Field data, including hydraulic and geometric parameters, were collected before and after a dredging operation on July 9, 2023. Water levels were continuously recorded at 15-minute intervals using ultrasonic sensors, while flow velocity and cross-sectional dimensions were measured using a current meter and surveying operations, respectively.

The methodological framework consisted of three main stages:

1. **Deterministic Baseline Calculation:** First, the classical Manning's equation was used with field data to calculate the initial, deterministic values for Manning's 'n' before and after dredging. This calculation yielded a baseline improvement of 4.47% and provided the mean values ( $\mu$ ) for the subsequent probabilistic analysis.
2. **Probabilistic Uncertainty Analysis:** A Monte Carlo simulation framework was implemented to quantify the uncertainty surrounding this baseline value. Key inputs—flow velocity ( $V$ ) and

a geometric factor ( $K$ )—were modeled as random variables with normal distributions, assuming relative uncertainties of 5% and 2%, respectively. The simulation was run for 50,000 iterations to generate a full probability distribution of the percentage reduction in Manning's 'n'.

3. Time-Series Forecasting (Proof of Concept): To demonstrate the feasibility of predictive management, an LSTM network was developed. Field-collected 24-hour water-level time series data (as described in the main text) was utilized. The data was normalized using a MinMaxScaler, and sequences were created using a look-back window of 8 time-steps (2 hours) to predict the next step. The LSTM model, consisting of one LSTM layer (50 units) and one Dense output layer, was trained for 50 epochs using the 'adam' optimizer. Its performance was evaluated using the Root Mean Squared Error (RMSE) on unseen test data.

**Results and Discussion:** The Monte Carlo analysis revealed that while the mean reduction in Manning's 'n' was 4.47%, the 95% confidence interval was exceptionally wide, spanning from -9.66% to +17.12%. This finding is critical, as it exposes the "illusion of certainty" in traditional assessments. It demonstrates that while the project was likely beneficial on average, the measurement uncertainty is so significant that a wide range of outcomes, including no improvement, cannot be statistically ruled out. The resulting probability distribution (visualized in Figure 4) highlights the inherent risk and variability that are ignored by deterministic approaches. This probabilistic view provides a more honest and managerially useful assessment of the project's risk profile. On the predictive front, the LSTM model demonstrated high efficacy. The final evaluation on the test set yielded an RMSE of only 0.032 meters (3.2 cm). This high level of accuracy confirms the model's potential for operational applications. The model's predictions (visualized in Figure 8) confirm this accuracy, showing the forecasted data closely tracking the complex fluctuations of the real-world time series. This successful proof of concept illustrates a paradigm shift from reactive maintenance to proactive, data-driven management. It opens the door for developing real-time flood warning systems and "Digital Twins" of urban water infrastructure. In synthesis, this study's probabilistic analysis offers a realistic "hindcast" of past actions, while the predictive model provides a powerful "forecast" for future management.

**Conclusion:** This research successfully developed and applied a dual framework that integrates probabilistic uncertainty analysis and deep learning-based forecasting for the evaluation of canal dredging projects. The study concludes that traditional, deterministic assessments are insufficient as they neglect critical uncertainties. The proposed framework provides a more realistic, comprehensive, and powerful approach. By combining an honest, probabilistic view of past performance with an intelligent, predictive tool for future events, this research offers a clear pathway toward more efficient, resilient, and data-driven management of urban water infrastructure in the digital age.

**Keywords:** Dredging, Uncertainty Quantification, Monte Carlo Simulation, LSTM, Predictive Maintenance.

#### References:

1. Pathan, A. I., Sidek, L. B. M., Basri, H. B., Hassan, M. Y., Khebir, M. I. A. B., Omar, S. M. B. A., ... & Ahmed, A. N. (2024). Comparative assessment of rainfall-based water level prediction using machine learning (ML) techniques. *Ain Shams Engineering Journal*, 15(7), 102854.
2. Wu, W., & Wan, L. (2022). Coastal ecological and environmental management under multiple anthropogenic pressures: A review of theory and evaluation methods. *Current Trends in Estuarine and Coastal Dynamics*, 385-415.
3. Camacho, R. A., Zhang, Z., & Chao, X. (2019). Receiving water quality models for TMDL development and implementation. *Journal of Hydrologic Engineering*, 24(2), 04018063.

**Conflict of Interest:** The authors declared no potential conflicts of interest concerning the research, authorship, and publication of this article.

**Funding:** The authors received no financial support for the research, authorship, and publication of this article.

**Data Availability Statements:** All information and results are presented in the text of the article. The datasets generated and/or analyzed during the current study are available from the corresponding author on reasonable request.

**Authors' contribution:**

**First Author:** Conceptualization, Methodology, Writing – original draft, and model implementation.

**Second Author:** Data analysis, Supervision, and Reviewing the results.

# یک چارچوب مونت کارلو- LSTM برای ارزیابی واقع بینانه و مدیریت پیش بینانه لایروبی کانال های شهری

محمدرضا مسعودی مقدم<sup>\*</sup>، جعفر یزدی<sup>۲</sup>

۱- دانشجوی دکتری، گروه مهندسی منابع آب، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران.  
۲- دانشیار گروه مهندسی منابع آب، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران.

\* m\_masoudimoghaddam@sbu.ac.ir

نشریه هیدرولیک  
انجمن هیدرولیک ایران  
وبگاه نشریه هیدرولیک: www.jhyd.iha.ir



دریافت: ۱۴۰۴/۰۵/۱۸  
بازنگری: ۱۴۰۴/۱۱/۱۴  
پذیرش: ۱۴۰۴/۱۱/۲۳  
نقد و بررسی: ۱۴۰۵/۰۷/۰۱

**چکیده:** ارزیابی اثربخشی لایروبی کانال‌ها برای مدیریت پایدار رواناب شهری حیاتی است. با این حال، رویکردهای سنتی که به گزارش یک شاخص قطعی (مانند درصد کاهش زبری مانینگ) اکتفا می‌کنند، عدم قطعیت‌های ذاتی در اندازه‌گیری‌های میدانی و پتانسیل مدل‌های پیش‌بینی مدرن را نادیده می‌گیرند. این پژوهش یک چارچوب ارزیابی دوگانه و نوآورانه برای رفع این خلاء ارائه می‌دهد. در این مطالعه، از داده‌های میدانی سطح آب و سرعت جریان قبل و بعد از لایروبی کانال ابوذر تهران استفاده شد. ابتدا، یک شبیه‌سازی مونت کارلو برای کمی‌سازی تأثیر عدم قطعیت در پارامترهای اندازه‌گیری شده بر روی ضریب زبری مانینگ پیاده‌سازی شد. سپس، به عنوان اثبات مفهوم، یک شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM) برای پیش‌بینی سری زمانی نوسانات سطح آب در کانال، بر اساس داده‌های سنسورها، توسعه داده شد. نتایج تحلیل عدم قطعیت نشان داد که اگرچه میانگین کاهش ضریب مانینگ ۴.۴۷ درصد بود، اما بازه اطمینان ۹۵٪ این کاهش، بسیار گسترده و بین ۹.۶۶- تا ۱۷.۱۲ درصد قرار دارد. این یافته به اهمیت حیاتی در نظر گرفتن عدم قطعیت در تحلیل‌های هیدرولیکی تأکید می‌کند. علاوه بر این، مدل LSTM توسعه‌یافته با موفقیت الگوهای زمانی را فرا گرفت و توانست سطح آب را با دقت بالا و ریشه میانگین مربعات خطای (RMSE) تنها ۳.۲ سانتی‌متر بر روی داده‌های آزمون، پیش‌بینی نماید. این مطالعه نتیجه می‌گیرد که تلفیق تحلیل‌های احتمالاتی با مدل‌های پیش‌بینی هوش مصنوعی، دیدگاهی بسیار واقع بینانه‌تر و جامع‌تر نسبت به روش‌های ارزیابی سنتی فراهم کرده و گامی اساسی به سوی مدیریت داده‌محور و هوشمند زیرساخت‌های آبی شهری است.

**کلیدواژگان:** لایروبی کانال، ضریب مانینگ، تحلیل عدم قطعیت، شبیه‌سازی مونت کارلو، یادگیری عمیق، LSTM، مدیریت رواناب شهری.

