

Título: **Diagnóstico de fugas en redes hidráulicas mediante redes neuronales con retardos**

Director: **Dr. Ildeberto de los Santos Ruiz**

Contacto: **ildeberto.dr@tuxtla.tecnm.mx**

Descripción de la propuesta

El diagnóstico de fugas es una tarea esencial para la gestión eficiente del agua potable. A nivel mundial, casi una tercera parte del líquido se pierde en las tuberías de las redes de distribución antes de llegar al consumidor final; en México, las fugas alcanzan entre 40% y 70% del agua químicamente tratada [1], lo que representa pérdidas económicas considerables y ocasiona problemas sanitarios en muchas ciudades. El diagnóstico de fugas es un problema complejo debido a que el agua fugada no emerge a la superficie sino que se filtra al subsuelo; sin embargo, el monitoreo de presiones y caudales en algunos puntos de la red permite —mediante algoritmos computacionales— detectar las fugas, dimensionarlas y estimar su ubicación [2].

Existen diversas propuestas basadas en mediciones de presión para localizar fugas en redes de distribución [3, 4]. Típicamente, los métodos de diagnóstico de fugas se basan en los residuales de presión, los cuales son la diferencia entre la presión real medida en ciertos nodos de la red y la presión estimada en esos nodos por simulación con un modelo hidráulico [5]. Los parámetros del modelo se asumen constantes en el tiempo y se calibran a partir de mediciones de las variables hidráulicas en un periodo concreto. Sin embargo, algunos parámetros pueden cambiar con el tiempo (e.g., las propiedades físicas de las tuberías) y es conveniente actualizarlos periódicamente, lo cual no es una tarea simple [6]; otros parámetros son inciertos (e.g., el consumo de los usuarios), de modo que los métodos de diagnóstico basados en modelos [7, 8] presentan limitaciones importantes por lo difícil que resulta mantener un modelo bien calibrado. Por ello, en los últimos años se han explorado diferentes métodos de diagnóstico basados en datos [9, 10], y también híbridos [11, 12] que usan combinaciones *model-based* + *data-driven* con las cuales se busca prescindir del modelo o reducir la dependencia de este.

El común denominador de los métodos de diagnóstico de fugas basados en datos es que utilizan alguna técnica de *machine learning* para aprender los patrones de comportamiento hidráulico asociados a las fugas [5, 13]. Entre las propuestas metodológicas más recientes para diagnosticar fugas se encuentran las redes neuronales con aprendizaje profundo (*deep learning*, en inglés) las cuales se basan en el procesamiento computacional de grandes cantidades de datos, generalmente en forma de imágenes, para extraer las características relevantes de los datos y asociarlas con los diferentes tipos de fuga [14, 15]. Sin embargo, con toda la complejidad computacional del aprendizaje profundo los resultados obtenidos con esta técnica no han sido superiores a los obtenidos con otros métodos de *machine learning*, posiblemente porque las redes neuronales se han entrenado para instantes de tiempo específicos sin considerar la dependencia temporal de las variables hidráulicas, la cual está relacionada con perfiles de consumo dependientes del horario. Por ello, **en esta tesis se propone estudiar el diagnóstico fugas mediante redes neuronales con retardos utilizando series de tiempo como datos de entrada.**

El argumento para suponer que las redes neuronales con retardos podrían conducir a un mejor diagnóstico de fugas, comparadas con las redes sin retardos, es que la inclusión de variables temporizadas (formalmente, señales o series de tiempo) permitiría que la red neuronal asimile la dinámica de baja frecuencia y las variaciones en el tiempo asociadas al perfil de consumo; así la red podría discriminar mejor entre los cambios de presión causados por fugas y aquellos propios de la dinámica temporal de las variables hidráulicas.

En la investigación se explorarán diferentes tipos de redes con retardos (también nombradas “redes recurrentes” por incluir lazos de retroalimentación), particularmente las redes profundas LSTM (*Long Short-Term Memory*), ya que estas han demostrado una buena capacidad de predicción en secuencias de datos que cambian con el tiempo [16, 17, 18]. A diferencia de las redes recurrentes básicas cuya memoria es de corto plazo, las redes LSTM están formadas por celdas con compuertas ajustables que permiten a los datos propagarse en la red y ser recordados durante largos periodos de tiempo, pero también están determinadas por un “factor

de olvido” que durante el entrenamiento se ajusta para que la red olvide datos cuando ya no le sean útiles [19]. Dado que no se conoce una red neuronal que sea superior a las demás en cualquier aplicación, un aspecto fundamental de la investigación será la selección de la arquitectura neuronal más apropiada para la tarea del diagnóstico de fugas.

Objetivo de la investigación

Desarrollar técnicas para diagnóstico de fugas en redes hidráulicas mediante redes neuronales con retardos a partir de las presiones en nodos específicos de la red tomadas como series de tiempo.

Objetivos específicos

1. Conocer la física de las redes de distribución de agua y los modelos hidráulicos que consideran al tiempo como variable.
2. Simular fugas con modelos de redes hidráulicas en periodo extendido.
3. Crear una base de datos de la red hidráulica experimental con mediciones en diferentes escenarios de fuga.
4. Diseñar un sistema neuronal para diagnóstico de fugas tomando como entradas las series de tiempo de presiones en nodos específicos de la red hidráulica.
5. Evaluar el desempeño del sistema de diagnóstico propuesto y contrastarlo con trabajos previos.

