

## **Evolución de los modelos de Deep Learning para el pronóstico de caudales en cuencas, 2026**

### **Evolution of Deep Learning models for forecasting flow rates in basins, 2026**

**Wilber Samuel Vargas-Crispin**

Universidad Nacional de Huancavelica, Perú

E-mail: [wilber.vargas@unh.edu.pe](mailto:wilber.vargas@unh.edu.pe) ORCID: <https://orcid.org/0000-0001-9904-6516>

**Edwin Montes-Raymundo**

Universidad Nacional de Huancavelica, Perú

E-mail: [edwin.montes@unh.edu.pe](mailto:edwin.montes@unh.edu.pe) ORCID: <https://orcid.org/0000-0003-3824-4396>

**José Carlos Yalli-Raymundo**

Universidad Nacional de Huancavelica, Perú

E-mail: [jose.yalli@unh.edu.pe](mailto:jose.yalli@unh.edu.pe) ORCID: <https://orcid.org/0009-0007-6558-7139>

**Omar Caballero-Sánchez**

Universidad Nacional de Huancavelica, Perú

E-mail: [omar.caballero@unh.edu.pe](mailto:omar.caballero@unh.edu.pe) ORCID: <https://orcid.org/0000-0002-8126-3835>

**Kevin Antony Vargas-Crispin**

Universidad Nacional de Huancavelica, Perú

E-mail: [varkevin@proton.me](mailto:varkevin@proton.me) ORCID: <https://orcid.org/0009-0005-1999-2235>

#### **Resumen**

El pronóstico de caudales es una herramienta crucial para la administración de los recursos hídricos, la reducción de riesgos de inundaciones y la planificación de sistemas hidráulicos. En las últimas décadas, las técnicas de predicción han avanzado de modelos hidrológicos físicos y conceptuales hacia métodos fundamentados en datos, con un enfoque especialmente fuerte en técnicas de Aprendizaje Automático (ML) y Aprendizaje Profundo (DL). De la revisión de los precedentes se explora la evolución de los modelos de aprendizaje profundo aplicados a la estimación, cálculo y predicción de caudales en cuencas hidrográficas hasta la actualidad. Se han presentado numerosos progresos metodológicos, las estructuras de los modelos, las necesidades de datos y los criterios de evaluación utilizados en estudios recientes.

Se pone especial énfasis en arquitecturas híbridas y profundas, tales como Deep Belief Network (DBN), Redes Neuronales Artificiales (ANN), Regresión de Vector de Soporte (SVR) y Redes Neuronales Artificiales de Wavelet (WANN). Los resultados de estas investigaciones indican que los métodos tradicionales de aprendizaje automático son muy efectivos para



*Scientific Research Journal*

Centro de Investigación y Desarrollo Intelectual CIDI

E-ISSN: 2789-2727 / Vol. 7, Núm. 11, 03-19, Abril 2026 / [www.srjournalcidi.org](http://www.srjournalcidi.org)

<https://doi.org/10.53942/srjcdi.v7i11.309>

pronósticos a corto plazo, mientras que los modelos híbridos son más eficientes para captar la no linealidad en horizontes temporales más extensos. Por último, se abordan los retos actuales, como la falta de datos, la interpretabilidad de los modelos y la evaluación de la incertidumbre, así como nuevas tendencias que incluyen redes neuronales guiadas por la física, redes neuronales de grafos y arquitecturas de tipo mutables.

### **Palabras Clave**

Aprendizaje profundo, Pronóstico de caudales, Modelación hidrológica.

### **Abstract**

Flow forecasting is a crucial tool for water resource management, flood risk reduction, and hydraulic system planning. In recent decades, forecasting techniques have advanced from physical and conceptual hydrological models to data-driven methods, with a particularly strong focus on Machine Learning (ML) and Deep Learning (DL) techniques. This review explores the evolution of deep learning models applied to the estimation, calculation, and prediction of river flows in watersheds to date. Numerous methodological advances, model structures, data requirements, and evaluation criteria used in recent studies have been presented.

Special emphasis is placed on hybrid and deep architectures, such as Deep Belief Networks (DBN), Artificial Neural Networks (ANN), Support Vector Regression (SVR), and Wavelet Artificial Neural Networks (WANN). The results of this research indicate that traditional machine learning methods are very effective for short-term forecasts, while hybrid models are more efficient at capturing non-linearity over longer time horizons. Finally, current challenges are addressed, such as data scarcity, model interpretability, and uncertainty assessment, as well as new trends including physics-guided neural networks, graph neural networks, and mutable architectures.

### **Keywords**

Deep learning, Streamflow forecasting, Hydrological modeling.