## ۱- مقدمه

میزان افزایش ظرفیت آگذری رودخانه ارزیابی می‌شود (HEC-RAS, 2016). در سال‌های اخیر، استفاده از شبیه‌سازی‌های هیدرولیکی دوپسی (2D) با داده‌های باکیفیت، به عنوان ابزاری دقیق برای بهبود نقشه‌های خطر سیلاب شهری و ارزیابی تأثیر اقدام‌های انجام شده مهندسی مانند لایروبی، به شدت مورد توجه قرار گرفته است (Mihu- et al., 2019). در این راستا، پژوهش و ارزیابی‌ها

آبراهه‌های سیلاب‌رو، زیرساخت‌های کلیدی برای حفاظت از جامعه‌های شهری و کشاورزی به شمار می‌آیند. حفظ ظرفیت هیدرولیکی این آبراهه‌ها مستلزم یک فعالیت نگهداری پیوسته، پرهزینه و ضروری به نام لایروبی است. اثربخشی این عملیات به طور معمول با استفاده از مدل‌های هیدرولیکی برای ارزیابی پیش‌فرض‌های مختلف و سنجش

نشان داده‌اند که افزودن بر کیفیت داده‌ها، فراسنجه‌های محاسباتی مانند فاصله‌های شبکه‌بندی و بهره‌گیری از پردازش موازی نقش تعیین‌کننده‌ای در تعادل میان سرعت و دقت مدل‌سازی‌های عددی سیلاب ایفا می‌کنند (Teymouri et al., 2025). به طور سنتی، ارزیابی اثربخشی پروژه‌های لایروبی یک فرآیند بنیادین و اقدام پس‌نگر است؛ به این معنا که داوران در مورد موفقیت یک پروژه پس از پایان آن و بر مبنای داده‌های هیدروگرافی و عملکرد مشاهده‌شده آبراهه صورت می‌گیرد. این رویکرد، که بر اصول تثبیت‌شده هیدرولیک مانند محاسبه سرعت جریان با استفاده از فرمول مانینگ و طراحی سازه‌های انجام شده مهندسی مانند آبشکن‌ها استوار است (van der Meer et al., 2010)، دارای محدودیت‌های ذاتی است. فعالیت‌های انسانی مانند ساخت‌وسازهای ساحلی و لایروبی، به عنوان یک نیروی بیرونی مهم، می‌توانند به طور قابل توجهی مورفودینامیک ساحل‌ها و خورها را تغییر دهند (Wu & Wan, 2022). نمونه‌ای از این تأثیرگذاری در بررسی و ارزیابی‌های درون کشور نیز مشاهده شده است، جایی که اقدام و مداخله‌های درونی مهندسی و طرح‌های توسعه فیزیکی می‌توانند الگوهای رسوب‌گذاری را در بوم سامانه‌های حساسی مانند تالاب‌ها به طور جدی دستخوش تغییر کنند (Heydarnzhad & Badiei, 2025). این رویکرد

واکنشی ناکارآمد و پرخطر است. این رویکرد به جای تمرکز بر شاخص‌های پیش‌بینانه (نیازهای آبی آبراهه)، بر شاخص‌های پس‌نگر (عملکرد گذشته) متمرکز است. این ناکارآمدی به طور مستقیم به هدررفت‌های احتمالی منابع (لایروبی بیش از حد یا زود هنگام) یا افزایش خطرگریزی (لایروبی کمتر از حد یا دیر هنگام) منجر می‌شود. این چرخه واکنشی، به جای پاسخ به این پرسش که "آیا برای روبه‌رو شدن با رویدادهای آبی آماده هستیم؟"، تنها به این پرسش پاسخ می‌دهد که "آیا مسئله و دشواری گذشته را حل کرده‌ایم؟". این ضعف، یک فرصت قابل توجه برای بهینه‌سازی و گذار از یک الگوی مدیریتی واکنشی به یک چارچوب راهبردی و پیش‌بینانه را نمایان می‌سازد. اهمیت این گذار از رویکرد واکنشی، در بررسی و ارزیابی‌های درون کشور که مرتبط با سیلاب‌های اخیر ایران هستند به وضوح

دید می‌شود. نتیجه پژوهش‌ها نشان داده‌اند که مسئله‌هایی چون لایروبی نشدن رودخانه‌ها، یکی از عامل‌های تشدیدکننده سیلاب‌های زیانبار احتمالی، مانند سیل ۱۳۹۸ در حوضه گرگان‌رود، بوده است (Rajabizadeh et al., 2019). در پاسخ، بررسی و ارزیابی‌ها در ایران با استفاده از مدل‌سازی هیدرولیکی به بررسی اثر پیش‌فرض‌های لایروبی در همین منطقه (Khajeh et al., 2022) و همچنین ارزیابی خطر سیلاب در دیگر دشت‌های سیلابی شهری ایران (به عنوان مثال، رودخانه ایرانشهر) پرداخته‌اند (Jamal & Valizadeh, 2019). همچنین، تحلیل‌های هیدرولیکی برای تعیین دقیق حد بستر قانونی در سیلاب‌دشت‌ها به عنوان ابزاری برای مدیریت پیشگیرانه و کاهش آسیب و زیان‌های پیش‌بینی نشده در رودخانه‌های ایران مورد استفاده قرار گرفته است (Ezzati et al., 2025). در چندی پیش نیز پژوهشی به طور خاص به ارزیابی تأثیر پیش‌فرض‌های مختلف لایروبی در شهر آق‌قلا با استفاده از شبیه‌سازی دوپسی پرداخته است (Rezaei-Ghaleh et al., 2025). این پژوهش و ارزیابی‌ها، هرچند در ارزیابی هیدرولیکی پیشرفته هستند، اما به طور معمول بر تحلیل‌های قطعی متمرکز بوده‌اند و خلأ تحلیل عدم قطعیت و پیش‌بینی هوشمند (که در این پژوهش و ارزیابی‌های مختلف به آن پرداخته می‌شود) همچنان به قوت خود باقی است.

از مدل‌های آماری سنتی و حتی برخی مدل‌های فیزیکی دارند (Shawon et al., 2024; Farfán-Durán & Cea, 2024; Truong et al., 2025). این حوزه به سرعت در حال تکامل است و پژوهشگران از مدل‌های مستقل و متداول تایید شده به سمت معماری‌های ترکیبی توانمندتر حرکت کرده‌اند. به عنوان مثال، مدل‌های ترکیبی CNN-LSTM برای استخراج همزمان ویژگی‌های مکانی (از داده‌های بارش) و زمانی (از سری جریان) طراحی شده‌اند (Li et al., 2022)، و مدل‌های دیگر با داده‌های ورودی گوناگون ترکیب می‌شوند تا دقت پیش‌بینی را افزایش دهند (Zheng et al., 2024). این پیشرفت‌ها، که در جدیدترین پژوهش‌ها نیز مشهود است، نشان می‌دهد که ابزار لازم برای تولید پیش‌بینی‌های قابل اعتماد و بلندمدت از متغیرهای کلیدی مؤثر بر نیاز به لایروبی، اکنون در دسترس و به توانمندی رسیده‌اند (Pathan et al., 2024).

با وجود توانمندی روش‌های مونت کارلو برای تحلیل عدم قطعیت و پایداری کارایی یادگیری عمیق برای پیش‌بینی، یک شکاف تحقیقاتی قابل توجه در کاربرد یکپارچه این دو فناوری برای حل مسئله ارزیابی لایروبی وجود دارد. این پژوهش با ارائه یک چارچوب نوآورانه که این دو حوزه را به هم پیوند می‌دهد، این شکاف را پر می‌کند. رویکرد تایید شده پیشنهادی، ارزیابی لایروبی را از یک تمرین منفعل و تاریخی به یک ابزار مدیریتی فعال، راهبردی و آینده‌نگر تبدیل می‌کند. چارچوب پیشنهادی این پژوهش به شرح زیر عمل می‌کند:

۱. یک مدل یادگیری عمیق مانند LSTM با استفاده از داده‌های تاریخی آموزش داده می‌شود تا شرایط هیدرولوژیکی آتی (مانند آب‌نگارهای مختلف جریان) را در یک افق برنامه‌ریزی مشخص پیش‌بینی کند.
۲. این پیش‌بینی‌ها به عنوان پیش‌فرض‌های ورودی و شرایط مرزی برای یک مدل هیدرولیکی معتبر (مانند HEC-RAS) که قابلیت‌های گسترده‌ای در مدل‌سازی رسوب و ارزیابی پیش‌فرض‌های لایروبی دارد، استفاده می‌شوند (Brunner, 2016; Van et al., 2024).
۳. آنگاه، شبیه‌سازی مونت کارلو بر روی مدل هیدرولیکی اجرا می‌شود تا عدم قطعیت‌های فراسنجه‌ای (مانند

