



Aceleración de simulaciones fluviales computacionalmente intensivas mediante aprendizaje automático

Kevin Douglas Alvarez Segales

Universidad Nacional Autónoma de México, Instituto de Ingeniería,
Ciudad de México, México.
ORCID: 0009-0009-2029-0547

Alejandro Mendoza Reséndiz

Universidad Nacional Autónoma de México, Instituto de Ingeniería,
Ciudad de México, México.
ORCID: 0000-0002-2479-9799

Moisés Berezowsky Verduzco

Universidad Nacional Autónoma de México, Instituto de Ingeniería,
Ciudad de México, México.
ORCID: 0000-0002-7675-3450

Recepción: 01 de marzo de 2026.

Aceptación: 22 de abril de 2026.

Mayo 2026 • número de revista 15 • DOI: 10.22201/dgtic.26832968e.2026.15.157

Aceleración de simulaciones fluviales computacionalmente intensivas mediante aprendizaje automático

Resumen

Predecir la evolución del lecho es clave para anticipar procesos de erosión y sedimentación que afectan la infraestructura. Aunque los modelos 2D resuelven la hidromorfodinámica mediante la ecuación de Exner, su costo computacional es elevado debido a restricciones de estabilidad, mallas finas y la sobrecarga del cómputo paralelo. Esta demanda técnica hace que la exploración de escenarios dependa habitualmente de plataformas de alto desempeño (HPC).

Se propone un esquema que combina simulación numérica y aprendizaje automático. Primero, se ejecutan modelos numéricos convencionales para generar bases de datos espacio-temporales. Luego, se entrenan redes neuronales tipo perceptrón multicapa (MLP) como modelos sustitutos, con el fin de predecir la evolución del fondo en pasos de tiempo sucesivos. El enfoque se evalúa con simulaciones 2D mediante un modelo de elementos finitos acoplado hidrodinámico-sedimentos, elaborado en TELEMAC-MASCARET. Los resultados muestran que el MLP reproduce la tendencia espacio-temporal del lecho y reduce de forma sustancial el tiempo de análisis, lo que habilita estudios iterativos y la exploración de escenarios. Se discuten las limitaciones por extrapolación y las recomendaciones para un uso robusto.

Palabras Clave: morfodinámica fluvial, transporte de sedimentos, modelación numérica, modelos sustitutos, perceptrón multicapa, TELEMAC-SISYPHE, aprendizaje de máquina.

Acceleration of computationally intensive fluvial simulations using machine learning

Abstract

Predicting riverbed evolution is essential in applied hydromorphology because it helps anticipate erosion and deposition processes that reshape channel geometry and affect hydraulic infrastructure. These dynamics are commonly simulated with 2D morphodynamic models that solve conservation equations for flow and sediment transport, including the Exner equation. However, computational cost can be high due to stability constraints, flow–sediment coupling, and, in 2D, mesh size and parallel communication overhead, motivating the use of high-performance computing (HPC) to explore scenarios more efficiently.

This paper proposes a hybrid workflow combining numerical simulation and machine learning: (i) running conventional high-fidelity models to generate spatiotemporal datasets and (ii) training multilayer perceptron (MLP) neural networks as surrogate models to predict bed evolution at successive time steps. The approach is evaluated using 2D simulations based on coupled hydrodynamics–sediment finite-element modeling in TELEMAC-MASCARET. Results indicate that the MLP reproduces the spatiotemporal trend of bed evolution while substantially reducing analysis time, enabling iterative studies. Limitations related to extrapolation are discussed, along with recommendations for robust operational use.