### **Zusammenfassung**

Die Abflussvorhersage ist ein entscheidendes Instrument für das Wassermanagement, die Hochwasservorsorge und die Planung hydraulischer Systeme. In den letzten Jahrzehnten haben sich die Vorhersagetechniken von physikalischen und konzeptionellen hydrologischen Modellen hin zu datengetriebenen Methoden weiterentwickelt, wobei der Fokus insbesondere auf maschinellem Lernen (ML) und Deep Learning (DL) liegt. Dieser Artikel untersucht die Entwicklung von Deep-Learning-Modellen zur Schätzung, Berechnung und Vorhersage des Abflusses in Flussgebieten bis heute anhand einer Übersicht bisheriger Arbeiten. Zahlreiche methodische Fortschritte, Modellstrukturen, Datenanforderungen und Bewertungskriterien aus aktuellen Studien werden vorgestellt.



Ein besonderer Schwerpunkt liegt auf hybriden und tiefen Architekturen wie Deep Belief Networks (DBNs), künstlichen neuronalen Netzen (KNNs), Support Vector Regression (SVR) und Wavelet Artificial Neural Networks (WANNs). Die Ergebnisse dieser Untersuchungen zeigen, dass traditionelle Methoden des maschinellen Lernens für Kurzfristvorhersagen sehr effektiv sind, während hybride Modelle Nichtlinearitäten über längere Zeiträume effizienter erfassen. Abschließend werden aktuelle Herausforderungen wie Datenlücken, Modellinterpretierbarkeit und Unsicherheitsbewertung sowie neue Trends wie physikbasierte neuronale Netze, Graph-Neuronale Netze und veränderliche Architekturen behandelt.

### **Schlüsselwörter**

Deep Learning, Abflussvorhersage, Hydrologische Modellierung

## **1. Introducción**

La labor de pronosticar precisamente los caudales en cauces viene siendo uno de los pilares principales de la ingeniería hidrológica y la gestión de los recursos hídricos, tanta es su importancia pues es base de la planificación de estructuras vitales como presas y puentes además de ser útil para la optimización de la operación de embalses para fines hidroeléctricos y de dotación de agua, operaciones de emisión de alertas tempranas ante eventos de inundación y sequías (Kabir et al., 2019; Yang et al., 2018). A lo largo de los últimos años el modelado hidrológico se fundamentó en dos grandes líneas: los modelos conceptuales basados en el procedimiento físico y los modelos basados en datos (data-driven). Si bien los modelos físicos ofrecen una representación minuciosa del procedimiento hidrológico de cálculo, su complejidad y la necesidad de una gran cantidad de datos de entrada (topografía, usos de suelo, propiedades del suelo) tienden a limitar su aplicación, específicamente en cuencas con poca información e instrumentación (Kumanlioglu & Fistikoglu, 2019; Vilanova et al., 2020).

En contraparte a las limitaciones que se encuentran en los procesos clásicos de modelado, los modelos basados en datos, especialmente las técnicas de Inteligencia Artificial (IA), han ganado un empuje importante en los últimos años (Yaseen et al., 2015). Las redes neuronales artificiales (ANN) convirtiéndose actualmente en una herramienta popular por sus capacidades para modelar relaciones no lineales complejas sin un



conocimiento explícito de los procesos físicos subyacentes (Dolling & Varas, 2002; Chang & Chen, 1995). En las últimas décadas la evolución de los algoritmos de desarrollo han mejorado bastante desde los modelos de ANN simples hasta arquitecturas más complejas, dando lugar a la aparición del aprendizaje profundo (Deep Learning - DL), estos han sido motor de cambio para aumentar la capacidad computacional y la disponibilidad de extensos conjuntos de datos, han dado lugar al desarrollo de modelos complejos que pueden capturar patrones temporales, series, secuencias y datos especiales de alta complejidad correlacionales a serie de tiempo hidrológicas (Hong et al., 2020; Tyralis et al., 2020).

Este artículo de revisión tiene como objetivo indicar el proceso de evolución de la aplicación de los modelos de ANN hasta las complejas y actuales arquitecturas de DL, analizaremos los hitos claves de desarrollo, los modelos más importantes y las tendencias emergentes con más expectativas, basados en investigaciones previas como referencia.

## 2. Estado del arte

### 2.1. De los modelos estadísticos a las Redes Neuronales Artificiales (ANN)

Sobre la predicción de series de tiempo hidrológicas, se han utilizado modelos estadísticos como Media Móvil Integrada Autoregresiva (ARIMA) y Media Móvil Autoregresiva (ARMA) (Khairuddin et al., 2019). No obstante, estos modelos lineales son frecuentemente inadecuados para capturar la complejidad y la dinámica no lineal de la interacción entre la precipitación y la escorrentía (Tongal & Booij, 2018). La llegada de las Redes Neuronales Artificiales (ANN), específicamente del Perceptrón Multicapa (MLP), representó un progreso notable. Un MLP es capaz de aproximar cualquier función no lineal a través de una configuración de capas de neuronas conectadas, donde la información avanza de manera directa (feedforward) y los pesos se modifican utilizando algoritmos de retroalimentación (backpropagation) (Dolling & Varas, 2002; Ghazali et al., 2018).