قطعیت ساختاری، که از ساده‌سازی‌های ذاتی مدل ناشی می‌شود. ضریب زبری مانینگ یک مثال کلاسیک از فراسنجه‌ای بسیار حساس و نامشخص است که تغییرپذیری‌های احتمالی کوچک در آن می‌تواند به طور قابل توجهی نتایج مدل‌سازی، از جمله رخ نمای سطح آب و پهناهای سیلابی، را تحت تأثیر قرار دهد. برای مدیریت این عدم قطعیت‌ها، روش‌های احتمالی مانند شبیه‌سازی مونت کارلو و رویکردهای بیزی (Bayesian) به عنوان ابزار استاندارد ظهور کرده‌اند. این روش‌ها به مهندسان اجازه می‌دهند تا به جای یک خروجی قطعی، یک توزیع احتمال از نتایج ممکن را تولید کنند (Camacho et al., 2019; Bessar et al., 2020; Thomas, 2020). این تغییر و دگرگونی‌ها، یک گذار فلسفی در مهندسی را نشان می‌دهد: از جستجوی یک پاسخ بهینه به سمت درک توزیعی از آینده‌های ممکن. این خروجی احتمالی برای مدیریت خطرگریزی بسیار ارزشمندتر از یک مقدار قطعی است. در زمینه لایروبی، این رویکرد به مدیران امکان می‌دهد تا تصمیم‌گیری‌های خود را بر مبنای یک سطح خطرگریزی قابل قبول اتخاذ کنند (مثلاً زمانی لایروبی می‌کنیم که احتمال تجاوز از ظرفیت آبراهه در فصل آینده بیش از ۱۰ درصد)، که یک راهبرد بسیار پیچیده‌تر و شایان دفاع‌تر است.

در حالی که شبیه‌سازی مونت کارلو می‌تواند عدم قطعیت را برای یک پیش‌فرض معین ارزیابی کند، به خودی خود نیز نمی‌تواند پیش‌بینی پیش‌فرض‌های آتی را بکند. این مسئله و زمینه، مربوط به مدل‌سازی پیش‌بینانه مبتنی بر داده‌ها است. در دهه‌های اخیر، شاهد پیشرفت‌های چشمگیری در ترکیب داده‌ها بوده‌ایم که منجر به گسترش مدل‌های یادگیری عمیق شده است. این مدل‌ها، به ویژه شبکه‌های حافظه طولانی کوتاه‌مدت (LSTM) و انواع آن مانند واحدهای بازگشتی دردار (GRU)، توانایی تعجب‌آوری در پیش‌بینی دوره‌های زمانی پیچیده، غیرخطی و تصادفی مانند جریان رودخانه و تراز آب از خود نشان داده‌اند (Zhang et al., 2018; Daramola et al., 2025). پژوهش و ارزیابی‌های چندی نشان داده‌اند که مدل‌های LSTM و مدل‌های ترکیبی (هیبریدی) به طور پیوسته عملکردی بهتر

## ۲-۲- گردآوری داده‌های میدانی و ابزار مورد ارزیابی

داده‌های مورد نیاز برای این پژوهش شامل فراسنجه‌های هیدرولیکی و هندسی آبراهه بود که پیش و پس از عملیات لایروبی (مورخ ۱۸ تیر ۱۴۰۲) گردآوری شد (شکل ۲). برای ثبت پیوسته و با فرکانس بالا، سطح آب در دو نقطه بالادست و پایین‌دست بازه مورد مطالعه با استفاده از حسگرهای فراصوتی (Ultrasonic Sensors) با گام زمانی ۱۵ دقیقه اندازه‌گیری شد. این داده‌های دوره زمانی به عنوان ورودی اصلی برای تحلیل‌های پسی به کار رفت. به منظور صحت‌سنجی و محاسبه مستقیم فراسنجه‌ها، سرعت جریان آب در مقطع‌های عرضی با استفاده از دستگاه سرعت‌سنج (Current Meter/Molinete) اندازه‌گیری شد. افزون بر این، ابعاد هندسی دقیق آبراهه، شامل ۵۷ مقطع عرضی در طول بازه زمانی مختلف، از طریق عملیات نقشه‌برداری به دست آمد. این مجموعه داده‌های جامع، پایه‌ای برای واسنجی مدل هیدرولیکی اولیه و همچنین تحلیل‌های آماری پیشرفته فراهم آورد.

## ۲-۳- تجزیه و تحلیل هیدرولیکی اولیه و محاسبه قطعی ضریب مانینگ

پیش از انجام تجزیه و تحلیل‌های احتمالی و پیش‌بینانه، در آغاز لازم بود تا مقدار پایه و قطعی ضریب زبری مانینگ برای شرایط پیش و پس از لایروبی محاسبه شود. این مقادیر، نقطه مرجع برای ارزیابی بهبود عملکرد آبراهه و همچنین به عنوان مقادیرهای میانگین ( $\mu$ ) در شبیه‌سازی مونت کارلو به کار رفتند. برای این منظور، از معادله کلاسیک مانینگ استفاده شد:

$$V = \frac{1}{n} R^{0.67} S^{0.5} \quad (1)$$

که در آن،  $V$  سرعت میانگین جریان (m/s)،  $n$  ضریب زبری مانینگ،  $R$  شعاع هیدرولیکی (m) و  $S$  شیب طولی بستر آبراهه است. مقادیر مورد نیاز برای این محاسبه، شامل سرعت متوسط جریان، شعاع هیدرولیکی (نسبت سطح مقطع به محیط خیس شده)، و شیب آبراهه، به طور مستقیم از داده‌های گردآوری شده در بخش ۲-۲ (شامل

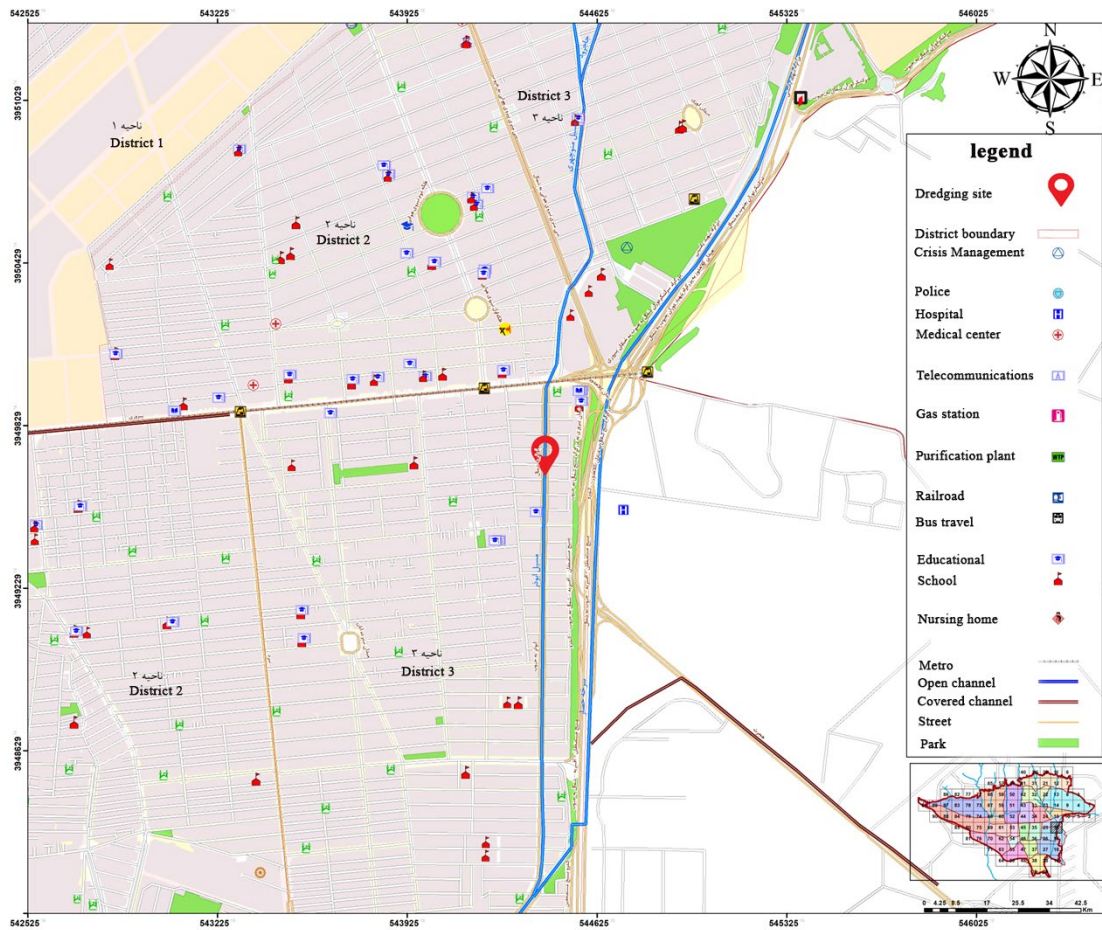
ضریب زبری مانینگ) برای هر یک از پیش‌فرض‌های پیش‌بینی شده در آینده، منتشر شود.