Keywords: *fluvial morphodynamics; sediment transport; numerical modeling; surrogate models; multilayer perceptron; TELEMAC-SISYPHE; machine learning.*

1 Introducción

La evolución del lecho fluvial surge de la interacción no lineal entre la hidrodinámica y el transporte de sedimentos, generando patrones de erosión y depósito que afectan la infraestructura hidráulica. En modelación clásica, este proceso se describe mediante las ecuaciones de flujo en lámina libre acopladas a la ecuación de Exner, la cual vincula la

divergencia del transporte con el cambio de elevación del fondo [1]. Para cerrar el sistema, las tasas de transporte se estiman mediante expresiones empíricas o semiempíricas ampliamente utilizadas (p. ej., Meyer-Peter y Müller; Engelund-Hansen; Van Rijn), derivadas de evidencia experimental y de campo [2], [3].

Este enfoque ofrece consistencia física, pero su alto costo computacional en mallas finas y simulaciones largas limita análisis iterativos (calibración e incertidumbre), incluso en sistemas HPC. Herramientas como TELEMAC-MASCARET y SISYPHE permiten modelar geometrías complejas y acoplamiento morfológico, pero mantienen una alta demanda de recursos en campañas extensivas [4], [5].

Los modelos de aprendizaje automático se han consolidado como una estrategia de aceleración al desplazar el costo computacional al entrenamiento, permitiendo inferencias rápidas. Específicamente, las redes MLP logran aproximar relaciones no lineales en procesos hidro-morfodinámicos [6], [7], [8]. Aplicaciones recientes confirman esta tendencia en la predicción de campos en ríos [9], los estudios que integran aprendizaje automático con modelación hidrodinámica para mejorar la gestión de recursos hídricos [10], las revisiones sobre predicción de caudales mediante inteligencia artificial [11] y los análisis de los desafíos y oportunidades del aprendizaje automático en hidrología de gran escala [12]. Este trabajo propone un flujo híbrido (modelos 2D y entrenamiento MLP) para emular la evolución del lecho, evaluando su precisión y ahorro computacional frente a métodos convencionales en HPC, así como sus riesgos de extrapolación.

2 Metodología y establecimiento del modelo

2.1 Modelación morfodinámica numérica de referencia

La evolución del lecho se modela mediante el acoplamiento entre la hidrodinámica de lámina libre y la continuidad de sedimentos. En 2D, se utiliza el sistema TELEMAC-SISYPHE sobre mallas no estructuradas, tomando sus salidas como referencia para entrenar modelos sustitutos [5].

$$\frac{\partial h}{\partial t} + \frac{\partial(uh)}{\partial x} = 0 \quad (1) \quad \frac{\partial(uh)}{\partial x} + \frac{\partial}{\partial x} \left(uh^2 + \frac{1}{2}gh^2 \right) = -gh \frac{\partial z_b}{\partial x} - ghS_f \quad (2)$$

Donde h es la profundidad del agua, u es la velocidad en dirección del flujo, z_b es la elevación de fondo, y S_f es la velocidad de fricción. Estas ecuaciones corresponden a la aproximación bidimensional de las ecuaciones de Navier–Stokes para flujo a superficie libre, adoptadas siguiendo la formulación clásica descrita en [1] y [9]. La evolución de fondo, representada por la ecuación de Exner [1], se muestra a continuación.

$$\frac{\partial z_b}{\partial t} + \left(\frac{1}{1 - \gamma_p} \right) \frac{\partial qs}{\partial x} = 0 \quad (1D) \quad (3) \quad \frac{\partial z}{\partial t} + \left(\frac{1}{1 - p_0} \right) \left(\frac{\partial qx}{\partial x} + \frac{\partial qy}{\partial y} \right) = \frac{\partial(cps)}{\partial t} \quad (2D) \quad (4)$$

Con γ_p/p_0 como la porosidad y q como el componente del flujo de sedimentos. En TELEMAC-SISYPHE, la hidrodinámica es resuelta con las ecuaciones de flujo superficial y de turbulencia de $(\kappa-\epsilon)$, con aplicación de Manning y transporte de sedimentos en su forma semi empírica [4].