### 2.2. Modelos Híbridos y de Ensamblaje (Hybrid and Ensemble Models)

Para aumentar la exactitud y consistencia de las predicciones, se desarrollaron modelos híbridos y de ensamblaje. Los modelos híbridos integran diversas metodologías, como una estructura conceptual con una red neuronal, para aprovechar las ventajas de



cada una. Por ejemplo, el modelo Híbrido de Datos Hidrológicos Dirigidos (HHDD) asocia el Modelo Hidrológico (HYMOD) con una ANN para optimizar las predicciones diarias de caudales (Ghaith et al., 2019). De manera análoga, la unión de la separación del flujo base con técnicas de ML, tales como Support Vector Regression (SVR), ANN y Random Forest, ha demostrado ser efectiva en la simulación de caudales y al descomponer la señal en partes más manejables (Tongal & Booij, 2018).

Por otro lado, los modelos de ensamblaje sintetizan las predicciones de múltiples modelos base para lograr una estimación final más precisa y consistente en comparación con cualquier modelo individual. Ejemplos destacados incluyen el método de aprendizaje de super-ensamble learning (Super Learner), que amalgama una decena de algoritmos de ML para la predicción diaria de caudales, demostrando ser mejor que cada algoritmo individualmente (Tyrallis et al., 2020). Otra técnica, el apilamiento, se ha utilizado para fusionar modelos como Elastic Net Regression (ENR), SVR, Random Forest (RF) y eXtreme Gradient Boosting (XGBoost) en pronósticos mensuales para cálculo de caudal para el río Yangtsé, mejorando los resultados de los modelos individuales (Li et al., 2019).

### **2.3. Modelos de Aprendizaje Profundo (Deep Learning - DL)**

El DL es un avance en las ANN, que se distingue por su estructura de redes con varias capas ocultas que tienen la capacidad de entender datos con niveles más profundos de abstracción.

#### **a. Redes Neuronales Recurrentes (RNN):**

Las redes neuronales recurrentes están creadas para manejar datos en secuencia, como los de series temporales, utilizando conexiones de retroalimentación que les proporcionan una memoria de corto alcance. Sin embargo, enfrentan el desafío del desvanecimiento del gradiente. Las Long Short-Term Memory (LSTM) se desarrollaron para abordar esta dificultad mediante un sistema complejo de compuertas que regulan el flujo de información, facilitando el aprendizaje de relaciones a largo plazo en los datos (Turlione, 2022; Hong et al., 2020). Las LSTM han llegado a ser el modelo estándar en la predicción de series temporales, para la estimación de



caudales, debido a su habilidad de captar dinámicas no lineales y la memoria del sistema hídrico (Kratzert et al., 2019; Turlione, 2022).

#### **b. Redes Neuronales Convolucionales (CNN):**

Las redes neuronales convolucionales son muy efectivas para identificar patrones locales y propiedades invariantes, especialmente en imágenes. En el ámbito temporal, se pueden utilizar CNN unidimensionales para analizar series de tiempo a fin de detectar patrones relevantes, como el impacto de un aumento en las precipitaciones. Comúnmente, se integran con LSTM en modelos CNN-LSTM, donde la CNN sirve como un extractor de atributos que alimenta la LSTM para modelar secuencias, logrando así la captura de patrones locales y dependencias a largo plazo. (Hong et al., 2020).

#### **2.4. Otras técnicas relevantes**

Además de los modelos previamente citados, se han empleado diversas técnicas de aprendizaje automático como fundamento para la transición hacia el aprendizaje profundo. Las Máquinas de Vectores de Soporte para Regresión son reconocidas por su solidez y su habilidad para generalizar, a menudo superando a las Redes Neuronales Artificiales en determinados escenarios (Maity et al., 2010; Samadianfard et al., 2019). Su optimización se ha perfeccionado a través de algoritmos metaheurísticos, como el algoritmo de optimización inspirado en la mosca de la fruta, dando lugar al modelo híbrido que parte del SVR con el algoritmo con Fly Optimización Algorithm (FOA) cuya amalgama de nombres es también conocido como FOASVR (Samadianfard et al., 2019). Los árboles de decisión y sus versiones de ensamblaje, tales como Random Forest y XGBoost, han mostrado un considerable potencial, no solo por su precisión, sino también por su aptitud para ofrecer evaluaciones de la relevancia de las variables predictivas, lo que facilita la comprensión de los elementos que influyen en el caudal (Hussain & Khan, 2020; Yang et al., 2018). Modelos como el algoritmo Model Tree (M5P) y el algoritmo de Conjunto de Reglas (M5Rule) proporcionan una mayor claridad al generar reglas o árboles de regresión (Salih et al., 2019; Mohsenzadeh Karimi et al., 2018).



### 3. Materiales y métodos

Este análisis se fundamenta en una investigación detallada de la literatura científica disponible, abarcando trabajos desde finales de los años 2000 hasta el presente. La información inicial incluye una recopilación de artículos en revistas indexadas, todos centrados en el uso de técnicas computacionales para la predicción de caudales.

