

Modelamiento de procesos hidrológicos aplicando técnicas de inteligencia artificial: una revisión sistemática de la literatura

Modeling of hydrological processes applying artificial intelligence techniques: a systematic literature review

Willians Franklin Rafael-Miñope¹ ; Pedro Víctor Raúl Vilcherres-Lizárraga¹ ; Sócrates Pedro Muñoz-Pérez¹ ;
Victor Alexci Tuesta-Montez¹ ; Heber Ivan Mejía-Cabrera¹

¹Ingeniería Civil, Universidad Señor de Sipán, Pimentel, Perú. minopewf@crece.uss.edu.pe, vlizarragapedro@crece.uss.edu.pe, msocrates@crece.uss.edu.pe, vtuesta@crece.uss.edu.pe, hmejia@crece.uss.edu.pe

Fecha de recepción: 13 de julio de 2021. Fecha de aprobación: 10 de diciembre de 2021

Resumen- El campo de la hidrología es una de las ciencias que se enfoca en el estudio, la planificación y la cuantificación del recurso hídrico, generando una magnitud significativa de datos, los cuales son indispensables en la rama de la ingeniería civil. Actualmente dichos datos son analizados por una variedad de técnicas, que entre las predominantes son las de inteligencia artificial (IA) exclusivamente aplicadas al modelamiento de procesos hidrológicos como lluvia-escorrentía, inundaciones, sequías, evapotranspiración, nivel de lagos y predicción de caudales. El presente documento realizó una revisión sistemática de la literatura publicadas entre los años 2015 al 2021 en las diversas bases de datos como, Scopus, Springer Link, EBSCOhost, SciELO y ScienceDirect. Para ello se estableció un proceso de protocolo en el cual se introduce la base de datos seleccionada, definición de términos de búsqueda y filtros de selección. En efecto después de considerar el proceso de protocolo se obtuvieron 50 artículos indexados además de 4 artículos y 1 libro de páginas web. Como consecuencia se encontró que las redes neuronales artificiales (RNA) son las técnicas más utilizadas para el modelamiento de procesos hidrológicos donde con innovadores lenguajes de programación se pueden codificar con mucha mayor versatilidad. A la fecha el uso de RNA se las está implementando con otras técnicas para

generar modelos híbridos que permiten obtener mejores estimaciones.

Palabras clave- Modelamiento hidrológico; inteligencia artificial; aprendizaje automático; red neuronal; evapotranspiración; escorrentía y precipitación.

Abstract- The field of hydrology is one of the sciences that focuses on the study, planning and quantification of water resources, generating a significant amount of data, which are indispensable in the branch of civil engineering. Currently these data are analyzed by a variety of techniques, among the predominant ones are artificial intelligence (IA) exclusively applied to the modeling of hydrological processes such as rain-runoff, floods, droughts, evapotranspiration, lake level and flow prediction. This document carried out a systematic review of the literature published between the years 2015 to 2021 in the various databases such as Scopus, Springer Link, EBSCOhost, SciELO and ScienceDirect. For this, a protocol process was established in which the selected database, definition of search terms and selection filters are entered. Indeed, after considering the protocol process, 50 indexed articles were obtained in addition to 4 articles and 1 book of web pages. As a consequence, it was found that artificial neural networks (ANNs) are the most widely used techniques for

Citar este artículo como: W. Rafael Miñope, P. Vilcherres Lizárraga, S. Muñoz Pérez, V. Tuesta Monteza, y H. Mejía Cabrera, Modelamiento de procesos hidrológicos aplicando técnicas de inteligencia artificial: una revisión sistemática de la literatura, ITECKNE, 19 (1), 2022 pp. 46 - 60. Doi: <https://doi.org/10.15332/iteckne.v19i1.2645>

modeling hydrological processes where, with innovative programming languages, they can be encoded with much greater versatility. To date, the use of RNA is being implemented with other techniques to generate hybrid models that allow obtaining better estimates.

Keywords- Hydrological modeling; artificial intelligence; machine learning; neural network; evapotranspiration; runoff and rainfall.