2.2 Morfodinámica en dos dimensiones en TELEMAC

Tres casos de referencia bidimensionales a escala de laboratorio se utilizaron para generar los conjuntos de datos de entrenamiento y validación de la ANN: (i) un canal recto con un obstáculo localizado en el lecho, tomado de ejemplos de TELEMAC–MASCARET descritos por Hervouet [13]; (ii) una curva de 180° basada en Yen y Lee [14], también derivada de ejemplos de TELEMAC; y (iii) un canal meándrico basado en Moghaddassi *et al.* [15]. Los casos presentan una complejidad creciente, desde ajustes en canales rectos hasta redistribuciones por curvatura y corrientes secundarias en meandros. En todos los escenarios, el acoplamiento TELEMAC-2D/SISYPHE generó las series temporales utilizadas para el entrenamiento del modelo.

2.3 Conformación de datos de entrenamiento de la red neuronal

El conjunto de datos se genera exclusivamente a partir de simulaciones numéricas con el enfoque “ $t \rightarrow t+1$ ”, donde el objetivo es predecir z_b^{t+1} a partir del estado hidráulico-morfodinámico en t . Para capturar la dependencia espacial local de la morfodinámica, se emplea un esquema de vecindad (esténcil o grafos) alrededor de cada nodo, con ventanas 37×37 , apilando variables como profundidad h , velocidad u y elevación del lecho z_b en t para predecir z_b^{t+1} en el nodo central. Este diseño equivale a aprender un operador morfodinámico local coherente con el rol de los gradientes y divergencias de transporte que controlan erosión/deposición en 2D.

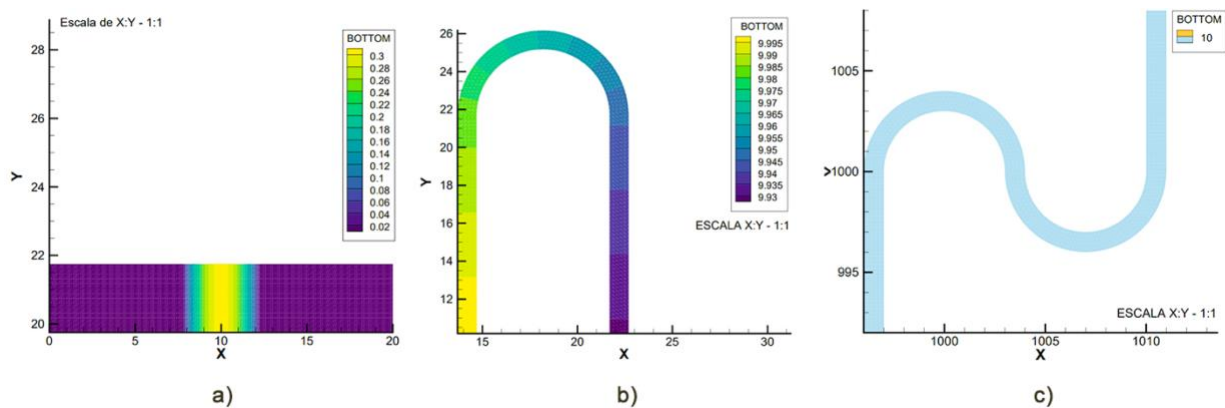


Fig. 1. Geometría inicial: a) canal recto con obstáculo, b) del canal con curva de 180° y c) del canal meándrico.

2.4 Combinaciones de entrada-salida de la RNA y reformulación adimensional

Una contribución clave es la construcción y evaluación sistemática de combinaciones de variables de entrada (C1–C7) y la reinterpretación de combinaciones bidimensionales previas de Kaveh *et al.* [4] en grupos adimensionales para mejorar la generalización física [5].