El enfoque adoptado para la creación de esta revisión fue el siguiente:

- a. **Clasificación por temática:** Los estudios fueron organizados en grupos según el método de modelado más utilizado como: modelos básicos de ANN (MLP, Radial Basis Function también conocidas como RBF y las Redes Neuronales de Regresión generalizada cuyas siglas son GRNN), modelos híbridos (HHDD, Wavelet-ANN, FOASVR), modelos de ensamblaje (Super Learner, Stacking) y modelos de DL (LSTM, CNN-LSTM).
- b. **Análisis cronológico:** Se observó cómo han evolucionado las técnicas con el tiempo, identificando momentos clave y cambios entre diferentes enfoques de modelado. Se puso especial énfasis en cómo los modelos más recientes (LSTM, híbridos) superan las limitaciones de las versiones anteriores (ARIMA, ANN sencillos).
- c. **Detección de tendencias:** Se señalaron las tendencias recientes, incluyendo el uso de información satelital como el instrumento de teledetección satelital Espectro radiómetro de Imágenes de Resolución Moderada (MODIS), la incorporación de fenómenos climáticos como la Oscilación Sur-El Niño y Oscilación Decadal del Pacífico (ENSO, PDO), la evaluación de la transferencia de modelos entre cuencas y el foco en la incertidumbre en los pronósticos.
- d. **Recopilación de evidencias:** Para cada tendencia o técnica, se reunió información sobre resultados, métricas de rendimiento como: Root Mean Square Error (RMSE), Nash-Sutcliffe Efficiency (NSE) y el coeficiente de determinación ( $R^2$ ). Finalmente, las conclusiones de los estudios de caso, con el objetivo de construir un argumento convincente sobre el avance y el estado a la actualidad.

### 4. Resultados



El estudio de los textos muestra una evolución notable y constante en los diseños de predicción de caudales.

#### **4.1. La Era de los Modelos ANN y sus Primeras Mejoras**

Las investigaciones iniciales se enfocaron en mostrar la ventaja de las redes neuronales artificiales (ANN) sobre los métodos estadísticos convencionales. Dolling y Varas (2002) utilizaron un perceptrón multicapa con una estructura denominada Multi Input Multi Output (MIMO) con la siguiente estructura 30-20-7 para prever los caudales mensuales en la cuenca del río San Juan en Argentina, empleando el ENSO, la temperatura, la precipitación y datos de nieve como variables predictivas. Este modelo presentó una notable capacidad de predicción, con más del 80% de los errores siendo menores al 5%. Chang y Chen (1995) propusieron un modelo de aprendizaje basado en casos que generaba hiperrectángulos anidados para la estimación de caudales, superando en eficacia a la regresión lineal múltiple y a las reglas de inferencia difusa. Cigizoglu (2005) examinó variantes como las redes de regresión generalizada, resaltando su velocidad en el entrenamiento y su habilidad para esquivar mínimos locales.

#### **4.2. El Auge de los Modelos Híbridos y de Ensamblaje**

La búsqueda de mayor exactitud condujo al diseño de modelos híbridos. Ghaith et al. (2019) presentó el modelo HHDD, que fusiona el modelo conceptual HYMOD con una red neuronal artificial (ANN), usando las salidas del HYMOD (escorrentía superficial, flujo base, etc.) como entradas para la ANN. Este método aumentó notablemente la precisión en los pronósticos diarios de caudales en comparación con el HYMOD solo, especialmente en la estimación de caudales máximos. De igual manera, la integración de la transformada wavelet con redes neuronales y modelos de regresión resultó ser muy eficaz para abordar la no estacionariedad en las series de caudales, mejorando la exactitud de los pronósticos (Partal y Cigizoglu, 2008; Kisi, 2009).

Los modelos de ensamblaje marcan otro progreso importante. Tyrallis et al., (2020) llevaron a cabo un Super Learner que amalgamaba diez algoritmos de aprendizaje automático (entre ellos SVR, RF, XGBoost y redes neuronales artificiales) para pronosticar caudales diarios en 511 cuencas de los Estados Unidos. El Super Learner superó de manera consistente a todos los algoritmos individuales, lo que demuestra el valor de la combinación inteligente de modelos. Li et al. (2019) respaldaron esta tendencia al implementar una estrategia de apilamiento que vendría a proponer un multi modelo de integración llamado modified stacking ensemble strategy (MSES) para unir modelos como ENR, SVR, RF y XGBoost en las predicciones mensuales del río Yangtsé, aumentando la precisión en la estimación de eventos de caudales máximos.



### 4.3. La Consolidación del Deep Learning: LSTM y CNN-LSTM

La llegada de las LSTM significó un cambio fundamental. Turlione (2022) evaluó modelos densos (MLP), LSTM y un modelo LSTM de dos capas para anticipar los caudales en la cuenca del río Chambo en Ecuador. El modelo LSTM de una capa (LSTM1), que fue entrenado usando análisis de componentes principales originalmente denominado Principal Component Analysis (PCA) de los datos de entrada, superó considerablemente al MLP y a la versión del LSTM de doble capa (LSTM2), subrayando la relevancia de una adecuada selección y preparación de los datos iniciales. La habilidad de las LSTM para conservar información a largo plazo les otorga la capacidad de representar eficazmente fenómenos como el deshielo o el aporte de flujo base.