نتیجه نهایی این فرآیند، یک مقدار قطعی نیست، بلکه یک پیش‌بینی احتمالی از چگونگی عملکرد آبراهه در آینده است (مثلاً با احتمال ۳۰ درصد، عمق آبراهه در ماه ششم کمتر از حد آستانه خواهد بود). این رویکرد، گامی مبنایی به سوی تحقق یک هدف پیشرفته‌تر، یعنی ایجاد «دوقلوی دیجیتال»، که به عنوان یک نسخه مجازی و پویای زیرساخت فیزیکی تعریف می‌شود، به مدیران امکان می‌دهد تا از آن برای برنامه‌ریزی پیشگیرانه، تحلیل پیش‌فرض‌های «چه-اگر» (what-if) و بهینه‌سازی پیوسته عملیات نگهداری استفاده کنند (Bühler, 2021; Syed et al., 2024; Green et al., 2025). در نهایت، این پژوهش یک تغییر دیدمان را پیشنهاد می‌کند: گذار از نگهداری مبتنی بر برنامه ثابت یا واکنش به شکست، به سمت مدیریت نگهداری پیش‌بینانه و مبتنی بر خطرگریزی، که کارآمدتر، مقرون‌به‌صرفه‌تر و تاب‌آورتر است.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

منطقه مورد نظر در این پژوهش، آبراهه ابوذر تهران به عنوان بخشی کلیدی از شبکه گردآوری رواناب شهری انتخاب شد. این آبراهه که ادامه آبراهه منوچهری به شمار می‌آید، از تقاطع خیابان‌های پیروزی و ابوذر آغاز می‌شود. مسیر آبراهه پس از عبور از چندین خیابان و بزرگراه اصلی، در نهایت به میدان افسریه نزدیک می‌شود. موقعیت دقیق محدوده مورد ارزیابی که عملیات لایروبی در آن صورت گرفته، در شکل ۱ نشان داده شده است. حوضه آبریز تحت پوشش این آبراهه گستردگی برابر با ۴۱۳.۹۳ کیلومتر مربع دارد. عملیات لایروبی در این آبراهه در تاریخ ۱۸ تیر ۱۴۰۲ (July 9, 2023) انجام شد که فرصتی برای ارزیابی تأثیر آن بر فراسنجه‌های هیدرولیکی فراهم آورد.



**Fig. 1** Dredging site in Abuzar Canal, Tehran  
 شکل ۱ محل لایروبی در آبراهه ابوزر تهران



**Fig. 2** Flow measurement with a mouline  
 شکل ۲ اندازه‌گیری جریان با مولینه

گرفته شد. انحراف معیار ( $\sigma$ ) آن بر مبنای عدم قطعیت نسبی ۵ درصد ( $\sigma/\mu = 0.05$ ) فرض شد. منظور از عدم قطعیت نسبی در اینجا، نسبت انحراف معیار به میانگین ( $\sigma/\mu$ ) است. این مقدار، یک فرض استاندارد و پذیرفته شده در آب‌سنجی میدانی است که بر مبنای مرجع‌های فنی معتبر (WMO, 2010) انتخاب شده و منعکس‌کننده خطاهای ذاتی ابزار مولینه در شرایط واقعی و آشفته‌گی احتمالی جریان می‌باشد.

- عامل هندسی (K): این عامل که ترکیبی از شعاع هیدرولیکی ( $R^{2/3}$ ) و شیب آبراهه ( $S^{1/2}$ ) است، با عدم قطعیت نسبی ۲ درصد برای در نظر گرفتن خطاهای جزئی نقشه‌برداری مدل‌سازی شد. این مقدار به عنوان یک برآورد محافظه‌کارانه برای خطاهای تجمیعی ناشی از نقشه‌برداری میدانی و درونیابی هندسی بین مقطع‌های عرضی انتخاب شد. این انتخاب، ضمن تأیید دقت بالاتر نقشه‌برداری نسبت به اندازه‌گیری جریان (۲ درصد  $\gg$  ۵ درصد)، با برآوردهای همانند و همسان در متون تخصصی سازگار است. دلیل انتخاب مقدار کمتر (۲ درصد) نسبت به سرعت، دقت بالاتر تجهیزهای نقشه‌برداری در مقایسه با آب‌سنجی است. این مقدار طبق مطالعه Di Baldassarre و Montanari (2009) به عنوان خطای تجمیعی ناشی از درونیابی بین مقطع‌های عرضی در نظر گرفته شده است.

فرآیند شبیه‌سازی شامل ۵۰۰۰۰ تکرار بود. در هر تکرار، یک مقدار تصادفی برای  $V$  و  $K$  از توزیع‌های تعریف‌شده نمونه‌برداری شده و ضریب مانینگ ( $n = K/V$ ) برای هر دو حالت پیش و پس از لایروبی محاسبه شد. از این طریق، دو توزیع احتمالی برای ضریب‌های مانینگ و در نهایت یک توزیع برای درصد کاهش آن به دست آمد. خروجی نهایی این تحلیل، میانگین و بازه اطمینان ۹۵ درصد برای درصد کاهش ضریب زبری است که دیدگاهی جامع و واقع‌بینانه از نتیجه پروژه ارائه می‌دهد.

این رویکرد در شکل ۳ به تصویر کشیده شده است. این نمودار مفهومی که خروجی کد پایتون گسترش داده شده در همین پژوهش است، روند کلی شبیه‌سازی را به صورت دیدگاهی نمایش می‌دهد.

نتایج دستگاه سرعت‌سنج و عملیات نقشه‌برداری استخراج شد. با جایگذاری این مقادیر، ضریب زبری مانینگ برای شرایط پیش و پس از لایروبی به کمک نرم افزار مایک محاسبه شد که منجر به کاهش قطعی معادل ۴/۴۷ درصد شد. این مقدار، همان نتیجه‌ای است که در تحلیل‌های سنتی گزارش شده و پایه تحلیل‌های عدم قطعیت پسی را تشکیل می‌دهد.

## ۲-۴- چارچوب تحلیل عدم قطعیت (شبیه‌سازی مونت کارلو)

ارزیابی‌های سنتی اغلب به یک مقدار قطعی برای کاهش ضریب زبری مانینگ اکتفا می‌کنند. این رویکرد، عدم قطعیت‌های ناشی از خطاهای ابزاری و شرایط متغیر میدانی را نادیده می‌گیرد و می‌تواند به تفسیری بیش از حد خوش‌بینانه از نتایج منجر شود. برای چیره شدن احتمالی بر این محدودیت، در این پژوهش از یک چارچوب تحلیل عدم قطعیت مبتنی بر شبیه‌سازی مونت کارلو استفاده شد. هدف از این تحلیل، حرکت از یک پاسخ قطعی به سمت درک توزیع احتمالی اثربخشی واقعی عملیات لایروبی بود. در این روش، فراسنجه‌های ورودی اصلی در معادله مانینگ به جای مقادیر ثابت، به عنوان متغیرهای تصادفی با توزیع نرمال ( $N(\mu, \sigma)$ ) در نظر گرفته شدند. انتخاب توزیع نرمال برای مدل‌سازی فراسنجه‌های ورودی بر پایه دو استدلال قوی آماری استوار است: اول، برابر موضوع حد مرکزی (CLT)، از آنجا که خطای اندازه‌گیری در ابزارهای مانند مولینه برآیند ده‌ها منبع خطای کوچک و مستقل (مانند توربولانس لحظه‌ای و خطاهای انسانی) است، مجموع آن‌ها به طور طبیعی به سمت توزیع نرمال میل می‌کند. دوم، بر مبنای اصل بیشینه آنتروپی (Maximum Entropy)، در شرایطی که تنها میانگین و انحراف معیار در دسترس است، توزیع نرمال محافظه‌کارانه‌ترین فرض ممکن است که هیچ بار اطلاعاتی اضافی و تأیید نشده‌ای را به مدل تحمیل نمی‌کند.