$$C4 = \left[\begin{matrix} \left(\frac{Z}{y_n}\right)_{i,j}^t, \left(\frac{Z}{y_n}\right)_{i-1,j}^t, \left(\frac{Z}{y_n}\right)_{i,j-1}^t, \left(\frac{U}{u_*}\right)_{i,j}^t, \left(\frac{U}{u_*}\right)_{i-1,j}^t, \left(\frac{U}{u_*}\right)_{i,j-1}^t, \left(\frac{H}{B}\right)_{i,j}^t, \left(\frac{H}{B}\right)_{i-1,j}^t, \left(\frac{H}{B}\right)_{i,j-1}^t \\ \left(\frac{Z}{y_n}\right)_{i,j}^{t-1}, \left(\frac{Z}{y_n}\right)_{i-1,j}^{t-1}, \left(\frac{Z}{y_n}\right)_{i,j-1}^{t-1}, \left(\frac{U}{u_*}\right)_{i,j}^{t-1}, \left(\frac{U}{u_*}\right)_{i-1,j}^{t-1}, \left(\frac{U}{u_*}\right)_{i,j-1}^{t-1}, \left(\frac{H}{B}\right)_{i,j}^{t-1}, \left(\frac{H}{B}\right)_{i-1,j}^{t-1}, \left(\frac{H}{B}\right)_{i,j-1}^{t-1} \end{matrix} \right] \quad (5)$$

$$C5 = \left[\left(\frac{Z}{y_n}\right)_{i,j}^t, \left(\frac{Z}{y_n}\right)_{i-1,j}^t, \left(\frac{Z}{y_n}\right)_{i,j-1}^t, \left(\frac{U}{u_*}\right)_{i,j}^t, \left(\frac{U}{u_*}\right)_{i-1,j}^t, \left(\frac{U}{u_*}\right)_{i,j-1}^t, \left(\frac{H}{B}\right)_{i,j}^t, \left(\frac{H}{B}\right)_{i-1,j}^t, \left(\frac{H}{B}\right)_{i,j-1}^t, \left(\frac{Z}{y_n}\right)_{i,j}^{t-1}, \right. \\ \left. \left(\frac{Z}{y_n}\right)_{i-1,j}^{t-1}, \left(\frac{Z}{y_n}\right)_{i,j-1}^{t-1}, \left(\frac{U}{u_*}\right)_{i,j}^{t+1}, \left(\frac{U}{u_*}\right)_{i-1,j}^{t+1}, \left(\frac{U}{u_*}\right)_{i,j-1}^{t+1}, \left(\frac{H}{B}\right)_{i,j}^{t-1}, \left(\frac{H}{B}\right)_{i-1,j}^{t-1}, \left(\frac{H}{B}\right)_{i,j-1}^{t-1} \right] \quad (6)$$

2.5 Modelos MLP y protocolo de entrenamiento

Los modelos sustitutos se implementan mediante redes MLP, evaluando funciones de activación (ReLU, tanh, Radbas) y el optimizador AdamW. Para asegurar la estabilidad, se aplica normalización Min-Max y particiones de entrenamiento/validación/prueba. En 2D, se emplea una arquitectura compacta de dos capas ocultas que prioriza la velocidad de inferencia, trasladando el costo computacional a la generación de datos y al entrenamiento.

Formalmente, la red aprende una función no lineal $f(x; W, b)$ que aproxima el operador morfodinámico local a partir del estado hidráulico-morfológico x . Para una red con L capas ocultas, la propagación hacia adelante se expresa como se muestra en la ecuación (5), donde $h^{(l)}$ denota la activación de la capa l , $W^{(l)}$ y $b^{(l)}$ son la matriz de pesos y el vector de sesgos asociados, y σ es la función de activación no lineal aplicada elemento a elemento [8].

$$h^{(l)} = \sigma(W^{(l)} h^{(l-1)} + b^{(l)}), \quad l = 1, \dots, L \quad (7)$$

Los parámetros $\{W^{(l)}, b^{(l)}\}$ se ajustan minimizando la función de pérdida cuadrática media sobre el conjunto de entrenamiento, mediante descenso de gradiente estocástico con la variante AdamW.