Referencias

- [1] OECD. Water governance in cities. *OECD Studies on Water*, 2016. doi: 10.1787/9789264251090-en.
- [2] David B Steffelbauer, Jochen Deuerlein, Denis Gilbert, Edo Abraham, and Olivier Piller. Pressure-leak duality for leak detection and localization in water distribution systems. *Journal of Water Resources Planning and Management*, 148(3):04021106, 2022.
- [3] Zukang Hu, Beiqing Chen, Wenlong Chen, Debao Tan, and Dingtao Shen. Review of model-based and data-driven approaches for leak detection and location in water distribution systems. *Water Supply*, 21(7):3282–3306, 2021.
- [4] Ildeberto Santos-Ruiz, Francisco-Ronay López-Estrada, Vicenç Puig, Guillermo Valencia-Palomo, and Héctor-Ricardo Hernández. Pressure sensor placement for leak localization in water distribution networks using information theory. *Sensors*, 22(2):443, 2022.
- [5] Ildeberto Santos-Ruiz, J Blesa, V Puig, and FR López-Estrada. Leak localization in water distribution networks using classifiers with cosenoidal features. *IFAC-PapersOnLine*, 53(2):16697–16702, 2020.
- [6] Ildeberto Santos-Ruiz, Francisco-Ronay López-Estrada, Vicenç Puig, Lizeth Torres, Guillermo Valencia-Palomo, and Samuel Gómez-Peñate. Optimal estimation of the roughness coefficient and friction factor of a pipeline. *Journal of Fluids Engineering*, 143(5), May 2021. ISSN 0098-2202. doi: 10.1115/1.4049674. 051304.
- [7] Ildeberto Santos-Ruiz, J. R. Bermúdez, F. R. López-Estrada, V. Puig, L. Torres, and J. A. Delgado-Aguiñaga. Online leak diagnosis in pipelines using an EKF-based and steady-state mixed approach. *Control Engineering Practice*, 81:55–64, December 2018. ISSN 0967-0661. doi: 10.1016/j.conengprac.2018.09.006.

- [8] Lizeth Torres, Cristina Verde, and Lázaro Molina. Leak diagnosis for pipelines with multiple branches based on model similarity. *Journal of Process Control*, 99:41–53, 2021.
- [9] Ivana Lučin, Zoran Čarija, Siniša Družeta, and Bože Lučin. Detailed leak localization in water distribution networks using random forest classifier and pipe segmentation. *IEEE Access*, 9:155113–155122, 2021.
- [10] Débora Alves, Joaquim Blesa, Eric Duviella, and Lala Rajaoarisoa. Robust data-driven leak localization in water distribution networks using pressure measurements and topological information. *Sensors*, 21(22):7551, 2021.
- [11] ZY Wu, A Chew, X Meng, J Cai, J Pok, R Kalfarisi, KC Lai, SF Hew, and JJ Wong. Data-driven and model-based framework for smart water grid anomaly detection and localization. *AQUA—Water Infrastructure, Ecosystems and Society*, 71(1):31–41, 2022.
- [12] Marlon Jesús Ares-Milián, Marcos Quiñones-Grueiro, Cristina Verde, and Orestes Llanes-Santiago. A leak zone location approach in water distribution networks combining data-driven and model-based methods. *Water*, 13(20):2924, 2021.
- [13] Amir Houshang Ayati, Ali Haghghi, and Hamid Reza Ghafouri. Machine learning–assisted model for leak detection in water distribution networks using hydraulic transient flows. *Journal of Water Resources Planning and Management*, 148(2):04021104, 2022.
- [14] Mohammadreza Javadiha, Joaquim Blesa, Adria Soldevila, and Vicenç Puig. Leak localization in water distribution networks using deep learning. In *2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)*, pages 1426–1431. IEEE, 2019.
- [15] Luis Romero, Joaquim Blesa, Vicenç Puig, Gabriela Cembrano, and Carlos Trapiello. First results in leak localization in water distribution networks using graph-based clustering and deep learning. *IFAC-PapersOnLine*, 53(2):16691–16696, 2020.
- [16] Zahra Karevan and Johan AK Suykens. Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*, 125:1–9, 2020.
- [17] Hoon Kang, Seunghyeok Yang, Jianying Huang, and Jeill Oh. Time series prediction of wastewater flow rate by bidirectional LSTM deep learning. *International Journal of Control, Automation and Systems*, 18(12):3023–3030, 2020.
- [18] Roberto Casado-Vara, Angel Martin del Rey, Daniel Pérez-Palau, Luis De-la Fuente-Valentín, and Juan M Corchado. Web Traffic Time Series Forecasting Using LSTM Neural Networks with Distributed Asynchronous Training. *Mathematics*, 9(4):421, 2021.
- [19] Xuanyi Song, Yuetian Liu, Liang Xue, Jun Wang, Jingzhe Zhang, Junqiang Wang, Long Jiang, and Ziyang Cheng. Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model. *Journal of Petroleum Science and Engineering*, 186:106682, 2020.