- سرعت جریان ( $V$ ): این فراسنجه به عنوان یک متغیر تصادفی با توزیع نرمال مدل‌سازی شد. میانگین ( $\mu$ ) آن برابر با مقدار اندازه‌گیری‌شده میدانی با مولینه در نظر

Conceptual Diagram of the Monte Carlo Simulation Method

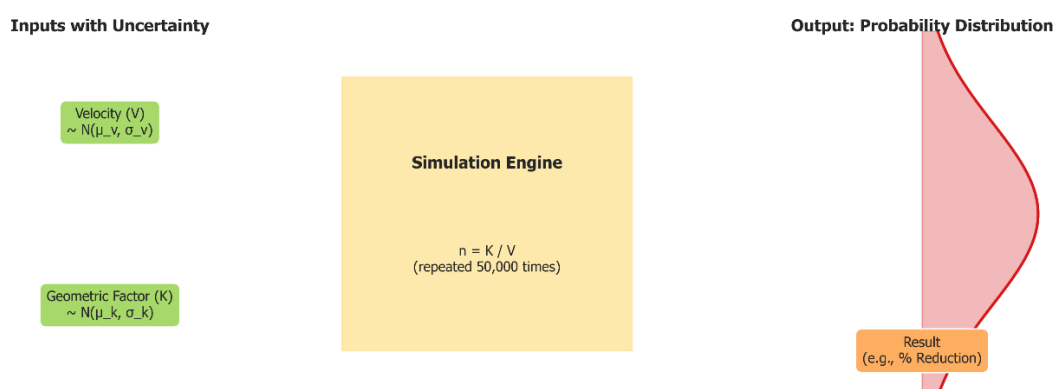


Fig. 3 Conceptual diagram of the Monte Carlo simulation framework

شکل ۳ نمودار مفهومی چارچوب شبیه‌سازی مونت کارلو

می‌رود. آن‌گاه، داده‌ها به دنباله‌هایی با طول ثابت تبدیل شدند؛ به‌گونه‌ای که از ۸ گام زمانی پیشین (معادل ۲ ساعت) برای پیش‌بینی مقدار در گام زمانی پسی استفاده شد.

۲-۵-۲- معماری و آموزش مدل

مدل LSTM با استفاده از کتابخانه Keras ساخته شد و شامل یک لایه LSTM با ۵۰ واحد پردازشی و یک لایه خروجی Dense برای پیش‌بینی مقدار نهایی بود. مدل با بهینه‌ساز adam و تابع هزینه mean\_squared\_error کامپایل و برای ۵۰ دوره (epoch) بر روی داده‌های آموزشی، آموزش داده شد. جزئیات کامل هاپیرپارامترهای مورد استفاده برای آموزش، شامل نرخ یادگیری، اندازه دسته (batch size) و چگونگی تقسیم داده‌های آموزشی/آزمون، در (پیوست ۱) به تفصیل آمده است.

۲-۵-۳- ارزیابی عملکرد

عملکرد نهایی مدل بر روی داده‌های آزمون (داده‌هایی که مدل در حین آموزش ندیده بود) ارزیابی شد. معیار اصلی برای سنجش دقت، ریشه میانگین مربعات خطا (Root Mean Squared Error - RMSE) بود که پس از برگرداندن مقدارهای پیش‌بینی‌شده به مقیاس واقعی (متر) محاسبه شد.

۲-۵- چارچوب پیش‌بینی دوره زمانی (شبکه

(LSTM - Long Short-Term Memory

افزون بر ارزیابی اثرگذاری‌های گذشته‌نگر لایروبی، این پژوهش توانمندی روش‌های پیشرفته برای پیش‌بینی‌های آینده‌نگر در مدیریت آبراهه‌ها را نیز بررسی می‌کند. به این منظور، یک چارچوب مبتنی بر شبکه‌های عصبی حافظه طولانی کوتاه‌مدت (LSTM) به عنوان یک اثبات مفهوم (Proof of Concept) توسعه داده شد. هدف، نمایش قابلیت این مدل‌ها در پیش‌بینی کوتاه‌مدت فراسنجه‌های هیدرولیکی، مانند سطح آب، بر مبنای داده‌های با بسامد بالای حسگرها بود.

۲-۵-۱- تولید داده و پیش‌پردازش

داده‌های مورد نیاز برای این بخش، از طریق یک دستگاه فراصوتی ساخته شده در دانشگاه شهید بهشتی (شامل حسگر، ثبات داده و منبع تغذیه مستقل) به همراه مولینه، که برای ثبت میدانی و پیوسته تغییرپذیری‌های احتمالی سطح آب در یک آبراهه طی چندین ماه مونتاز شده بود، گردآوری شد. داده‌های گردآوری‌شده شامل نوسانات ۲۴ ساعته سطح آب با گام زمانی ۱۵ دقیقه بوده و نویزهای تصادفی ناشی از شرایط محیطی را نیز در بر داشت. این داده‌ها در آغاز با استفاده از MinMaxScaler به بازه [۰, ۱] نرمال‌سازی شدند که این فرایند یکی از پیش‌نیازهای استاندارد برای آموزش پایدار شبکه‌های عصبی به شمار

## ۳- نتایج

## ۳-۱- خروجی تجزیه و تحلیل عدم قطعیت:

## رونمایی از طیف کامل پیامدهای پروژه

تجزیه و تحلیل احتمالی مبتنی بر شبیه‌سازی مونت کارلو، تصویری چندپسی از تأثیر لایروبی ارائه داد. نتایج ۵۰,۰۰۰ تکرار شبیه‌سازی، میانگین کاهش در ضریب زبری مانینگ را ۴/۴۷ درصد و میانه آن را ۴/۷۱ درصد نشان داد. این مقدارها، به عنوان نماینده مرکزی توزیع، یک بهبود کلی در کارایی هیدرولیکی آبراهه را تأیید می‌کنند. با این حال، شاخص تعیین‌کننده در این تحلیل، بازه اطمینان ۹۵٪ بود

که گستره‌ای از ۹.۶۶ - تا ۱۷.۱۲ درصد را در بر می‌گرفت. این بازه گسترده، عدم قطعیت شایان توجهی را که در اندازه‌گیری‌های میدانی نهفته است، به صورت کمی آشکار می‌سازد. طیف کامل این نتایج محتمل در شکل ۴، که توزیع احتمالی درصد کاهش ضریب مانینگ به دست آمده از شبیه‌سازی مونت کارلو را نمایش می‌دهد، به تصویر کشیده شده است. این هیستوگرام به وضوح نشان می‌دهد که با وجود تمرکز نتایج حول میانگین مثبت، دامنه‌های توزیع تا مقدارهای منفی نیز گسترش یافته‌اند که بیانگر وجود خطرگریزی و پیش‌فرض‌های نامطلوب در کنار نتایج مثبت است.

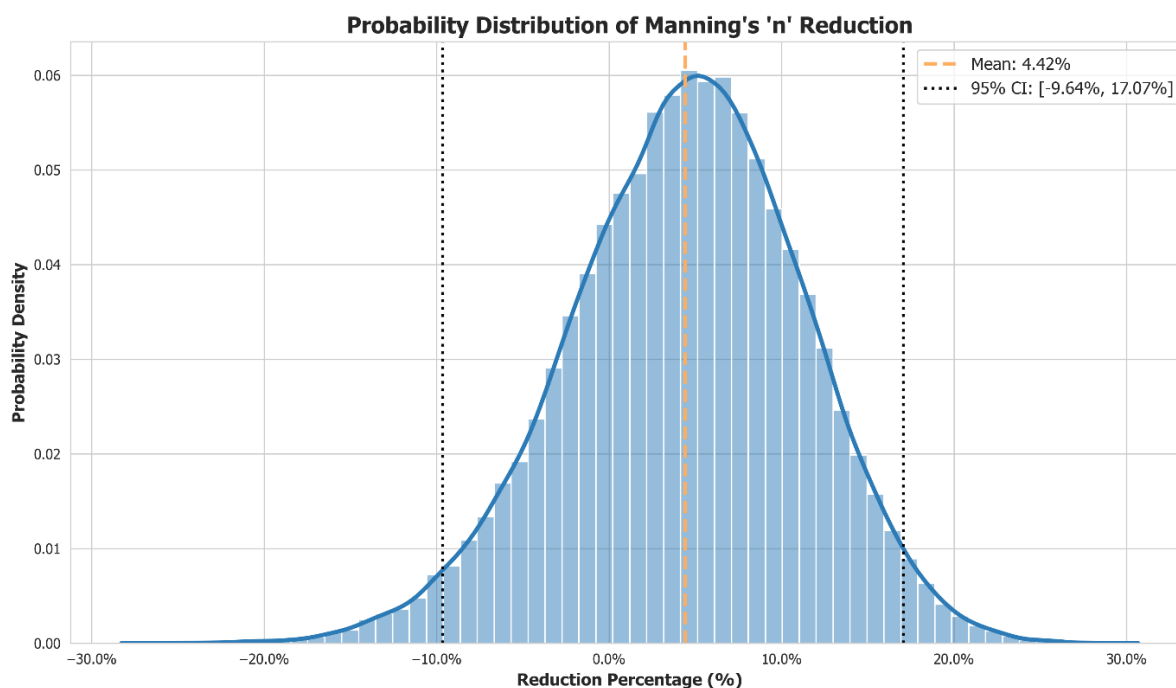


Fig. 4 Probability distribution of percentage reduction in Manning coefficient resulting from Monte Carlo simulation

شکل ۴ توزیع احتمالی درصد کاهش ضریب مانینگ به دست آمده از شبیه‌سازی مونت کارلو

ناشی از عدم قطعیت را به نمایش می‌گذارد؛ ناحیه‌ای که در آن، تمایز آماری بین شرایط پیش و پس از لایروبی معنادار نیست.