2.6 Métricas de evaluación del modelo

La validación estadística del emulador se realiza comparando los valores predichos \hat{y}_i con los de referencia y_i obtenidos de TELEMAT-SISYPHE. Se utilizan tres indicadores ampliamente aceptados en la modelación hidrológica [8]: el error cuadrático medio (RMSE), el error absoluto medio (MAE) y el coeficiente de determinación R^2 . El RMSE penaliza errores grandes

en unidades físicas, el MAE mide el error promedio y R^2 la varianza explicada. Estos índices se evalúan en el conjunto de prueba y se complementan con mapas de diferencia espacial para identificar posibles sesgos locales.

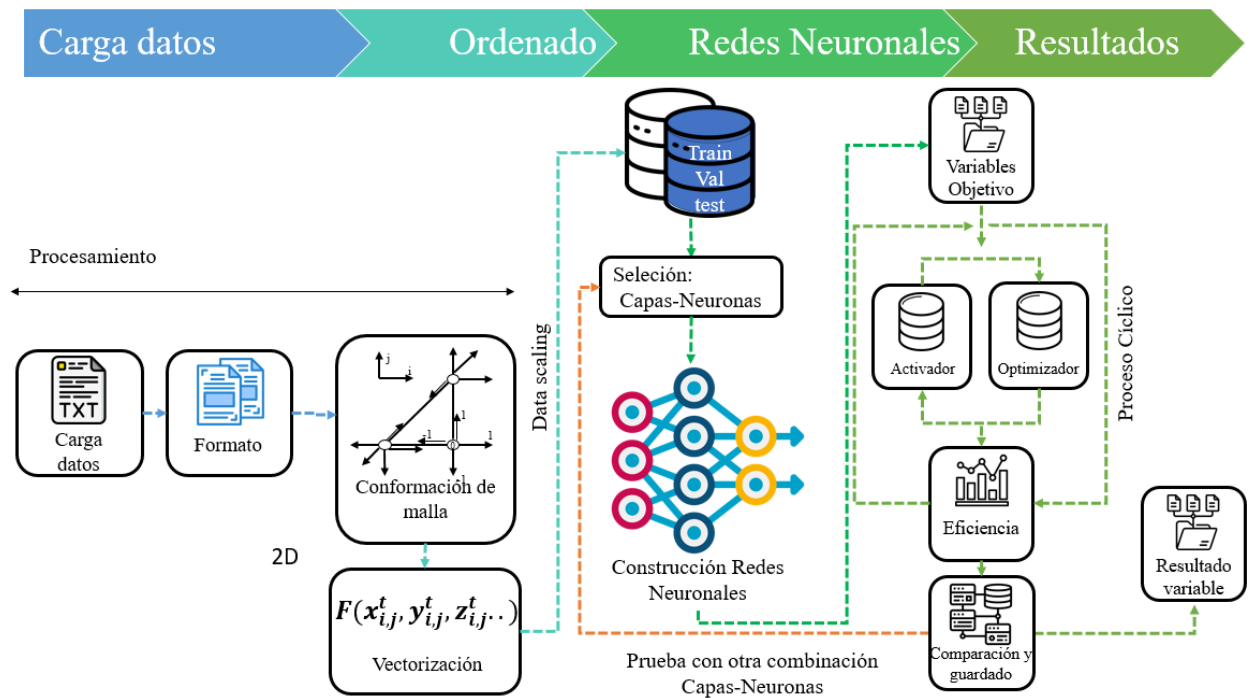


Fig. 2. Diagrama de flujo de red neuronal artificial para predicción de evolución en dos dimensiones.

Los resultados reportan que el caso del río meándrico de referencia 2D evaluó 7 combinaciones con diferentes funciones de activación y optimizadores (Tabla). La combinación con mejor desempeño (C4 y C5) utiliza la activación Radbas y el optimizador AdamW, alcanzando $R = 0.999391$ con $RMSE = 8.249 \times 10^{-4}$ en 22 épocas. El mejor desempeño estadístico no es proporcional a la velocidad de convergencia, lo que subraya la necesidad de comparar arquitecturas de forma controlada.