La combinación de CNN y LSTM ha avanzado las capacidades de modelado aún más. Hong et al. (2020) utilizaron modelos CNN-LSTM para predecir el caudal de entrada a la represa de Soyang en Corea del Sur. Aunque el MLP estándar logró el rendimiento más alto en general, los investigadores examinaron la fusión de modelos como: RF con el MLP y Gradient boosting (GB) y MLP con el fin de mejorar las predicciones en distintos regímenes de flujo, evidenciando que las estructuras complejas pueden beneficiarse de tácticas de combinación. A pesar de que en su investigación el CNN-LSTM no superó al MLP, su uso en otros campos indica un gran potencial para captar tanto patrones espaciales (de la cuenca) como temporales (de la serie de caudal), la tabla 1 muestra un resumen sobre la evolución de los modelos detallados:

**Tabla 1**

*Evolución de los Modelos de Pronóstico de Caudales.*

GENERACIÓN	MODELOS REPRESENTATIVOS	FORTALEZAS	DEBILIDADES/DESAFÍOS
1ra Generación Estadísticos	ARIMA, ARMA, MLR (Khairuddin et al., 2019)	Simples, interpretables, base sólida.	Incapaces de modelar No- Linealidades complejas.
2da Generación ANN Básicos	MLP, RBF, GRNN (Dolling & Varas, 2002; Cigizoglu, 2005)	Modelan No-Linealidades, flexibles.	Sobreajuste, mínimos locales, "Caja Negra".
3ra Generación Híbridos y Ensamblaje	HHDD (Ghaith et al., 2019), Wavelet-ANN (Kisi, 2009), Super Learner (Tyrallis et al., 2020), Stacking (Li et al., 2019)	Mayor precisión y robustez que modelos individuales. Mejor manejo de No- Estacionariedad.	Mayor complejidad computacional, difícil interpretación del modelo combinado.
4ta Generación Deep Learning	LSTM (Turlione, 2022), CNN- LSTM (Hong et al., 2020)	Capturan dependencias temporales a largo plazo (LSTM). Extraen características locales	Requieren grandes volúmenes de datos para entrenamiento, alto costo computacional,



---

relevantes (CNN). Altamente interpretabilidad sigue  
precisos. siendo un reto.

---

## 5. Discusión

### 5.1. El avance clave sobre la captura de la memoria de un modelo hidrológico.

La principal ventaja de los modelos de DL, y en particular las LSTM, sobre las generaciones anteriores de modelos (como los MLP estándar) es su capacidad inherente para modelar la "memoria" del sistema hidrológico de manera adaptativa. Mientras que los modelos de redes neuronales artificiales (ANN) tradicionales, como el perceptrón multicapa (MLP), se basan en una representación de la memoria de "ventana fija". Esto significa que requieren que el modelador seleccione a priori un número fijo de rezagos (lags) como entrada (ejemplo  $Q(t-1)$ ,  $Q(t-2)$ ,  $Q(t-3)$ ), las LSTM tienen la capacidad de aprender de forma interna qué datos del pasado son importantes y por cuánto tiempo conservarlos (Turlione, 2022; Kratzert et al., 2019). Es fundamental para representar adecuadamente procesos con diferentes escalas de tiempo, como la influencia del agua subterránea (flujo base) o el impacto del deshielo, que dependen de condiciones hidrológicas que pudieron haber sucedido semanas o meses antes.

### 5.2. La integración de múltiples fuentes de datos

Una tendencia importante es la inclusión de variadas y abundantes fuentes de datos. Ahora no se trata únicamente de emplear caudales anteriores. Los modelos actuales incluyen:

- a. **Datos climáticos:** La incorporación de índices de teledetección para fenómenos como el ENSO y PDO ha mostrado mejorar notablemente los pronósticos, particularmente a escalas estacionales, al captar la influencia de fenómenos climáticos de gran escala en la hidrología local (Yang et al., 2018; Kabir et al., 2019).
- b. **Datos de satélite:** La utilización de productos satelitales como MODIS (Indicadores de nieve, índice de densidad de vegetación (LAI) y la cobertura de nieve) ofrece información crucial sobre la condición de la vegetación y la acumulación de nieve en cuencas con limitaciones de datos in-situ, aumentando la exactitud de las predicciones (Ghazali et al., 2018).
- c. **Selección eficiente de predictores:** El uso de métodos como PCA (Turlione, 2022), regresión con penalización (LASSO) y Optimización por Enjambre de Particular (PSO)-ANN (Alizadeh et al., 2020) facilita la reducción de la dimensionalidad y la identificación de los predictores más significativos, aumentando la efectividad y la exactitud del modelo.



### 5.3. Los avances y desafíos hasta la actualidad

A pesar de los progresos, continúan existiendo desafíos importantes que definirán las áreas de investigación hasta la actualidad.