1. INTRODUCCIÓN

Generalmente, los métodos hidrológicos e hidráulicos requieren diferentes parámetros, mientras que la aplicación de técnicas de inteligencia artificial (IA) simplifica la cantidad de datos [1]. Asimismo, la sostenibilidad ambiental es una de las principales preocupaciones del desarrollo urbano y rural afectando al suelo y otras esferas del planeta, que al respecto [2] comparte esta misma teoría detallando algunos avances ejecutados por el equipo de alta montaña de Asia (HIMAT, del inglés high mountain Asia team), equipo que está al mando de la NASA, que debido a los cambios en la hidrología no solo afectan la seguridad del agua, sino que también a la energía, la industria, el transporte y los ecosistemas, para ello HIMAT destaca los desafíos y evalúa estos impactos, asociando e integrando modelos climáticos, la hidrología, la energía hidroeléctrica y un análisis económico. En esta misma línea [3] realiza una evaluación de los acontecimientos pasados y actuales con respecto a las amenazas del suelo a saber, la erosión y contaminación, que a través del tiempo se ha venido gestionado medidas de previsión para reducir dichos impactos, teniendo en consideración algunas preocupaciones como estrategias efectivas de conservación, la implementación de nuevas tecnologías computacionales, modelos y mediciones in situ que aportan a la gestión de recursos y el desarrollo de tecnologías verdes.

Los actores y las partes interesadas necesitan simulaciones económicas, efectivas y eficientes para predecir y evaluar los efectos en el avance para el medio ambiente, sin dejar de lado las limitaciones que esto podría conllevar [4]. Los modelos hidrológicos que trabajan con técnicas de inteligencia artificial son capaces de simular áreas de diferentes tamaños y características espaciales [5].

El modelamiento de procesos hidrológicos actualmente es fundamental, toda vez que estos van cambiando constantemente con el pasar de los días y años, así por ejemplo como refiere [6], el modelamiento de lluvia-escorrentía juega un rol fundamental en diferentes aspectos para un mejoramiento a través de una buena gestión de los recursos hídricos (RGI), beneficiando significativamente a resolver los problemas relacionados con el control de inundaciones, la protección de tierras agrícolas, etc. La estimación de lluvia-escorrentía es un proceso muy importante en hidrología, por lo general, brinda apoyo para diferentes actividades de planificación y gestión de recursos hídricos [7]. Diseñar un modelo físico para tales fenómenos es a menudo un asunto costoso y también requiere una experiencia absoluta en el dominio, por lo tanto,

las técnicas de inteligencia artificial se utilizan comúnmente para descubrir una relación oculta [8].

La modelización regional de precipitación-escorrentía es un problema antiguo, pero aun mayormente pendiente en las ciencias hidrológicas [9]. La modelización de la escorrentía es uno de los desafíos clave en el campo de la hidrología [10], por ejemplo, la predicción precisa de la descarga de escorrentía por hora en una cuenca fluvial durante tifones es de importancia crítica en el control y la gestión operativa de inundaciones [11]. Al respecto, las inundaciones se encuentran entre los desastres naturales más destructivos, que son muy complejos de modelar. La investigación sobre el avance de los modelos de predicción de inundaciones contribuyó a la reducción del riesgo, la sugerencia de políticas, minimización de la pérdida de vidas humanas y reducción de los daños a la propiedad asociados con las inundaciones [12].

Ahora bien, se sabe que el crecimiento de las zonas urbanas y con esto el cambio de uso de suelos, han generado variaciones a la impermeabilidad, ocasionando el aumento de los caudales máximos, lo que ha provocado inundaciones, especialmente durante los eventos extremos como el que se presentó en el Perú y Ecuador en los años 2016-2017 conocidos también como el fenómeno del niño costero, causando importantes daños en viviendas y carreteras, por otro lado, los datos de precipitación de baja calidad siguen siendo uno de los desafíos en el pronóstico de inundaciones en tiempo real, lo que requiere avances en predicciones meteorológicas, numéricas, espaciales y temporales, más altas para mejorar el pronóstico en cuencas urbanas pequeñas [13].