برای درک نتایج در سطح هر تک‌تکرار، شکل ۶ ارائه شده است. این نمودار، نتایج ۵۰,۰۰۰ تکرار شبیه‌سازی را در یک نمودار پراکندگی مقایسه می‌کند. یادآوری این نکته ضروری است که این نمودار نباید به عنوان یک نمودار همبستگی

این دوگانگی روند مثبت در مقابل عدم قطعیت بالا، در شکل ۵ با جزئیات بیشتری نمایش داده شده است. این شکل، مقایسه توزیع چگالی احتمال ضریب مانینگ پیش (زرد) و پس (بنفش) از عملیات لایروبی را نشان می‌دهد. جابجایی آشکار اوج توزیع پس از لایروبی به سمت مقدارهای احتمالی کمتر، سیگنال بهبود کارایی را تأیید می‌کند، اما در عین حال، ناحیه همپوشانی شایان توجه دو نمودار، نویز

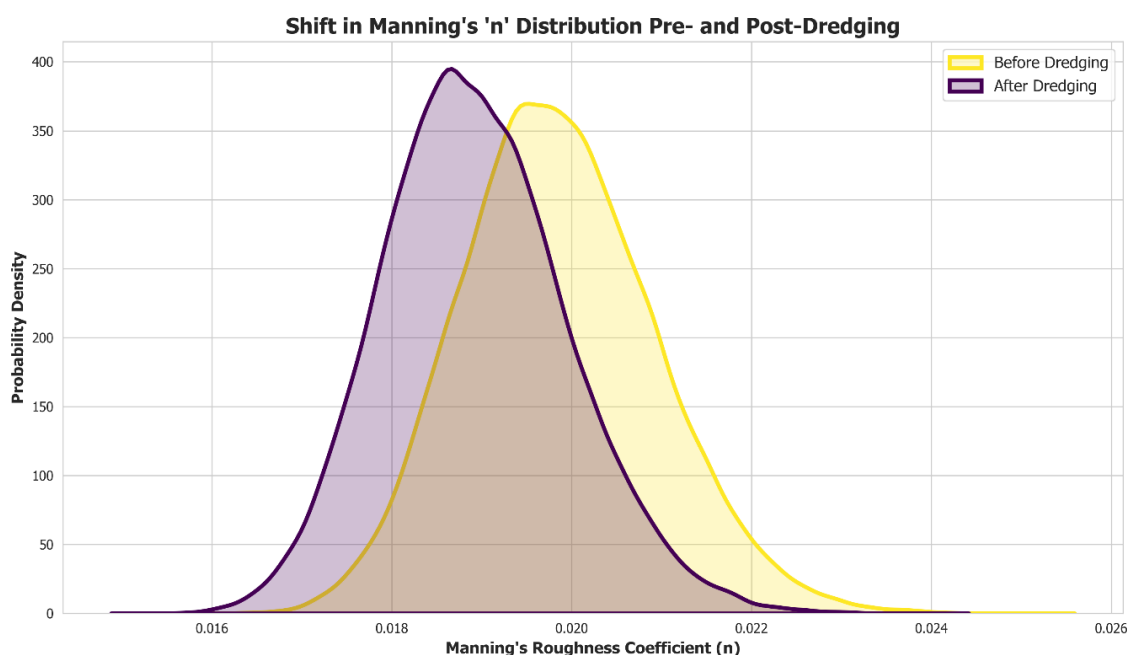


Fig. 5 Comparison of the probability density distribution of Manning's coefficient before (yellow) and after (purple) dredging operations

شکل ۵ مقایسه توزیع چگالی احتمال ضریب مانینگ پیش (زرد) و پس (بنفش) از عملیات لایروبی

گذاشت. ارزیابی نهایی مدل بر روی داده‌های آزمون، منجر به محاسبه ریشه میانگین مربعات خطای (RMSE) برابر با ۳/۲ سانتی‌متر شد. این مقدار خطا، که معادل تنها ۳/۲ سانتی‌متر است، دقت بالای مدل را برای کاربردهای عملی تأیید می‌کند. فرآیند یادگیری موفق مدل در شکل ۷، که منحنی‌های یادگیری مدل LSTM و روند کاهش خطا را در طول دوره‌های آموزش نشان می‌دهد، مستند شده است. همگرایی پایدار و نزدیک به هم منحنی‌های آموزش و اعتبارسنجی، اثبات می‌کند که مدل الگوهای واقعی داده‌ها را به خوبی فرا گرفته و دچار بیش‌برازش (Overfitting) نشده است.

در نهایت، اوج عملکرد مدل در شکل ۸ به نمایش گذاشته شده است. این شکل، مقایسه دوره زمانی مقدارهای واقعی سطح آب با مقدارهای پیش‌بینی شده توسط مدل LSTM در شرایط سیلابی را نشان می‌دهد. همخوانی شایان توجهی نزدیک خط پیش‌بینی قرمز با داده‌های واقعی خاکستری، نشان می‌دهد که مدل نه تنها قادر به دنبال کردن روند کلی است، بلکه پیچیدگی‌ها، نوسان‌ها و نقطه‌های اوج و فرود موضعی را نیز با وفاداری بالایی بازتولید می‌کند.

(correlation) تفسیر شود. از آنجایی که مقدارهای پیش و پس در هر تکرار به صورت مستقل از توزیع‌های آماری خود نمونه‌برداری شده‌اند، انتظار وجود همبستگی خطی بین دو محور وجود ندارد. هدف این نمودار، یک مقایسه فراوانی نسبت به خط مرجع  $y=x$  (خط بدون تغییر) است. این نمودار به صورت دیداری ثلثت می‌کند که بیشینه قاطع نقطه‌ها، به رغم پراکندگی زیاد، در زیر این خط مرجع قرار گرفته‌اند. نبود همبستگی خطی در شکل ۶ ناشی از ماهیت مستقل نمونه‌برداری تصادفی (Independent Sampling) در هر تکرار مونت کارلو است. هدف این نمودار نمایش همبستگی نیست، بلکه مقایسه فراوانی است؛ به طوری که قرارگیری بیشینه قاطع نقطه‌ها در زیر خط  $y=x$  نشان‌دهنده چیره شدن آماری پیش‌فرض‌های بهبود یافته است. این تراکم بالا گواهی بر این است که کاهش ضریب زبری، یک روند غالب و پایدار در کل فضای شبیه‌سازی بوده است.

### ۳-۲- خروجی مدل LSTM

مدل شبکه عصبی LSTM پس از آموزش، عملکرد توانمندی در پیش‌بینی دوره‌های زمانی از خود به نمایش




Fig. 6 shows the results of 50,000 simulation iterations comparing Manning before and after dredging in a scatter plot.

شکل ۶ نتایج ۵۰,۰۰۰ تکرار شبیه‌سازی را برای مقایسه مانینگ پیش و پس از لایروبی در یک نمودار پراکندگی




Fig. 7 Training and validation error diagram of the LSTM model

شکل ۷ نمودار خطای آموزش و اعتبارسنجی مدل LSTM




Fig. 8 Comparison of water level prediction by LSTM model with actual data in flood conditions

شکل ۸ مقایسه پیش‌بینی سطح آب توسط مدل LSTM با داده‌های واقعی در شرایط سیلابی

ناشی از لایروبی را تحت‌الشعاع قرار می‌دهد. این بازه گسترده، قدرت روش پیشنهادی در کمی‌سازی واقع‌بینانه محدودیت‌های داده‌های میدانی را نشان می‌دهد و تأکید می‌کند که اتکا به گزارش‌های تک‌عددی در مدیریت زیرساخت‌های شهری می‌تواند گمراه‌کننده باشد.

شکل ۴ و شکل ۵ این واقعیت را به صورت کمی و کیفی به تصویر می‌کشند. همپوشانی عظیم بین توزیع ضریب مانینگ پیش و پس از لایروبی (که در شکل ۵ مشهود است)، نشان می‌دهد که اگرچه به طور میانگین بهبودی حاصل شده، اما در هر نقطه خاصی از آبراهه، ممکن است این بهبود ناچیز یا حتی در محدوده خطای اندازه‌گیری بوده باشد.

