

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

Mohammadreza Masoudi Moghaddam*

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

* m_masoudimoghaddam@sbu.ac.ir

Abstract

Introduction: Flood-control canals are key infrastructures for protecting urban and agricultural communities. Maintaining their hydraulic capacity requires dredging, a continuous, costly, and essential maintenance activity. Traditionally, the effectiveness of dredging is evaluated retrospectively; judgment on a project's success is made after its completion based on hydrographic data and observed performance. This approach has inherent limitations when dealing with dynamic systems affected by human activities. This reactive "dredge-and-see" cycle is inherently inefficient and risky, focusing on past performance rather than future needs.

This weakness presents a significant opportunity to transition from a reactive management model to a strategic, predictive framework. This transition requires confronting a fundamental technical challenge: uncertainty. Deterministic hydraulic models provide a misleading picture of precision, as real-world systems face uncertainties from parametric sources (e.g., Manning's roughness coefficient), input data errors, and structural model simplifications. To manage this, probabilistic methods like Monte Carlo simulation have emerged as standard tools, allowing engineers to generate a probability distribution of possible outcomes instead of a single deterministic output. While Monte Carlo can assess uncertainty for a given scenario, it cannot forecast future scenarios. This is the domain of data-driven predictive modeling. Deep learning models, particularly Long Short-Term Memory (LSTM) networks, have shown an extraordinary ability to forecast complex time series, such as river flow and water levels, and now provide reliable predictive tools. Despite the parallel maturation of Monte Carlo methods and deep learning, a significant research gap exists in their integrated application to dredging evaluation. This paper fills this gap by presenting an innovative framework that links these two domains, transforming dredging assessment from a passive, historical exercise into an active, strategic, and 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 (μ) 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.

یک چارچوب مونت کارلو- LSTM برای ارزیابی واقع‌بینانه و مدیریت پیش‌بینانه لایروبی کانال‌های شهری

محمد رضا مسعودی مقدم*

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

* m_masoudimoghaddam@sbu.ac.ir

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 ابودر 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 ۴۴٪ درصد بود، اما بازه اطمینان ۹۵٪ این کاهش، بسیار گسترده و بین ۹۶۶- تا ۱۷۱۲ درصد قرار دارد. این یافته بر اهمیت حیاتی در نظر گرفتن عدم قطعیت در تحلیل‌های هیدرولیکی تأکید می‌کند. علاوه بر این، مدل LSTM توسعه یافته با موفقیت الگوهای زمانی را فرا گرفت و توانست سطح آب را با دقت بالا و ریشه میانگین مربعات خطای (RMSE) تنها ۳۲ سانتی‌متر بر روی داده‌های آزمون، پیش‌بینی نماید. این مطالعه نتیجه می‌گیرد که تلفیق تحلیل‌های احتمالاتی با مدل‌های پیش‌بینی هوش مصنوعی، دیدگاهی بسیار واقع‌بینانه‌تر و جامع‌تر نسبت به روش‌های ارزیابی سنتی فراهم کرده و گامی اساسی به سوی مدیریت داده‌محور و هوشمند زیرساخت‌های آبی شهری است.

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

۱- مقدمه

پژوهش‌ها نشان داده‌اند که علاوه بر کیفیت داده‌ها، پارامترهای محاسباتی نظیر فواصل شبکه‌بندی و بهره‌گیری از پردازش موازی نقش تعیین‌کننده‌ای در تعادل میان سرعت و دقت مدل‌سازی‌های عددی سیلاب ایفا می‌کنند (Teymouri et al., 2024). به طور سنتی، ارزیابی اثربخشی پروژه‌های لایروبی یک فرآیند اساساً پس‌نگر است؛ به این معنا که قضاوت در مورد موفقیت یک پروژه پس از اتمام آن و بر اساس داده‌های هیدروگرافی و عملکرد مشاهده‌شده کانال صورت می‌گیرد. این رویکرد، که بر اصول تثبیت‌شده هیدرولیک مانند محاسبه سرعت جریان با استفاده از فرمول مانینگ و طراحی سازه‌های مهندسی مانند آبشکن‌ها استوار است (Van der Meer et al., 2025)، دارای محدودیت‌های ذاتی است. فعالیت‌های انسانی مانند ساخت‌وسازهای

کانال‌های سیلاب‌رو، زیرساخت‌های کلیدی برای حفاظت از جوامع شهری و کشاورزی محسوب می‌شوند. حفظ ظرفیت هیدرولیکی این کانال‌ها مستلزم یک فعالیت نگهداری مستمر، پرهزینه و ضروری به نام لایروبی است. اثربخشی این عملیات معمولاً با استفاده از مدل‌های هیدرولیکی برای ارزیابی سناریوهای مختلف و سنجش میزان افزایش ظرفیت آبگذری رودخانه ارزیابی می‌شود (HEC-RAS, 2016). در سال‌های اخیر، استفاده از شبیه‌سازی‌های هیدرولیکی دوبعدی (2D) با داده‌های باکیفیت، به عنوان ابزاری دقیق برای بهبود نقشه‌های خطر سیلاب شهری و ارزیابی تأثیر مداخلات مهندسی مانند لایروبی، به شدت مورد توجه قرار گرفته است (Mihu-Pintilie et al., 2019). در این راستا،