El diseño de estructuras hidráulicas y la gestión del riesgo de inundaciones a menudo se basan en el flujo máximo instantáneo (IPF), sin embargo, las series de tiempo de flujo disponibles con alta resolución temporal son escasas y de duración limitada. Una estimación correcta del IPF es fundamental para reducir las consecuencias derivadas de las inundaciones repentinas [14]. La predicción de inundaciones es importante, ya que así a través del diseño se puede tener una mejor planificación y RGI [15].

Entre otros de los procesos hidrológicos que se han tratado con técnicas de inteligencia artificial se tiene, la estimación precisa de los cambios en el caudal del río, el cual es un problema bastante importante para un uso racional y sostenible. Tal problema es crucial para las obras y decisiones relacionadas con los recursos hídricos y su gestión [16]. En la misma línea, la predicción del nivel del agua de lagos es otro de los problemas complejos en el campo de la hidrología debido a la incorporación de diversas características hidrológicas y morfológicas [17].

La previsión de sequías hidrológicas juega un papel importante en la RGI, dado que es un problema tratado [18], mediante la aplicación de técnicas de IA. Del mismo modo, se menciona que la sequía hidrológica afecta en gran medida la asignación de agua y la generación de energía hidroeléctrica.

En este sentido, se puede decir que el objetivo de la presente indagación es realizar una revisión bibliográfica respecto a aplicaciones de técnicas de inteligencia artificial al modelamiento de procesos hidrológicos, a saber, modelamiento de lluvia-escorrentía, inundaciones, evapotranspiración, sequías, nivel de lagos entre otros.

2. METODOLOGÍA

Se realizó una búsqueda bibliográfica de artículos indexados para el período comprendido entre 2015-2021 en diferentes bases de datos, los cuales fueron distribuidos de la siguiente forma: 28 artículos en Scopus, 1 en Web of Science, 12 en Springer Link, 6 en EBSCOhost, 1 en SciELO, 4 en ScienceDirect, 4 artículos y 1 libro de páginas web, así

se recopilaron 57 investigaciones que aplicaron técnicas de inteligencia artificial al modelamiento de procesos hidrológicos. Para la búsqueda se emplearon palabras claves como: modelamiento hidrológico (hydrological modeling), evapotranspiración (evapotranspiration), escorrentía (runoff), inteligencia artificial (artificial intelligence), aprendizaje automático (machine learning), red neuronal (neural network) y precipitación (rainfall).

A continuación, para mayor detalle en la tabla I y II se presenta la distribución de artículos referenciados y en la figura 1 el protocolo de búsqueda y selección de publicaciones, esto de acuerdo a las diferentes bases de datos, el año del cual fue publicado, y las palabras claves con los que fueron identificados.

Tabla I
DISTRIBUCIÓN DE ARTÍCULOS DE ACUERDO A SU AÑO DE PUBLICACIÓN Y SU BASE DE DATOS

| Base de datos | Año de publicación | | | | | | | |
|----------------|--------------------|------|------|------|------|------|------|-------|
| | 2015 | 2016 | 2017 | 2018 | 2019 | 2020 | 2021 | Total |
| Scopus | -- | -- | 2 | 3 | 8 | 9 | 6 | 28 |
| Web of Science | -- | -- | -- | -- | -- | -- | 1 | 1 |
| Springer Link | 1 | -- | 2 | 1 | 1 | 4 | 3 | 12 |
| EBSCOhost | 1 | -- | -- | 1 | 3 | 1 | -- | 6 |
| SciELO | -- | -- | -- | -- | 1 | -- | -- | 1 |
| ScienceDirect | -- | -- | -- | -- | 2 | 2 | -- | 4 |
| Páginas web | -- | 2 | -- | 1 | 1 | 1 | -- | 5 |
| Total | 2 | 2 | 4 | 6 | 16 | 17 | 10 | 57 |

Fuente: Autores

Tabla II
DISTRIBUCIÓN DE ARTÍCULO SEGÚN LOS DIFERENTES CRITERIOS DE BÚSQUEDA.