Tabla I. Resultados de evaluación de combinación C4 para caso de río Meándrico

Activador	Optimizador	Épocas	R	MAE	RMSE	MAE
sigmoid	adamw	34	0.999315	0.004835	0.009995	0.001042

tanh	amsgrad	18	0.999364	0.003882	0.009453	0.000837
tanh	adam	20	0.999363	0.004788	0.009592	0.001032
relu	adam	15	0.99937	0.00478	0.009651	0.00103
relu	adamw	19	0.999365	0.004727	0.009757	0.001019
relu	amsgrad	38	0.999323	0.003911	0.009807	0.000843
relu	adamw	16	0.999354	0.005022	0.009833	0.001082
radbas	amsgrad	16	0.999303	0.00387	0.009892	0.000834
sigmoid	amsgrad	81	0.999311	0.004229	0.009947	0.000911
radbas	adamw	22	0.999391	0.003415	0.008249	0.000736
sigmoid	adam	24	0.999335	0.004791	0.010043	0.001033
radbas	adam	16	0.999266	0.004887	0.010809	0.001053
tanh	sgd	200	0.998573	0.007007	0.014454	0.00151
radbas	sgd	151	0.998388	0.006837	0.015086	0.001474
relu	sgd	200	0.998176	0.008059	0.016916	0.001737
sigmoid	sgd	200	0.990905	0.023056	0.037767	0.004969

3. Evaluación y resultados: precisión, patrones morfológicos y consistencia

En 2D, los mapas de elevación del lecho predichos reproducen los patrones de erosión y deposición obtenidos con TELEMAC-SISYPHE, incluyendo asimetrías asociadas a la geometría (p. ej., en curvatura). Por ejemplo, para el río meándrico (último tiempo 432,000 s), el estudio reporta $RMSE \approx 4.90 \times 10^{-4} - 4.91 \times 10^{-4}$ m, con correlación cercana a 1, y diferencias espaciales típicamente del orden de milésimas [5]. Más allá del valor global de RMSE, el análisis de mapas de diferencia es crítico: permite verificar ausencia de sesgos sistemáticos (p. ej., sobre erosión en márgenes o depósito artificial), lo cual es el criterio práctico de consistencia morfológica frente al modelo físico.

Desde el punto de vista computacional, la MLP actúa como un acelerador del proceso morfológico al sustituir los cálculos iterativos del transporte de sedimentos por una

aproximación aprendida, reduciendo de forma importante los tiempos de simulación asociados a la morfodinámica del lecho.

En este trabajo, TELEMAC y el módulo SISYPHE actualizan el fondo cada $3\Delta t$, dado que la evolución morfológica ocurre en escalas temporales más lentas que las hidráulicas. Una vez entrenada la red, cada actualización del campo morfológico puede obtenerse en segundos, con mayor eficiencia al ejecutar TensorFlow en GPU, frente a una simulación bidimensional convencional.

La MLP optimiza el cálculo morfodinámico mediante operaciones matriciales simples, manteniendo la consistencia con los resultados de TELEMAC sin requerir las iteraciones del modelo numérico. Según la Figura 4, el tiempo en CPU para el canal meándrico (1 h 17 min) disminuye drásticamente al aplicar la red neuronal, ya que el costo principal se desplaza al entrenamiento previo y no a la fase de evaluación.