- a. **Pronóstico de eventos extremos:** Los modelos de DL, al igual que sus predecesores, frecuentemente subestiman la subida de caudales durante épocas de máximas avenidas. Esto se debe a que los eventos extremos son, por su naturaleza, infrecuentes y están poco representados en los datos de entrenamiento. Una alternativa viable es crear modelos híbridos que integren DL con modelos físicos hidrológicos para replicar la producción de escorrentía en esos eventos (Li et al., 2019), o implementar técnicas de aumento de datos para fortalecer el conjunto de entrenamiento con eventos sintéticos realistas.
- b. **Incertidumbre y transferibilidad:** Es crucial medir la incertidumbre de las predicciones para facilitar la toma de decisiones. La aplicación de técnicas como el Ensamblaje Bayesiano (BMA) ha demostrado ser útil para integrar modelos y ofrecer pronósticos probabilísticos, disminuyendo la incertidumbre (Meira- Neto et al., 2018). Un reto adicional es la capacidad de transferir modelos entrenados de una cuenca a otra (Vilanova et al., 2020). Los modelos de DL que han sido entrenados en numerosas cuencas variadas (Tyrallis et al., 2020) representan un avance alentador hacia la creación de modelos más generalizables. La transferencia de modelos ajustados en subcuencas de tamaño mediano ha demostrado un rendimiento global superior en comparación con la transferencia de modelos de cuencas extremadamente pequeñas o grandes (Vilanova et al., 2020).
- c. **Interpretabilidad:** La característica de "Caja Negra" de los modelos de DL continúa siendo un impedimento para su uso extensivo en la administración operativa. Métodos para evaluar la relevancia de las variables (como las ofrecidas por RF y XGBoost) y para ilustrar las representaciones adquiridas por las capas internas de las LSTM serán esenciales para lograr la confianza de los administradores y entender más a fondo los procesos hidrológicos subyacentes (Yang et al., 2018).
- d. **Los modelos fundacionales para la hidrología:** Se presenta con el auge y consolidación del DL y la optimización de estos métodos, la oportunidad de crear amplios modelos fundamentales de DL, pre-entrenados con información de cientos o miles de cuencas alrededor del planeta. Estos modelos podrían ser ajustados más adelante (fine-tuned) para cuencas particulares con datos escasos, siguiendo la tendencia observada en otras áreas como el procesamiento de lenguaje natural. Los avances de Kratzert et al. (2019) y Tyrallis et al. (2020) se dirigen hacia esta línea de investigación.

## 6. Conclusiones



El desarrollo de los modelos para pronosticar caudales ha sido motivado por la necesidad de entender la complejidad, No Linealidad y dinámica temporal de los procesos hidrológicos. A partir de los modelos estadísticos lineales, se progresó hacia las ANN, que presentaron una primera alternativa para el modelado No Lineal. La nueva ola de innovación introdujo los modelos híbridos y de ensamblaje, que aumentaron la precisión y consistencia al unir las ventajas de diversas técnicas. En la actualidad, los modelos de DL, particularmente las LSTM y sus variantes, constituyen la mejora sustancial a la técnica, evidenciando una habilidad superior para captar dependencias temporales a largo plazo y para combinar múltiples fuentes de datos, desde índices climáticos hasta imágenes satelitales.

Hacia el año 2026, se anticipa que las investigaciones se concentran en abordar los desafíos restantes: optimizar la precisión en la predicción de eventos extremos, crear metodologías sólidas para cuantificar la incertidumbre, investigar la transferibilidad de modelos entre cuencas y potenciar la interpretabilidad de las arquitecturas de DL. La dirección sugiere el desarrollo de modelos cada vez más robustos y generalizables, capaces de aprender a partir de extensos volúmenes de datos diversos, estableciendo el aprendizaje profundo como una herramienta esencial y fiable para la hidrología operativa del mañana.



### **7. Declaración de contribución de autoría: CREdiT**

Wilber Samuel Vargas-Crispin y Edwin Montes-Raymundo: Conceptualización, Metodología. José Carlos Yalli-Raymundo: Redacción, borrador original. Omar Caballero-Sánchez: Resultados, Discusión. Kevin Antony Vargas-Crispin: Redacción, Conclusiones y Revisión de estilo.

### **8. Agradecimientos**

Los autores agradecen a los revisores por tomarse el tiempo y el esfuerzo necesario para revisar este artículo de revisión.

### **9. Declaración de conflicto de intereses**

Los autores declaran que no tienen intereses financieros en competencia conocidos ni relaciones personales que pudieran haber parecido influir en el trabajo reportado en este artículo.

### **10. Disponibilidad de los datos**

No se utilizaron datos para la investigación descrita en el artículo.