عدم قطعیت و پیش‌بینی هوشمند (که در این مقاله به آن پرداخته می‌شود) همچنان به قوت خود باقی است. گذار از پس‌نگری به پیش‌بینی مستلزم مواجهه با یک چالش فنی بنیادین است: عدم قطعیت. مدل‌های هیدرولیکی قطعی، هرچند مفید، یک تصویر گمراه‌کننده از دقت ارائه می‌دهند. در واقعیت، سیستم‌های هیدرولیکی با عدم قطعیت‌های متعددی از منابع مختلف مواجه هستند. این عدم قطعیت‌ها را می‌توان به سه دسته اصلی تقسیم کرد: عدم قطعیت پارامتری، مانند ضریب زبری مانینگ که به شدت به شرایط بستر و پوشش گیاهی وابسته است. در واقع، ضریب مانینگ یک پارامتر تجربی پیچیده است که نه تنها به زبری بستر، بلکه به عواملی متعدد دیگری چون وجود و نوع پوشش گیاهی، نامنظمی‌های کانال، رسوب‌گذاری و بار معلق نیز بستگی دارد (Chow, 1959; Ebrahimi, 2017). عدم قطعیت داده‌های ورودی، مانند خطاهای موجود در داده‌های توپوگرافی و دبی جریان؛ و عدم قطعیت ساختاری، که از ساده‌سازی‌های ذاتی مدل ناشی می‌شود (Savage et al., 2018). ضریب زبری مانینگ یک مثال کلاسیک از پارامتری بسیار حساس و نامشخص است که تغییرات کوچک در آن می‌تواند به طور قابل توجهی نتایج مدل‌سازی، از جمله پروفیل سطح آب و پهنه‌های سیلابی، را تحت تأثیر قرار دهد. برای مدیریت این عدم قطعیت‌ها، روش‌های احتمالی مانند شبیه‌سازی مونت کارلو و رویکردهای بیزی (Bayesian) به عنوان ابزارهای 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; Dastorani & Pinos & Timbe, 2021). این تحول، یک گذار فلسفی در مهندسی را نشان می‌دهد: از جستجوی یک پاسخ صحیح به سمت درک توزیعی از آینده‌های ممکن. این خروجی احتمالی برای مدیریت ریسک بسیار ارزشمندتر از یک مقدار قطعی است. در زمینه لایروبی، این رویکرد به مدیران امکان می‌دهد تا تصمیمات خود را بر اساس یک سطح ریسک قابل قبول اتخاذ کنند (مثلاً زمانی لایروبی می‌کنیم که احتمال تجاوز از ظرفیت کانال در فصل آینده بیش از ۱۰ درصد)، که یک استراتژی بسیار پیچیده‌تر و قابل دفاع‌تر است.

در حالی که شبیه‌سازی مونت کارلو می‌تواند عدم قطعیت را برای یک سناریوی معین ارزیابی کند، به خودی خود قادر

ساحلی و لایروبی، به عنوان یک نیروی خارجی مهم، می‌تواند به طور قابل توجهی مورفودینامیک سواحل و خورها را تغییر دهند (Wu & Wan, 2022). نمونه‌ای از این تأثیرات در مطالعات داخلی نیز مشاهده شده است، جایی که مداخلات مهندسی و طرح‌های توسعه فیزیکی می‌توانند الگوهای رسوب‌گذاری را در اکوسیستم‌های حساسی مانند تالاب‌ها به طور جدی دستخوش تغییر کنند (Heydarnzhad & Badiei, 2025). این رویکرد واکنشی ذاتاً ناکارآمد و پرریسک است. این رویکرد به جای تمرکز بر شاخص‌های پیش‌بینانه (نیازهای آبی کانال)، بر شاخص‌های پس‌نگر (عملکرد گذشته) متمرکز است. این ناکارآمدی مستقیماً به اتلاف منابع (لایروبی بیش از حد یا زود هنگام) یا افزایش ریسک (لایروبی کمتر از حد یا دیر هنگام) منجر می‌شود. این چرخه واکنشی، به جای پاسخ به این پرسش که "آیا برای مواجهه با رویدادهای آبی آماده هستیم؟"، تنها به این پرسش پاسخ می‌دهد که "آیا مشکل گذشته را حل کرده‌ایم؟". این ضعف، یک فرصت قابل توجه برای بهینه‌سازی و گذار از یک الگوی مدیریتی واکنشی به یک چارچوب استراتژیک و پیش‌بینانه را نمایان می‌سازد. اهمیت این گذار از رویکرد واکنشی، در مطالعات داخلی مرتبط با سیلاب‌های اخیر ایران به وضوح دیده می‌شود. پژوهش‌ها نشان داده‌اند که مسائلی چون عدم لایروبی رودخانه‌ها، یکی از عوامل تشدیدکننده سیلاب‌های مخرب، مانند سیل ۱۳۹۸ در حوضه گرگان‌رود، بوده است (Rajabizadeh et al., 2019). در پاسخ، مطالعاتی در ایران با استفاده از مدل‌سازی هیدرولیکی به بررسی اثر سناریوهای لایروبی در همین منطقه (Khajeh et al., 2022) و همچنین ارزیابی خطر سیلاب در سایر دشت‌های سیلابی شهری ایران (به عنوان مثال، رودخانه ایرانشهر) پرداخته‌اند (Jamal et al., 2019). همچنین، تحلیل‌های هیدرولیکی برای تعیین دقیق حد بستر قانونی در سیلاب‌دشت‌ها به عنوان ابزاری برای مدیریت پیشگیرانه و کاهش خسارات در رودخانه‌های ایران مورد استفاده قرار گرفته است (Ezzati et al., 2025). باخیراً نیز پژوهشی به طور خاص به ارزیابی تأثیر سناریوهای مختلف لایروبی در شهر آق‌قلا با استفاده از شبیه‌سازی دوبعدی پرداخته است (Rezaei-Ghaleh et al., 2025). این مطالعات، هرچند در ارزیابی هیدرولیکی پیشرفته هستند، اما عموماً بر تحلیل‌های قطعی متمرکز بوده‌اند و خلأ تحلیل

۲. این پیش‌بینی‌ها به عنوان سناریوهای ورودی و شرایط مرزی برای یک مدل هیدرولیکی معتبر (مانند HEC-RAS) که قابلیت‌های گسترده‌ای در مدل‌سازی رسوب و ارزیابی سناریوهای لایروبی دارد، استفاده می‌شوند (Brunner, 2016; Van et al., 2024).