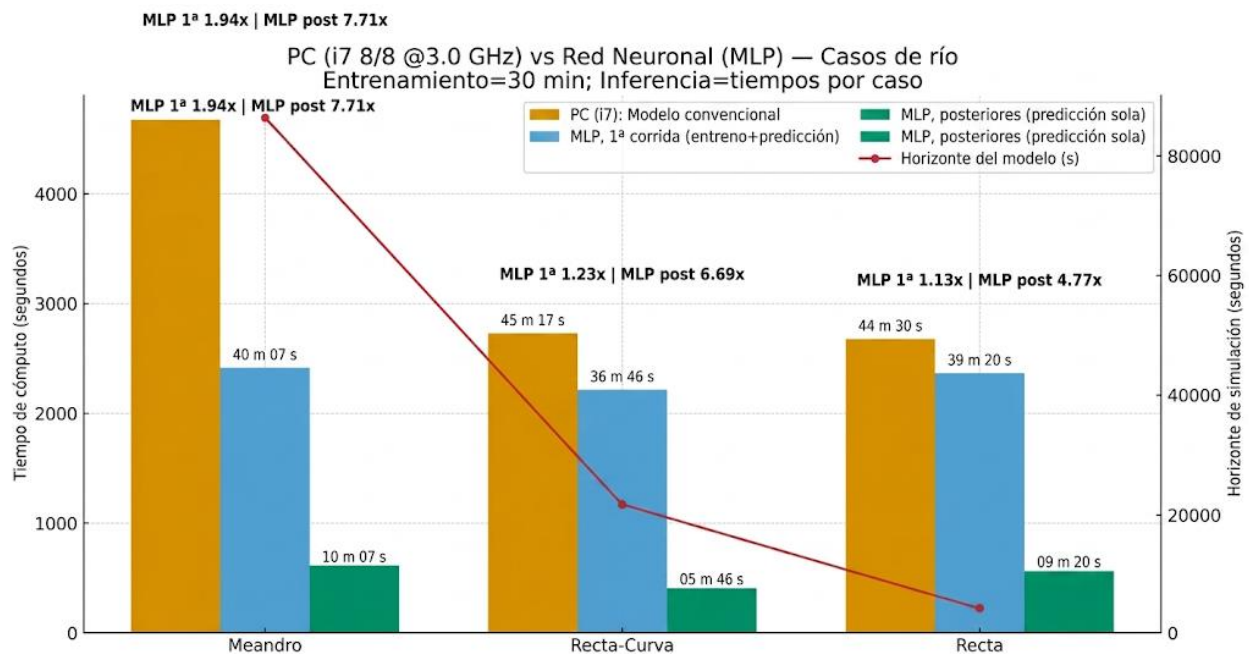


Fig. 4. Comparación de eficiencia computacional de los casos de estudio.

4. Conclusión

Una estrategia híbrida, como la modelación morfodinámica 2D para generar datos y MLP como sustituto, preserva la estructura espaciotemporal del lecho con $RMSE \approx 4.9 \times 10^{-4}$ m y reduce el tiempo de evaluación de horas a minutos. La comparación TELEMAC-MLP debe interpretarse como emulación del operador numérico dentro del dominio de entrenamiento: la RNA no impone explícitamente conservación tipo Exner, pero, al aprender de soluciones físicas, reproduce patrones de erosión y deposición sin sesgos evidentes. Aun así, para una aplicación en escenarios reales, el método actual presenta limitaciones concretas. El modelo se desarrolló bajo geometrías y caudales controlados; por tanto, carece de pruebas en condiciones extremas o de flujo no permanente propios de la naturaleza. Además, el cálculo se restringe al transporte de carga de fondo y omite el transporte en suspensión. Estructuralmente, la arquitectura MLP puede ser insuficiente para captar dependencias espaciotemporales complejas, donde redes convolucionales o recurrentes serían más aptas. El esquema actual carece de paralelización o implementación en lenguajes óptimos (como C o plataformas HPC) para dominios extensos. Además, la precisión puede degradarse fuera del rango entrenado, por lo que se recomienda diversificar el conjunto de datos e integrar restricciones físicas para mejorar la generalización.