## Referencias

1. Alizadeh, Z., Yazdi, J., Kim, J. H., & Al-Shamiri, A. K. (2018). Assessment of machine learning techniques for monthly flow prediction. *Water*, 10(11), 1676. <https://doi.org/10.3390/w10111676>
2. Alizadeh, Z., Shourian, M., & Yaseen, Z. M. (2020). Simulating monthly streamflow using a hybrid feature selection approach integrated with an intelligence model. *Hydrological Sciences Journal*, 65(10), 1-14. <https://doi.org/10.1080/02626667.2020.1755436>
3. Beskow, S., de Mello, C. R., Vargas, M. M., Corrêa, L. L., Caldeira, T. L., Durães, M. F., & de Aguiar, M. S. (2016). Artificial intelligence techniques coupled with seasonality measures for hydrological regionalization of Q90 under Brazilian conditions. *Journal of Hydrology*, 541, 1406-1419. <https://doi.org/10.1016/j.jhydrol.2016.08.046>
4. Cassalho, F., Beskow, S., de Mello, C. R., de Moura, M. M., de Oliveira, L. F., & de Aguiar, M. S. (2019). Artificial intelligence for identifying hydrologically homogeneous regions: A state-of-the-art regional flood frequency analysis. *Hydrological Processes*, 33(7), 1101-1116. <https://doi.org/10.1002/hyp.13388>
5. Chang, F. J., & Chen, L. (1995). An exemplar-based learning model for hydrosystems prediction and categorization. *Journal of Hydrology*, 169(1-4), 229-241. [https://doi.org/10.1016/0022-1694\(94\)02645-9](https://doi.org/10.1016/0022-1694(94)02645-9)
6. Cigizoglu, H. K. (2005). Application of generalized regression neural networks to intermittent flow forecasting and estimation. *Journal of Hydrologic Engineering*, 10(4), 336-341. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2005\)10:4\(336\)](https://doi.org/10.1061/(ASCE)1084-0699(2005)10:4(336))
7. Corchado, J. M., & Lees, B. (2001). A hybrid case-based model for forecasting. *Applied Artificial Intelligence*, 15(2), 105-127. <https://doi.org/10.1080/088395101750065723>
8. Dolling, O. R., & Varas, E. A. (2002). Artificial neural networks for streamflow prediction. *Journal of Hydraulic Research*, 40(5), 547-554. <https://doi.org/10.1080/00221680209499899>
9. Ghaith, M., Siam, A., Li, Z., & El-Dakhkhni, W. (2020). Hybrid hydrological data-driven approach for daily streamflow forecasting. *Journal of Hydrologic Engineering*, 25(2), 04019063. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001866](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001866)
10. Ghazali, M., Honar, T., & Nikoo, M. R. (2018). A fusion-based neural network methodology for monthly reservoir inflow prediction using MODIS products. *Hydrological Sciences Journal*, 63(15-16), 1-21. <https://doi.org/10.1080/02626667.2018.1558365>
11. Hong, J., Lee, S., Bae, J. H., Lee, J., Park, W. J., Lee, D., Kim, J., & Lim, K. J. (2020). Development and evaluation of the combined machine learning models for the prediction of dam inflow. *Water*, 12(10), 2927. <https://doi.org/10.3390/w12102927>



12. Hussain, D., & Khan, A. A. (2020). Machine learning techniques for monthly river flow forecasting of Hunza River, Pakistan. *Earth Science Informatics*, 13, 1-10. <https://doi.org/10.1007/s12145-020-00450-z>
13. Kabir, S., Patidar, S., & Pender, G. (2019). Investigating capabilities of machine learning techniques in forecasting streamflow. *Proceedings of the Institution of Civil Engineers - Water Management*, 173(2), 1-16. <https://doi.org/10.1680/jwama.19.00001>
14. Khairuddin, N., Aris, A. Z., Elshafie, A., Narany, T. S., Ishak, M. Y., & Isa, N. M. (2019). Efficient forecasting model technique for river stream flow in tropical environment. *Urban Water Journal*, 16(8), 1-10. <https://doi.org/10.1080/1573062X.2019.1637906>
15. Kisi, O. (2010). Daily suspended sediment estimation using neuro-wavelet models. *International Journal of Earth Sciences*, 99, 1471-1482. <https://doi.org/10.1007/s00531-009-0460-2>
16. Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., & Nearing, G. (2019). Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. *Hydrology and Earth System Sciences*, 23(12), 5089-5110. <https://doi.org/10.5194/hess-23-5089-2019>
17. Kumanlioglu, A. A., & Fistikoglu, O. (2019). Performance enhancement of a conceptual hydrological model by integrating artificial intelligence. *Journal of Hydrologic Engineering*, 24(11), 04019047. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001850](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001850)
18. Li, Y., Liang, Z., Hu, Y., Li, B., Xu, B., & Wang, D. (2019). A multi-model integration method for monthly streamflow prediction: modified stacking ensemble strategy. *Journal of Hydroinformatics*, 22(2), 1-18. <https://doi.org/10.2166/hydro.2019.066>
19. Maity, R., Bhagwat, P. P., & Bhatnagar, A. (2010). Potential of support vector regression for prediction of monthly streamflow using endogenous property. *Hydrological Processes*, 24(7), 917-923. <https://doi.org/10.1002/hyp.7535>
20. Meira Neto, A. A., Oliveira, P. T. S., Rodrigues, D. B. B., & Wendland, E. (2018). Improving streamflow prediction using uncertainty analysis and Bayesian model averaging. *Journal of Hydrologic Engineering*, 23(5), 05018004. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001639](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001639)
21. Mohsenzadeh Karimi, S., Karimi, S., & Poorrajabali, M. (2018). Forecasting monthly streamflows using heuristic models. *ISH Journal of Hydraulic Engineering*, 26(1), 1-9. <https://doi.org/10.1080/09715010.2018.1516575>
22. Partal, T., & Cigizoglu, H. K. (2008). Estimation and forecasting of daily suspended sediment data using wavelet-neural networks. *Journal of Hydrology*, 358(3-4), 317-331. <https://doi.org/10.1016/j.jhydrol.2008.06.013>