۳. سپس، شبیه‌سازی مونت کارلو بر روی مدل هیدرولیکی اجرا می‌شود تا عدم قطعیت‌های پارامتری (مانند ضریب زبری مانینگ) برای هر یک از سناریوهای پیش‌بینی‌شده در آینده، منتشر شود.

نتیجه نهایی این فرآیند، یک مقدار قطعی نیست، بلکه یک پیش‌بینی احتمالاتی از چگونگی عملکرد کانال در آینده است (مثلاً با احتمال ۳۰ درصد، عمق کانال در ماه ششم کمتر از حد آستانه خواهد بود). این رویکرد، گامی اساسی به سوی تحقق یک هدف پیشرفته‌تر، یعنی ایجاد «دوقلوی دیجیتال» (Digital Twin) برای کانال است. 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 سناریوهای «چه-اگر» (what-if) و بهینه‌سازی مستمر عملیات نگهداری استفاده کنند (Viergutz & Josipović, 2023; Syed et al., 2024; Green et al., 2025). در نهایت، این پژوهش یک تغییر پارادایم را پیشنهاد می‌کند: گذار از نگهداری مبتنی بر برنامه ثابت یا واکنش به شکست، به سمت مدیریت نگهداری پیش‌بینانه و مبتنی بر ریسک، که کارآمدتر، مقرون‌به‌صرفه‌تر و تاب‌آورتر است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، کانال ابوذر تهران به عنوان بخشی کلیدی از شبکه جمع‌آوری رواناب شهری انتخاب گردید. این کانال که ادامه کانال منوچهری محسوب می‌شود، از تقاطع خیابان‌های پیروزی و ابوذر آغاز می‌گردد. مسیر کانال پس از عبور از چندین خیابان و بزرگراه اصلی، در نهایت به میدان افسریه نزدیک می‌شود. موقعیت دقیق محدوده مورد مطالعه که عملیات لایروبی در آن صورت گرفته، در شکل ۱ نشان داده شده است. حوضه آبریز تحت پوشش این کانال مساحتی برابر با ۴۱۳.۹۳ کیلومتر مربع دارد. عملیات لایروبی در این کانال در تاریخ ۱۸ تیر ۱۴۰۲

به پیش‌بینی سناریوهای آتی نیست. این حوزه، مربوط به مدل‌سازی پیش‌بینانه مبتنی بر داده است. در دهه‌های اخیر، شاهد پیشرفت‌های چشمگیری در علوم داده بوده‌ایم که منجر به توسعه مدل‌های یادگیری عمیق شده است. این مدل‌ها، به ویژه شبکه‌های حافظه طولانی کوتاه-مدت (LSTM) و انواع آن مانند واحدهای بازگشتی دردار (GRU)، توانایی خارق‌العاده‌ای در پیش‌بینی سری‌های زمانی پیچیده، غیرخطی و تصادفی مانند جریان رودخانه و تراز آب از خود نشان داده‌اند (Zhang et al., 2018; Daramola et al., 2025). مطالعات متعدد نشان داده‌اند که مدل‌های LSTM و مدل‌های ترکیبی (هیبریدی) به طور مداوم عملکردی بهتر از مدل‌های آماری سنتی و حتی برخی مدل‌های فیزیکی دارند (Bhuiyan et al., 2024; Farfán-Durán & Cea, 2024; Truong et al., 2025). این حوزه به سرعت در حال تکامل است و پژوهشگران از مدل‌های مستقل به سمت معماری‌های ترکیبی قدرتمندتر 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 متنوع ترکیب می‌شوند تا دقت پیش‌بینی را افزایش دهند (Zheng et al., 2024). این پیشرفت‌ها، که در جدیدترین پژوهش‌ها نیز مشهود است، نشان می‌دهد که ابزارهای لازم برای تولید پیش‌بینی‌های قابل اعتماد و بلندمدت از متغیرهای کلیدی مؤثر بر نیاز به لایروبی، اکنون در دسترس و به بلوغ رسیده‌اند (Pathan et al., 2024).

با وجود بلوغ روش‌های مونت کارلو برای تحلیل عدم قطعیت و اثبات کارایی یادگیری عمیق برای پیش‌بینی، یک شکاف تحقیقاتی قابل توجه در کاربرد یکپارچه این دو فناوری برای حل مسئله ارزیابی لایروبی وجود دارد. این مقاله با ارائه یک چارچوب نوآورانه که این دو حوزه را به هم پیوند می‌دهد، این شکاف را پر می‌کند. رویکرد پیشنهادی، ارزیابی لایروبی را از یک تمرین منفعل و تاریخی به یک ابزار مدیریتی فعال، استراتژیک 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 هیدروگراف جریان) را در یک افق برنامه‌ریزی مشخص پیش‌بینی کند.

(July 9, 2023) انجام شد که فرصتی برای ارزیابی تأثیر آن بر پارامترهای هیدرولیکی فراهم آورد.