این یافته، رویکرد مهندسان و مدیران شهری را به چالش می‌کشد. دیگر نمی‌توان به یک عدد برای داوری در مورد موفقیت یک پروژه چند میلیارد تومانی اکتفا کرد. این پژوهش نشان می‌دهد که ارائه نتایج به صورت یک توزیع احتمالی نه تنها از نظر علمی صادقانه‌تر است، بلکه ابزار مدیریتی بهتری برای ارزیابی خطرگریزی و تخصیص منابع فراهم می‌کند. شکل ۶ نیز این تحلیل را تأیید می‌کند؛ با اینکه روند کلی مثبت است، اما پراکندگی گسترش نقطه‌ها، گواهی بر همین عدم قطعیت است.

#### ۴- بحث و تحلیل نتایج

این پژوهش با دو رویکرد نوآورانه، پا را از ارزیابی‌های متداول فراتر گذاشته و درکی چندپسی از تأثیرگذاری‌های لایروبی و توانمندی مدیریت هوشمند آبراهه‌های شهری ارائه می‌دهد. در ادامه، مفهوم‌ها و پیامدهای کلیدی یافته‌های این تحقیق به تفصیل مورد بحث قرار می‌گیرد.

#### ۴-۱- توهم قطعیت: نگاهی واقع‌بینانه به

#### اثر بخشی پروژه‌های هیدرولیکی

مهم‌ترین یافته این پژوهش، نتیجه عددی کاهش ۴/۴۷ درصدی ضریب مانینگ نیست، بلکه بازه اطمینان بسیار گسترده (۹/۶۶٪- تا ۱۷/۱۲٪+) پیرامون آن است. وجود عدد صفر در بازه اطمینان ۹۵ درصدی، به معنای بی‌اثر بودن عملیات لایروبی نیست؛ بلکه نشان‌دهنده پدیده‌ای است که این پژوهش از آن به عنوان "توهم قطعیت" یاد می‌کند. در حالی که تحلیل‌های سنتی و قطعی تنها به گزارش میانگین کاهش ۴/۴۷ درصدی اکتفا کرده و پروژه را با قطعیت موفق اعلام می‌کنند، این تجزیه و تحلیل احتمالی آشکار می‌سازد که نویز و عدم قطعیت ذاتی در اندازه‌گیری‌های میدانی به قدری بالاست که سیگنال مثبت

مشخصات هیدرولیکی و رسوب‌شناسی متفاوت اجرا شود تا قابلیت تعمیم‌پذیری آن افزایش یابد.

۲. یک پایگاه داده بلندمدت از داده‌های واقعی حسگرها گردآوری شده و از آن برای گسترش و اعتبارسنجی یک مدل LSTM عملیاتی استفاده شود.

۳. فراسنجه‌های مختلف اقتصادی (هزینه لایروبی در مقابل هزینه آسیب و زیان‌های احتمالی سیلاب) با این چارچوب یکپارچه شوند تا یک ابزار بهینه‌سازی و پشتیبانی از تصمیم (Decision Support System) کامل ایجاد شود.

## ۵ - نتیجه‌گیری

این پژوهش با هدف فراتر رفتن از ارزیابی‌های سنتی و قطعی در پروژه‌های لایروبی آبراهه‌های شهری انجام شد و یک چارچوب تحلیلی دوگانه و مدرن را معرفی کرد. نتایج نشان داد که اگرچه لایروبی به طور میانگین به بهبود ۴/۵ درصدی کارایی هیدرولیکی منجر شد، اما تحلیل عدم قطعیت، یک بازه اطمینان بسیار گسترده را آشکار ساخت که اهمیت نگاه احتمالی به نتایج و در نظر گرفتن خطاهای اندازه‌گیری را برجسته می‌کند. افزون بر این، این بررسی و ارزیابی‌ها با موفقیت نشان داد که مدل‌های یادگیری عمیق (LSTM) از توان بالایی برای پیش‌بینی دقیق و کوتاه‌مدت فراسنجه‌های هیدرولیکی برخوردارند و می‌توانند به عنوان ابزاری برای مدیریت هوشمند و پیش‌بینانه به کار گرفته شوند.

نتیجه‌گیری اصلی این پژوهش آن است که چارچوب دوگانه ارائه‌شده، که تحلیل عدم قطعیت احتمالی را با قابلیت‌های پیش‌بینی هوش مصنوعی تلفیق می‌کند، یک رویکرد جامع و سودمند و توانمند برای ارزیابی و مدیریت زیرساخت‌های آبی است. این چارچوب، مدیران و مهندسان را قادر می‌سازد تا با دیدی واقع‌بینانه‌تر نسبت به نتایج پروژه‌های گذشته (پس‌نگری) و با ابزاری هوشمند برای مدیریت رویدادهای آینده (پیش‌بینی)، به سوی مدیریت پایدار و داده‌محور منابع آب شهری حرکت کنند. این پژوهش، گامی تأیید شده به سوی نسل جدیدی از ارزیابی‌های مهندسی در عصر دیجیتال است.

## ۴-۲- از نگهداری واکنشی تا مدیریت پیش‌بینانه

بخش دوم این پژوهش، یک جهش دیدمانی از گذشته‌نگری به آینده‌نگری را به نمایش می‌گذارد. موفقیت مدل LSTM، که به عنوان یک اثبات مفهوم توسعه داده شد، در پیش‌بینی نوسان‌های سطح آب با دقت RMSE حدود ۳/۲ سانتی‌متر (که در شکل ۸ به تصویر کشیده شده)، توان بالقوه بالای یادگیری عمیق را برای مدیریت سامانه‌های هیدرولیکی شهری آشکار می‌سازد. اگرچه ارزیابی کامل یک مدل عملیاتی نیازمند شواهد و معیارهای گسترده‌تری است (که در بخش محدودیت‌ها نیز به آن اشاره شده است)، این نتیجه به وضوح نشان می‌دهد که گذار به مدیریت پیش‌بینانه، یک هدف عملی و قابل دستیابی است. در حال حاضر، مدیریت آبراهه‌ها بیشتر واکنشی است؛ یعنی پس از رخداد دشواری (مانند گرفتگی یا سیلاب) اقدام صورت می‌گیرد. اما مدل LSTM راه را برای یک مدیریت پیش‌بینانه (Predictive) و پیش‌گیرانه (Proactive) هموار می‌کند. می‌توان آینده‌ای را تصور کرد که در آن، داده‌های آبی از شبکه‌ای از حسگرها به مدل‌های هوش مصنوعی تغذیه شده و این مدل‌ها می‌توانند رخداد سیلاب را ساعت‌ها پیش‌بینی کنند، به صورت خودکار دریچه‌ها را تنظیم کنند، یا حتی نیاز به لایروبی را پیش از بحرانی شدن شرایط، هشدار دهند. شکل ۷ نشان می‌دهد که این مدل‌ها به سرعت و با دقت یاد می‌گیرند و آماده تبدیل شدن به یک ابزار عملیاتی هستند. این رویکرد، هسته اصلی مفهوم‌هایی چون شهر هوشمند و دوقلوی دیجیتال (Digital Twin) برای زیرساخت‌های آبی است.

## ۴-۳- محدودیت‌ها و مسیرهای تحقیقاتی آینده

با وجود نوآوری‌ها، این بررسی و ارزیابی‌ها دارای محدودیت‌هایی است که مسیر را برای پژوهش‌های آتی مشخص می‌کند. نخست اینکه تجزیه و تحلیل عدم قطعیت بر روی یک مطالعه موردی واحد متمرکز بود و تعمیم نتایج به دیگر آبراهه‌ها نیازمند تحقیقات بیشتر است.

بنابراین، پیشنهاد و تأکید می‌شود در آینده:

۱. این چارچوب دوگانه بر روی آبراهه‌های چند دیگری با

McGraw-Hill.

Daramola, S., Muñoz, D.F., Muñoz, P., Saksena, S. & Irish, J. (2025). Predicting the evolution of extreme water levels with long short-term memory station-based approximated models and transfer learning techniques. *Water Resources Research*, 61(3), e2024WR039054. <https://doi.org/10.1029/2024WR039054>.

Di Baldassarre, G. & Montanari, A. (2009). Uncertainty in river discharge observations: a quantitative analysis. *Hydrology and Earth System Sciences*, 13(6), 913-921.

Ebrahimi, N., Gharibreza, M., Hosseini, M. & Ashraf, M.A. (2017). Experimental study on the impact of vegetation coverage on flow roughness coefficient and trapping of sediment. *Geology, Ecology, and Landscapes*, 1(3), 167-172.