Referencias

- [1] M. Garcia, Ed., *Sedimentation Engineering: Processes, Measurements, Modeling, and Practice*. Reston, VA, USA: American Society of Civil Engineers, 2008. doi: 10.1061/9780784408148.
- [2] E. Meyer-Peter and R. Muller, "Formulas for Bed-Load transport," in *Proceedings of 2nd meeting of the International Association for Hydraulic Structures Research*, 1948. Accessed: Oct. 20, 2025. [Online]. Available: <https://repository.tudelft.nl/record/uuid:4fda9b61-be28-4703-ab06-43cdc2a21bd7>
- [3] L. C. van Rijn, *Principles of Sediment Transport in Rivers, Estuaries and Coastal Seas*. Aqua Publications, 1993. [Online]. Available: <https://books.google.com.mx/books?id=gGIYAQAIAAJ>

- [4] K. Kaveh, "Development of Data Driven Models for Hydromorphology and Sediment Transport," Tesis doctoral. Technische Universität München, 2019. Accessed: Oct. 20, 2025. [Online]. Available: <https://mediatum.ub.tum.de/node?id=1451898>
- [5] K. D. A. Segales, "Aplicación De Técnicas De Aprendizaje De Máquina Para El Análisis Morfológico De Ríos," Tesis de licenciatura, Universidad Nacional Autónoma de México, México, 2025.
- [6] A. W. Minns, "Hydrological Modelling in a Hydroinformatics Context," in *Distributed Hydrological Modelling*, M. B. Abbott and J. C. Refsgaard, Eds., Dordrecht: Springer Netherlands, 1996, pp. 297–312. doi: 10.1007/978-94-009-0257-2_16.
- [7] C. W. Dawson and R. L. Wilby, "A comparison of artificial neural networks used for river forecasting," *Hydrology and Earth System Sciences Discussions*, vol. 3, no. 4, pp. 529–540, 1999.
- [8] R. Abraham, P. E. Kneale, and L. M. See, Eds., *Neural Networks for Hydrological Modeling*, CRC Press, 2004. doi: 10.1201/9780203024119.
- [9] X. Yan, F. Du, T. Zhang, Q. Cui, Z. Zhu, and Z. Song, "Predicting the Flow Fields in Meandering Rivers with a Deep Super-Resolution Convolutional Neural Network," *Water*, vol. 16, no. 3, p. 425, Jan. 2024, doi: 10.3390/w16030425.
- [10] S. R. O. Marshall, T.-N.-D. Tran, M. R. Tapas, and B. Q. Nguyen, "Integrating artificial intelligence and machine learning in hydrological modeling for sustainable resource management," *International Journal of River Basin Management*, pp. 1–17, Mar. 2025, doi: 10.1080/15715124.2025.2478280.
- [11] J. G. Gacu, C. E. F. Monjardin, R. G. T. Mangulabnan, and J. C. F. Mendez, "Application of Artificial Intelligence in Hydrological Modeling for Streamflow Prediction in Ungauged Watersheds: A Review," *Water*, vol. 17, no. 18, p. 2722, Sep. 2025, doi: 10.3390/w17182722.
- [12] L. Slater *et al.*, "Challenges and opportunities of ML and explainable AI in large-sample hydrology," *Phil. Trans. R. Soc. A*, vol. 383, no. 2302, p. 20240287, Jul. 2025, doi: 10.1098/rsta.2024.0287.

- [13] J. Hervouet, *Hydrodynamics of Free Surface Flows: Modelling with the finite element method*, 1st ed. Wiley, 2007. doi: 10.1002/9780470319628.
- [14] C. Yen and K. T. Lee, "Bed Topography and Sediment Sorting in Channel Bend with Unsteady Flow," *J. Hydraul. Eng.*, vol. 121, no. 8, pp. 591–599, Aug. 1995, doi: 10.1061/(ASCE)0733-9429(1995)121:8(591).
- [15] N. Moghaddassi, S. H. Musavi-Jahromi, M. Vaghefi, and A. Khosrojerdi, "Effect of Mean Velocity-to-Critical Velocity Ratios on Bed Topography and Incipient Motion in a Meandering Channel: Experimental Investigation," *Water*, vol. 13, no. 7, p. 883, Mar. 2021, doi: 10.3390/w13070883.