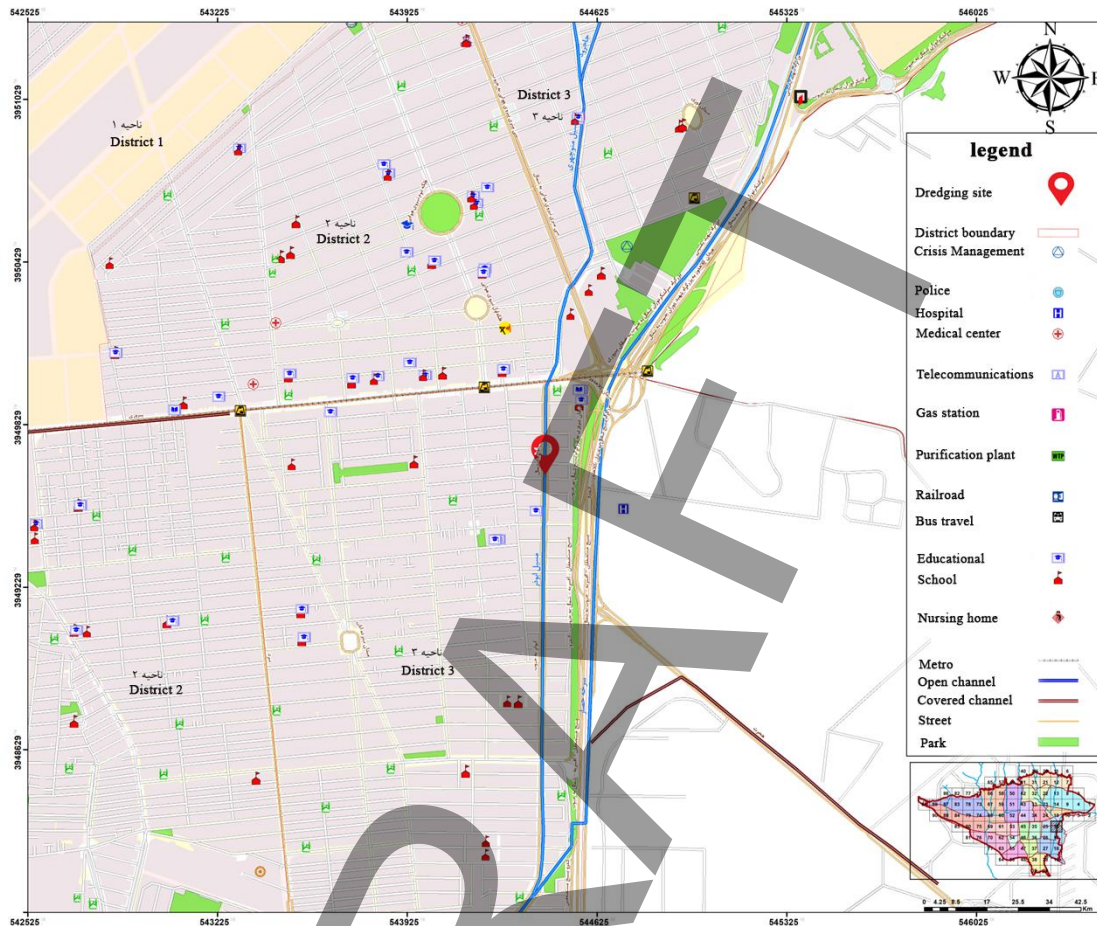


Fig. 1 Dredging site in Abuzar Canal, Tehran

شکل ۱ محل لایروبی در کانال ابوزر تهران

به منظور صحت‌سنجی و محاسبه مستقیم پارامترها، سرعت جریان آب در مقاطع عرضی با استفاده از دستگاه سرعت‌سنج (Current Meter/Molinete) اندازه‌گیری شد. علاوه بر این، ابعاد هندسی دقیق کانال، شامل ۵۷ مقطع عرضی در طول بازه مطالعاتی، از طریق عملیات نقشه‌برداری به دست آمد. این مجموعه داده‌های جامع، پایه‌ای برای کالیبراسیون مدل هیدرولیکی اولیه و همچنین تحلیل‌های آماری پیشرفته فراهم آورد.

۲-۲- جمع‌آوری داده‌های میدانی و ابزارها

داده‌های مورد نیاز برای این پژوهش شامل پارامترهای هیدرولیکی و هندسی کانال بود که قبل و بعد از عملیات لایروبی (مورخ ۱۸ تیر ۱۴۰۲) جمع‌آوری گردید (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 سری زمانی به عنوان ورودی اصلی برای تحلیل‌های بعدی به کار رفت.



Fig. 2 Flow measurement with a mouline

شکل ۲ اندازه گیری جریان با مولینه

۲-۳- تحلیل هیدرولیکی اولیه و محاسبه

قطعی ضریب مانینگ

پیش از انجام تحلیل‌های احتمالاتی و پیش‌بینانه، ابتدا لازم بود تا مقدار پایه و قطعی ضریب زبری مانینگ برای شرایط قبل و بعد از لایروبی محاسبه گردد. این مقادیر، نقطه مرجع برای ارزیابی بهبود عملکرد کانال و همچنین به عنوان مقادیر میانگین (μ) 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 متوسط جریان (m/s)، n ضریب زبری مانینگ، R شعاع هیدرولیکی (m) و S شیب طولی بستر کانال است. مقادیر مورد نیاز برای این محاسبه، شامل سرعت متوسط جریان، شعاع هیدرولیکی (نسبت سطح مقطع به محیط خیس شده)، و شیب کانال، مستقیماً از داده‌های جمع‌آوری شده در بخش ۲.۲ (شامل نتایج دستگاه سرعت‌سنج و عملیات نقشه‌برداری) استخراج گردید. با جایگذاری این مقادیر، ضریب زبری مانینگ برای شرایط قبل و بعد از لایروبی به کمک نرم افزار مایک محاسبه شد که منجر به کاهش قطعی معادل ۴.۴۷ درصد گردید. این مقدار، همان نتیجه‌ای است که در تحلیل‌های سنتی گزارش شده و پایه تحلیل‌های عدم قطعیت بعدی را تشکیل می‌دهد.