Ezzati, S., Eydi, Z. & Mohajeri, S.H. (2025). Determination of the legal bed boundary of natural canals branching from rivers in floodplains using a hydraulic analysis approach (Case study: Shahrestan Canal). *Journal of Hydraulics*, 20(4), 123-136. (In Persian)

Farfán-Durán, J.F. & Cea, L. (2024). Streamflow forecasting with deep learning models: A side-by-side comparison in Northwest Spain. *Earth Science Informatics*, 17(6), 5289-5315.

Green, A.C., Lewis, E., Tong, X. & Wardle, R. (2025). A framework for incorporating rainfall data into a flooding digital twin. *Journal of Hydrology*, 656, 132893. <https://doi.org/10.1016/j.jhydrol.2025.132893>.

HEC-RAS. (2016). River analysis system, hydraulic reference manual, USACE version 5.0. US Army Corps of Engineers, CPD-68.

Heydarnzhad, H. & Badiei, P. (2025). Evaluation of the effects of Anzali Port Development on Sedimentation at Anzali Wetland by Numerical Simulations. *Journal of Hydraulics*, 20(4), 57-70. (In Persian)

Jamal, P. & Valizadeh, D. (2019). Flood hazard zoning in the Iranshahr River using two-dimensional numerical modeling and GIS. *Journal of Water and Soil Sciences*, 23(4), 71-83. (In Persian)

Khajeh, S., Ataie-Ashtiani, B. & Hosseini, S.M. (2022). Effect of DEM resolution in flood modeling, a case study of Gorganrood River Northeastern Iran. *Natural Hazards*, 112(3), 2673-2693.

Li, X., Xu, W., Ren, M., Jiang, Y. & Fu, G. (2022). Hybrid CNN-LSTM models for river flow

## تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

## منابع مالی

نویسنده (نویسندگان) هیچ گونه حمایت مالی برای تحقیق، تالیف و انتشار این مقاله دریافت نکردند.

## دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است. مجموعه داده‌های تولید شده و یا تحلیل شده در طول مطالعه حاضر، در صورت درخواست معقول، از نویسنده مسئول در دسترس هستند.

## مشارکت نویسندگان

**نویسنده اول:** ایده‌پردازی، روش‌شناسی، نگارش پیش‌نویس اصلی مقاله و پیاده‌سازی مدل‌ها.  
**نویسنده دوم:** تجزیه و تحلیل داده‌ها، نظارت علمی بر روند تحقیق و بازنگری نهایی نتایج.

## ۶- منبع‌ها

Bessar, M.A., Matte, P. & Anctil, F. (2020). Uncertainty analysis of a 1d river hydraulic model with adaptive calibration. *Water*, 12(2), 561. <https://doi.org/10.3390/w12020561>.

Brunner, G.W. (2016). HEC-RAS river analysis system 2D modeling user's manual. US Army Corps of Engineers—Hydrologic Engineering Center, 1-171.

Bühler, M.M., Sebal, C., Rechid, D., Baier, E., Michalski, A., Rothstein, B., ... & Buziek, G. (2021). Application of copernicus data for climate-relevant urban planning using the example of water, heat, and vegetation. *Remote sensing*, 13(18), 3634. <https://doi.org/10.3390/rs13183634>.

Camacho, R.A., Zhang, Z. & Chao, X. (2019). Receiving water quality models for TMDL development and implementation. *Journal of Hydrologic Engineering*, 24(2), 04018063. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001723](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001723).

Chow, V.T. (1959). Open-channel hydraulics.

- Thomas, V.S. (2020). Understanding the role of green infrastructure in climate change resiliency of transportation infrastructure, Doctoral dissertation, Kansas State University.
- Truong, V.A., Hoang, T.N.M. & Truong, D.V. (2025). Deep learning for downstream water level prediction in complex hydrology systems: An LSTM approach. *Open Journal of Modern Hydrology*, 15(2), 218-232.
- Van der Meer, J.W., Hardeman, B., Steendam, G.J., Schüttrumpf, H. & Verheij, H. (2010). Flow depths and velocities at crest and landward slope of a dike, in theory and with the wave overtopping simulator. In: J., Mc Kee Smith, & P., Lynett (Eds.), Proceedings of 32nd Conference on Coastal Engineering, ICCE 2010 (pp. 1-15). s.n..
- Van, T., Bui, D.X., Do, T.A.T. & Do, A.N.T. (2024). Assessing flood susceptibility in Hanoi using machine learning and remote sensing: implications for urban health and resilience. *Natural Hazards*, 121(9), 10149-10170.
- World Meteorological Organization (2010). Manual on Stream Gauging (WMO-No. 1044). Geneva, Switzerland: WMO.
- Wu, W. & Wan, L. (2022). Coastal ecological and environmental management under multiple anthropogenic pressures: A review of theory and evaluation methods. *Current Trends in Estuarine and Coastal Dynamics*, 385-415. <https://doi.org/10.1016/B978-0-443-21728-9.00013-2>.
- Zhang, D., Holland, E.S., Lindholm, G. & Ratnaweera, H. (2018). Enhancing operation of a sewage pumping station for inter catchment wastewater transfer by using deep learning and hydraulic model. arXiv preprint arXiv:1811.06367. <https://doi.org/10.13140/RG.2.2.27769.72808>.
- Zheng, F., Zhang, Y., Li, X. & Wang, Z. (2024). A hybrid deep learning approach for streamflow prediction incorporating watershed memory and residual error correction. *Hydrology Research*, 55(4), 498-512.
- prediction. *Water Supply*, 22(5), 4902-4919.
- Mihu-Pintilie, A., Cîmpianu, C.I., Stoleriu, C.C., Pérez, M.N. & Paveluc, L.E. (2019). Using high-density LiDAR data and 2D streamflow hydraulic modeling to improve urban flood hazard maps: A HEC-RAS multi-scenario approach. *Water*, 11(9), 1832. <https://doi.org/10.3390/w11091832>.
- Pathan, A.I., Sidek, L.B.M., Basri, H.B., Hassan, M.Y., Khebir, M.I.A.B., Omar, S.M.B.A., ... & Ahmed, A.N. (2024). Comparative assessment of rainfall-based water level prediction using machine learning (ML) techniques. *Ain Shams Engineering Journal*, 15(7), 102854. <https://doi.org/10.1016/j.asej.2024.102854>.
- Rajabizadeh, Y., Ayyoubzadeh, S.A. & Zahiri, A. (2019). Flood Survey of Golestan Province in 2018-2019 and providing solutions for its control and management in the future. *Journal of Ecohydrology*, 6(4), 921-942.
- Rezaei-Ghaleh, L., Rezaei, H. & Ghorbani, K. (2025). Effect of dredging on flood extent and depth in low-slope areas using two-dimensional simulation (Case study: Aq Qala County). *Journal of Civil and Environmental Engineering*, 55(118), 1-10. (In Persian)
- Shawon, S.M., Haider, S.N., Chakma, A., Alam, M.W., Islam, M.T. & Rana, M.F. (2024). DeepFlowNet: Deep Learning Based Daily Water Flow Forecasting of Test River. In: 2024 IEEE International Conference on Power, Electrical, Electronics and Industrial Applications (PEEIACON), 839-844, IEEE. <https://doi.org/10.1109/PEEIACON63629.2024.10800657>.
- Syed, T.A., Muhammad, M.A., AlShahrani, A.A., Hammad, M. & Naqash, M.T. (2024). Smart water management with digital twins and multimodal transformers: A predictive approach to usage and leakage detection. *Water*, 16(23), 3410. <https://doi.org/10.3390/w16233410>.
- Teymouri, R., Dehghani, A.A. & Meftah Helghi, M. (2025). Investigating the effect of parallel processing and different mesh sizes on the speed and accuracy of flood modeling using STE software. *Scientific Journal of Hydraulics*, 20(4), 1-21. (In Persian)

© 2026 The Author(s). Published by Iranian Hydraulic Association, Tehran, Iran.  
 This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.



## پیوست ۱: هایپرپارامترهای مدل LSTM

جدول زیر جزئیات کامل معماری و پارامترهای آموزشی مورد استفاده برای مدل LSTM (بخش ۲-۵) را به منظور تکرارپذیری پژوهش ارائه می‌دهد.

جدول پ ۱ هایپرپارامترهای مدل LSTM

**Table A1.** Hyperparameters of the LSTM Model

Hyperparameter	Value
Model Architecture	
Library	Keras (TensorFlow Backend)
First Layer	LSTM
LSTM Units	50
Second Layer	Dense (Output)
Dense Units	1
Input Sequence Length (Look-back)	8 Time Steps
Preprocessing	MinMaxScaler (Range [0, 1])
Training Parameters	
Optimizer	Adam
Learning Rate	0.001
Loss Function	mean_squared_error
Epochs	50
Batch Size	32
Data Splitting	
Train/Test Split	80% / 20%
Validation Split	20% (from Training Data)