23. Rozos, E. (2020). A methodology for simple and fast streamflow modelling. *Hydrological Sciences Journal*, 65(5), 1-12. <https://doi.org/10.1080/02626667.2020.1728475>
24. Salih, S. Q., Sharafati, A., Khosravi, K., Faris, H., Kisi, O., Tao, H., Ali, M., & Yaseen, Z. M. (2019). River suspended sediment load prediction based on river discharge information: application of newly developed data mining models. *Hydrological Sciences Journal*, 65(4), 1-18. <https://doi.org/10.1080/02626667.2019.1703186>
25. Samadianfard, S., Jarhan, S., Salwana, E., Mosavi, A., Shamshirband, S., & Akib, S. (2019). Support vector regression integrated with fruit fly optimization algorithm for river flow forecasting in Lake Urmia Basin. *Water*, 11(9), 1934. <https://doi.org/10.3390/w11091934>
26. Shamshirband, S., Hashemi, S., Salimi, H., Samadianfard, S., Asadi, E., Shadkani, S., Kargar, K., Mosavi, A., Nabipour, N., & Chau, K. W. (2020). Predicting Standardized Streamflow index for hydrological drought using machine learning models. *Engineering Applications of Computational Fluid Mechanics*, 14(1), 339-350. <https://doi.org/10.1080/19942060.2020.1715844>
27. Tao, H., Al-Sulttani, A. O., Salih Ameen, A. M., Ali, Z. H., Al-Ansari, N., Salih, S. Q., & Mostafa, R. R. (2020). Training and testing data division influence on hybrid machine learning model process: application of river flow forecasting. *Complexity*, 2020, 8844367. <https://doi.org/10.1155/2020/8844367>
28. Tongal, H., & Booij, M. J. (2018). Simulation and forecasting of streamflows using machine learning models coupled with base flow separation. *Journal of Hydrology*, 564, 266-282. <https://doi.org/10.1016/j.jhydrol.2018.07.004>
29. Toprak, Z. F., & Cigizoglu, H. K. (2008). Predicting longitudinal dispersion coefficient in natural streams by artificial intelligence methods. *Hydrological Processes*, 22(20), 4106-4129. <https://doi.org/10.1002/hyp.7012>
30. Turlione, A. R. (2022). *Modelado del caudal natural en la cuenca hidrográfica Chambo con redes neuronales* [Trabajo de Fin de Máster, Facultad de Ciencias]. Ucrea. <https://repositorio.unican.es/xmlui/handle/10902/27063>
31. Tyrallis, H., Papacharalampous, G., & Langousis, A. (2020). Super ensemble learning for daily streamflow forecasting: large-scale demonstration and comparison with multiple machine learning algorithms. *Neural Computing and Applications*, 33, 3053-3068. <https://doi.org/10.1007/s00521-020-05172-3>
32. Vilanova, R. S., Zanetti, S. S., & Cecílio, R. A. (2020). Artificial neural networks–based model parameter transfer in streamflow simulation of Brazilian Atlantic Rainforest watersheds. *Journal of Hydrologic Engineering*, 25(7), 05020013. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001947](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001947)



33. Yang, T., Asanjan, A. A., Welles, E., Gao, X., Sorooshian, S., & Liu, X. (2018). Developing reservoir monthly inflow forecasts using artificial intelligence and climate phenomenon information. *Water Resources Research*, 54(2), 1117-1138. <https://doi.org/10.1002/2017WR020482>
34. Yaseen, Z. M., El-Shafie, A., Jaafar, O., Afan, H. A., & Sayl, K. N. (2015). Artificial intelligence based models for stream-flow forecasting: 2000–2015. *Journal of Hydrology*, 530, 829-844. <https://doi.org/10.1016/j.jhydrol.2015.10.038>
35. Yaseen, Z. M., Jaafar, O., Deo, R. C., Kisi, O., Adamowski, J., Quilty, J., & El-Shafie, A. (2016). Stream-flow forecasting using extreme learning machines: A case study in a semi-arid region in Iraq. *Journal of Hydrology*, 542, 603-614. <https://doi.org/10.1016/j.jhydrol.2016.09.035>