۲-۴- چارچوب تحلیل عدم قطعیت

(شبیه‌سازی مونت کارلو - Monte Carlo Simulation)

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 غلبه بر این محدودیت، در این پژوهش از یک چارچوب تحلیل عدم قطعیت مبتنی بر شبیه‌سازی مونت کارلو استفاده گردید. هدف از این تحلیل، حرکت از یک پاسخ قطعی به سمت درک توزیع احتمالاتی اثربخشی واقعی عملیات لایروبی بود.

در این روش، پارامترهای 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 پارامترهای ورودی بر پایه دو استدلال قوی آماری استوار است: اول، طبق قضیه حد مرکزی (CLT)، از آنجا که خطای اندازه‌گیری در ابزارهایی 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 اساس

مقاطع عرضی انتخاب شد. این انتخاب، ضمن تأیید دقت بالاتر نقشه‌برداری نسبت به اندازه‌گیری جریان (۲ درصد >> ۵ درصد)، با برآوردهای مشابه در متون تخصصی سازگار است. دلیل انتخاب مقدار کمتر (۲ درصد) نسبت به سرعت، دقت بالاتر تجهیزات نقشه‌برداری در مقایسه با هیدرومتری است. این مقدار طبق مطالعه Di Baldassarre و Montanari (2009) به عنوان خطای تجمیعی ناشی از درونیابی بین مقاطع 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 قبل و بعد از لایروبی محاسبه گردید. از این طریق، دو توزیع احتمالاتی برای ضرایب 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 توسعه داده شده در همین پژوهش است، روند کلی شبیه‌سازی را به صورت بصری نمایش می‌دهد.

اصل حداکثر 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 پارامتر به عنوان یک متغیر تصادفی با توزیع نرمال مدل‌سازی شد. میانگین (μ) آن برابر با مقدار اندازه‌گیری شده میدانی با مولینه در نظر گرفته شد. انحراف معیار (σ) آن بر اساس عدم قطعیت نسبی ۵ درصد ($\sigma/\mu = 0.05$) فرض گردید. منظور از عدم قطعیت نسبی در اینجا، نسبت انحراف معیار به میانگین (σ/μ) است. این مقدار، یک فرض استاندارد و پذیرفته‌شده در هیدرومتری میدانی است که بر اساس مراجع فنی معتبر (WMO, 2010) انتخاب شده و منعکس‌کننده خطاهای ذاتی ابزار مولینه در شرایط واقعی و متلاطم جریان می‌باشد.
- فاکتور هندسی (K): این فاکتور که ترکیبی از شعاع هیدرولیکی ($R^{2/3}$) و شیب کانال ($S^{1/2}$) است، با عدم قطعیت نسبی ۲ درصد برای در نظر گرفتن خطاهای جزئی نقشه‌برداری مدل‌سازی شد. این مقدار به عنوان یک تخمین محافظه‌کارانه برای خطاهای تجمیعی ناشی از نقشه‌برداری میدانی و درونیابی هندسی بین

Conceptual Diagram of the Monte Carlo Simulation Method

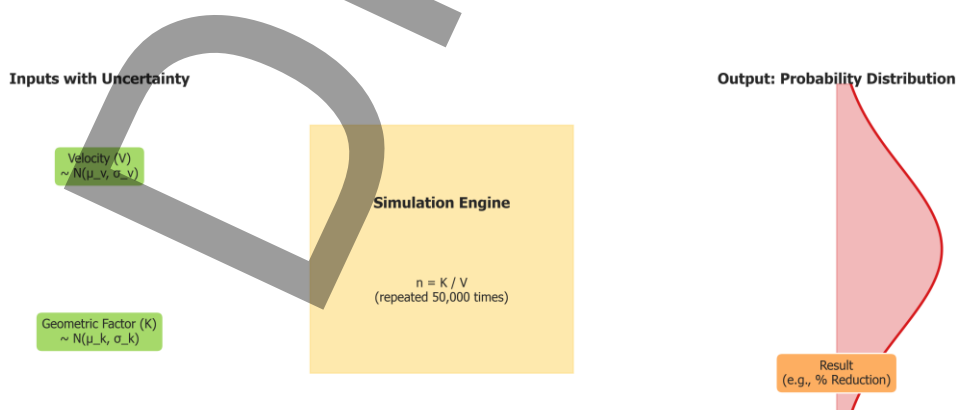


Fig. 3 Conceptual diagram of the Monte Carlo simulation framework

شکل ۳ نمودار مفهومی چارچوب شبیه‌سازی مونت کارلو

کامپایل و برای ۵۰ دوره (epoch) بر روی داده‌های آموزشی، آموزش داده شد. جزئیات کامل هایپرپارامترهای مورد استفاده برای آموزش، شامل نرخ یادگیری، اندازه دسته (batch size) و نحوه 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 گردید. معیار اصلی برای سنجش دقت، ریشه میانگین مربعات خطا (Root Mean Squared Error - RMSE) بود که پس از برگرداندن مقادیر پیش‌بینی شده به مقیاس واقعی (متر) محاسبه شد.

۳- نتایج

۳-۱- خروجی تحلیل عدم قطعیت: رونمایی

از طیف کامل پیامدهای پروژه

تحلیل احتمالاتی مبتنی بر شبیه‌سازی مونت کارلو، تصویری چندبعدی 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 مقادیر، به عنوان نماینده مرکزی توزیع، یک بهبود کلی در کارایی هیدرولیکی کانال 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 قابل توجهی را که در اندازه‌گیری‌های میدانی نهفته است، به صورت کمی آشکار می‌سازد. طیف کامل این نتایج محتمل در شکل ۴، که توزیع احتمالاتی درصد کاهش ضریب مانینگ حاصل 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 مقادیر منفی نیز گسترش یافته‌اند که بیانگر وجود ریسک و سناریوهای نامطلوب در کنار نتایج مثبت است.

۲-۵- چارچوب پیش‌بینی سری زمانی

(شبکه LSTM - Long Short-Term Memory)

(Memory)

علاوه بر ارزیابی اثرات گذشته‌نگر لایروبی، این پژوهش پتانسیل روش‌های مدرن برای پیش‌بینی‌های آینده‌نگر در مدیریت کانال‌ها 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 پارامترهای هیدرولیکی، مانند سطح آب، بر اساس داده‌های با فرکانس بالای سنسورها بود.

۲-۵-۱- تولید داده و پیش‌پردازش

داده‌های مورد نیاز برای این بخش، از طریق یک دستگاه اولتراسونیک ساخته شده در دانشگاه شهید بهشتی (شامل سنسور، ثبات داده و منبع تغذیه مستقل) به همراه مولینه، که برای ثبت میدانی و پیوسته تغییرات سطح آب در یک کانال طی چندین ماه مونتاژ شده بود، جمع‌آوری گردید. داده‌های جمع‌آوری شده 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 ابتدا با استفاده از MinMaxScaler به بازه [۰, ۱] نرمال‌سازی شدند که این فرایند یکی از پیش‌نیازهای استاندارد برای آموزش پایدار شبکه‌های عصبی به شمار می‌رود. سپس، داده‌ها به دنباله‌هایی با طول ثابت تبدیل شدند؛ به گونه‌ای که از ۸ گام زمانی پیشین (معادل ۲ ساعت) برای پیش‌بینی مقدار در گام زمانی بعدی 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

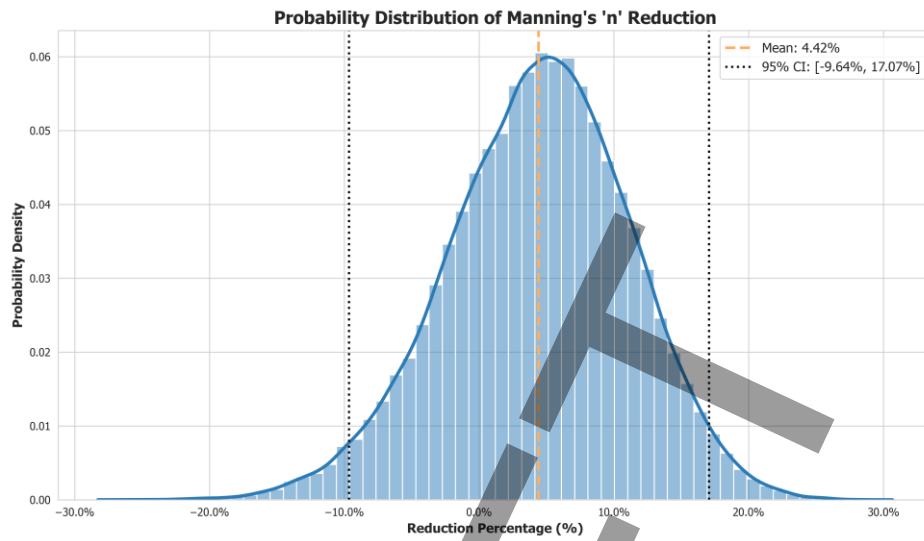


Fig. 4 Probability distribution of percentage reduction in Manning coefficient resulting from Monte Carlo simulation
 شکل ۴ توزیع احتمالاتی درصد کاهش ضریب مانینگ حاصل از شبیه‌سازی مونت کارلو

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 قبل (زرد) و بعد (بنفش) از عملیات لایروبی را نشان می‌دهد. جابجایی آشکار قله توزیع پس از لایروبی به سمت مقادیر کمتر،

سیگنال بهبود کارایی را تأیید می‌کند، اما در عین حال، ناحیه همپوشانی قابل توجه دو نمودار، نویز ناشی از عدم قطعیت را به نمایش می‌گذارد؛ ناحیه‌ای که در آن، تمایز آماری بین شرایط قبل و بعد از لایروبی معنادار نیست.




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 قبل (زرد) و بعد (بنفش) از عملیات لایروبی

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. ذکر این نکته ضروری است که این نمودار نباید به عنوان یک نمودار همبستگی

نمونه‌برداری تصادفی (Independent Sampling) در هر تکرار مونت کارلو است. هدف این نمودار نمایش همبستگی نیست، بلکه مقایسه فراوانی است؛ به طوری که قرارگیری اکثریت قاطع نقاط در زیر خط $y=x$ نشان‌دهنده غلبه آماری سناریوهای 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.

(correlation) تفسیر شود. از آنجایی که مقادیر قبل و بعد 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 بصری ثابت می‌کند که اکثریت قاطع نقاط، علیرغم پراکندگی زیاد، در زیر این خط مرجع قرار گرفته‌اند. فقدان همبستگی خطی در شکل ۶ ناشی از ماهیت مستقل




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 قبل و بعد از لایروبی در یک نمودار پراکندگی

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.

۲-۳ خروجی مدل LSTM

مدل شبکه عصبی LSTM پس از آموزش، عملکرد قدرتمندی در پیش‌بینی سری زمانی از خود به نمایش گذاشت. ارزیابی نهایی مدل بر روی داده‌های آزمون، منجر به محاسبه ریشه میانگین مربعات خطای (RMSE) برابر با ۳.۲ سانتی‌متر گردید. این مقدار خطا، که معادل تنها ۳.۲ سانتی‌متر است، دقت بالایی را برای کاربردهای عملی

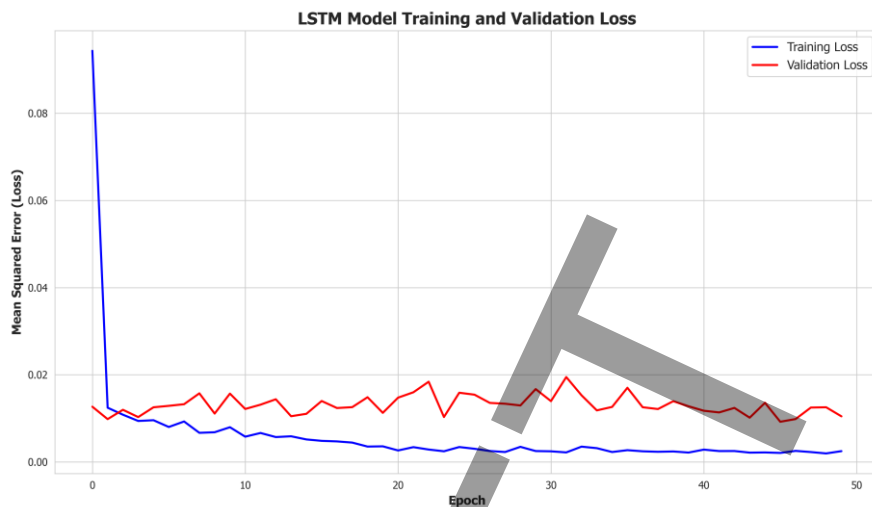


Fig. 7 Training and validation error diagram of the LSTM model

شکل ۷ نمودار خطای آموزش و اعتبارسنجی مدل LSTM

می‌دهد که مدل نه تنها قادر به دنبال کردن روند کلی است، بلکه پیچیدگی‌ها، نوسانات و نقاط اوج و فرود موضعی را نیز با وفاداری بالایی بازتولید می‌کند.

در نهایت، اوج عملکرد مدل در شکل ۸ به نمایش گذاشته شده است. این شکل، مقایسه سری زمانی مقادیر واقعی سطح آب با مقادیر پیش‌بینی شده توسط مدل LSTM در شرایط سیلابی را نشان می‌دهد. انطباق فوق‌العاده نزدیک خط پیش‌بینی قرمز با داده‌های واقعی خاکستری، نشان




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

پتانسیل مدیریت هوشمند کانال‌های شهری ارائه می‌دهد. در ادامه، مفاهیم و پیامدهای کلیدی یافته‌های این تحقیق به تفصیل مورد بحث قرار می‌گیرد.

۴- بحث و تحلیل نتایج

این پژوهش با دو رویکرد نوآورانه، پارا از ارزیابی‌های متداول فراتر گذاشته و درکی چندبعدی از تأثیرات لایروبی و

۴-۱- توهم قطعیت: نگاهی واقع‌بینانه به

اثربخشی پروژه‌های هیدرولیکی

مهم‌ترین یافته این پژوهش، نتیجه عددی کاهش ۴۰.۴۷ 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 تحت عنوان "توهم قطعیت" یاد می‌کند. در حالی که تحلیل‌های سنتی و قطعی صرفاً به گزارش میانگین کاهش ۴.۴۷ درصدی اکتفا کرده و پروژه را با قطعیت موفق اعلام می‌کنند، تحلیل احتمالی حاضر آشکار می‌سازد که نوز و عدم قطعیت ذاتی در اندازه‌گیری‌های میدانی به قدری بالاست که سیگنال مثبت 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 قبل و بعد از لایروبی (که در شکل ۵ مشهود است)، نشان می‌دهد که اگرچه به طور متوسط بهبودی حاصل شده، اما در هر نقطه خاصی از کانال، 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 قضاوت در مورد موفقیت یک پروژه چند میلیارد تومانی اکتفا کرد. این پژوهش نشان می‌دهد که ارائه نتایج به صورت یک توزیع احتمالاتی نه تنها از نظر علمی صادقانه‌تر است، بلکه ابزار مدیریتی بهتری برای ارزیابی ریسک و تخصیص منابع فراهم می‌کند. شکل ۶ نیز این تحلیل را تأیید می‌کند؛ با اینکه روند کلی مثبت است، اما پراکندگی وسیع نقاط، گواهی بر همین عدم قطعیت است.

۴-۲- از نگهداری واکنشی تا مدیریت

پیش‌بینانه

بخش دوم این پژوهش، یک جهش پارادایمی از گذشته‌نگری به آینده‌نگری را به نمایش می‌گذارد. موفقیت

مدل LSTM، که به عنوان یک اثبات مفهوم توسعه داده شد، در پیش‌بینی نوسانات سطح آب با دقت RMSE حدود ۳.۲ سانتی‌متر (که در شکل ۸ به تصویر کشیده شده)، پتانسیل عظیم یادگیری عمیق را برای مدیریت سیستم‌های 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 کانال‌ها عمدتاً واکنشی است؛ یعنی پس از وقوع مشکل (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 سنسورها به مدل‌های هوش مصنوعی تغذیه شده و این مدل‌ها قادرند وقوع سیلاب را ساعت‌ها قبل پیش‌بینی کنند، به صورت خودکار دریچه‌ها را تنظیم نمایند، یا حتی نیاز به لایروبی را قبل 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 مفاهیمی چون شهر هوشمند و دوقلوی دیجیتال (Digital Twin) برای زیرساخت‌های آبی است.

۴-۳- محدودیت‌ها و مسیرهای تحقیقاتی

آینده

با وجود نوآوری‌ها، این مطالعه دارای محدودیت‌هایی است که مسیر را برای پژوهش‌های آتی مشخص می‌کند. اولاً، تحلیل عدم قطعیت بر روی یک مطالعه موردی واحد متمرکز بود و تعمیم نتایج به سایر کانال‌ها نیازمند تحقیقات بیشتر است.

بنابراین، پیشنهاد می‌شود در آینده:

۱. این چارچوب دوگانه بر روی کانال‌های متعددی با مشخصات هیدرولیکی و رسوب‌شناسی متفاوت اجرا شود تا قابلیت تعمیم‌پذیری آن افزایش یابد.
۲. یک پایگاه داده بلندمدت از داده‌های واقعی سنسورها جمع‌آوری شده و از آن برای توسعه و اعتبارسنجی یک مدل LSTM عملیاتی استفاده گردد.

development and implementation. *Journal of Hydrologic Engineering*, 24(2), 04018063.

Chow, V. T. (1959). *Open-channel hydraulics*. 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, e2024WR039054.

Dastorani, M. T., & Dastorani, M. (2020). Uncertainty analysis of a 1D river hydraulic model with adaptive calibration. *Water*, 12(2), 561.

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

Ebrahimi, G. (2017). Impact assessment of vegetation coverage on flow roughness coefficient and trapping of sediment in experimental condition. *International Journal of Hydrology Science and Technology*, 7(4), 355-368.

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*, 123-136.

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, 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.

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). Assessment of the impacts of the Anzali Port development plan on sedimentation in Anzali Lagoon using mathematical simulation. *Journal of Hydraulics*, 57-70.

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.

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.

۳. پارامترهای اقتصادی (هزینه لایروبی در مقابل هزینه خسارت سیلاب) با این چارچوب یکپارچه شوند تا یک ابزار بهینه‌سازی و پشتیبانی از تصمیم (Decision Support System) کامل ایجاد گردد.

۵ - نتیجه‌گیری

این پژوهش با هدف فراتر رفتن از ارزیابی‌های سنتی و قطعی در پروژه‌های لایروبی کانال‌های شهری انجام شد و یک چارچوب تحلیلی دوگانه و مدرن را معرفی نمود. نتایج نشان داد که اگرچه لایروبی به طور متوسط به بهبود 4.5 درصدی کارایی هیدرولیکی منجر شد، اما تحلیل عدم قطعیت، یک بازه اطمینان بسیار گسترده را آشکار ساخت که اهمیت نگاه احتمالاتی به نتایج و در نظر گرفتن خطاهای اندازه‌گیری را برجسته می‌کند. علاوه بر این، این مطالعه با موفقیت نشان داد که مدل‌های یادگیری عمیق (LSTM) از پتانسیل بالایی برای پیش‌بینی دقیق و کوتاه‌مدت پارامترهای 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 احتمالاتی را با قابلیت‌های پیش‌بینی هوش مصنوعی تلفیق می‌کند، یک رویکرد جامع و قدرتمند 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 به سوی نسل جدیدی از ارزیابی‌های مهندسی در عصر دیجیتال است.

۶- فهرست منابع

Bhuiyan, M. A. E., Islam, A. K. M. R., & Nistor, I. (2024). DeepFlowNet: Deep learning based daily water flow forecasting of Test River. *International Journal of Intelligent Systems and Applications in Engineering*, 12(1), 234-245.

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

Camacho, R. A., Zhang, Z., & Chao, X. (2019). Receiving water quality models for TMDL

- accuracy of flood modeling using STE software. *Scientific Journal of Hydraulics*, 20(4), 1–21.
- 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, 218-232.
- 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.
- Van der Meer, J. W., Hardeman, B., Steendam, G. J., Schüttrumpf, H., & Verheij, H. (2025). Flow depths and velocities at crest and landward slope of a dike, in theory and with the wave overtopping simulator. *Coastal Engineering Proceedings*, 1(32), 10.
- Viergutz, C., & Josipović, I. (2023). Smart city flood management: A transdisciplinary approach using big data, digital twins, and remote sensing. *German Aerospace Center (DLR)*.
- 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.
- 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*.
- 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.
- Li, X., Li, J., & Liu, Z. (2022). Hybrid CNN-LSTM models for river flow prediction. *Water Science and Technology*, 85(10), 2874-2886.
- Mihu-Pintilie, A., et al. (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, 1832.
- 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.
- Pinos, J., & Timbe, L. (2021). Uncertainty quantification in hydrologic and hydraulic modeling for floodplain delineation considering climate change effects. *Water*, 13(9), 1248.
- 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, Kh. (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(1), 1–10.
- Savage, A. C., Pianosi, F., & Bates, P. D. (2018). A framework for probabilistic flood forecasting by coupling hydrologic and 2D unsteady hydraulic models. *Hydrology and Earth System Sciences*, 22(3), 1845-1864.
- 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(22), 3410.
- Teymouri, R., Dehghani, A. A., & Meftah Helghi, M. (2025). Investigating the effect of parallel processing and different mesh sizes on the speed and

پیوست ۱: هایپر پارامترهای 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 پیوست ۱ هایپر پارامترهای مدل LSTM

Table Appendix 1 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)