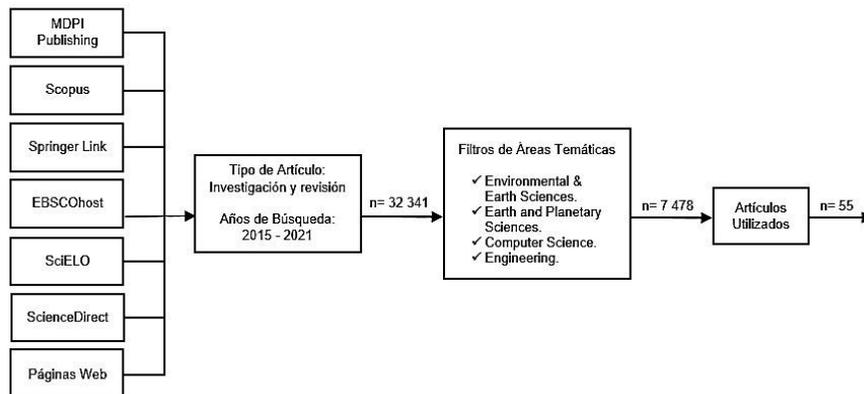
| Base de datos | Año de búsqueda | Palabras claves | Resultados sin filtro | Filtros aplicados | Resultados con filtros | Artículos seleccionados |
|-----------------|--------------------|-----------------------|--|---|------------------------|-------------------------|
| MDPI Publishing | 2015-2021 | "Runoff" | 2 417 | Subjects: Environmental & Earth Sciences | 1483 | 4 |
| | | | | Article | | |
| | | | | Journals: Water/ Sustainability | | |
| | 2015-2021 | Hydrological modeling | 591 | Subjects: Environmental & Earth Sciences | 321 | 4 |
| | | | | Article | | |
| | | | | Journals: Water/ Sustainability | | |
| | 2015-2021 | "Machine learning" | 9415 | Subjects: Environmental & Earth Sciences | 1245 | 4 |
| | | | | Research and review article | | |
| | | | | Journals: Applied Sciences/ Water | | |
| | 2015-2021 | "Neural network" | 9508 | Subjects: Environmental & Earth Sciences | 2634 | 4 |
| | | | | Article | | |
| | | | | Journals: Remote Sensing/ Water/Applied Sciences. | | |
| 2015-2021 | Evapotranspiration | 1530 | Subjects: Environmental & Earth Sciences | 490 | 1 | |
| | | | Article | | | |
| | | | Journal: Water | | | |

| Base de datos | Año de búsqueda | Palabras claves | Resultados sin filtro | Filtros aplicados | Resultados con filtros | Artículos seleccionados |
|-----------------------------------|---------------------------|-------------------------|---|--|------------------------|-------------------------|
| Scopus | 2015 - 2021 | "Hydrological modeling" | 13206 | Areas: Environmental Science y Earth and Planetary Sciences | 399 | 3 |
| | | | | Article | | |
| | | | | Source: Hydrological Sciences Journal/ Journal of Flood Risk Management/ Theoretical and Applied Climatology | | |
| | | | | Idioma: Ingles | | |
| | 2015 - 2021 | "Neural network" | 318527 | Areas: Computer science/ Engineering/ Earth and Planetary Sciences | 3289 | 4 |
| | | | | Article and Conference Paper | | |
| | | | | Source: IEEE Access/ Lecture Notes in Electrical Engineering/ Soft Computing/ Meteorological Applications. | | |
| | | | | Idioma: inglés keyword: Neural network | | |
| | 2015 - 2021 | "Runoff" | 37008 | All Open Access | 77 | 1 |
| | | | | Áreas: Environmental Science | | |
| Article | | | | | | |
| Idioma: inglés keyword: Runoff | | | | | | |
| 2015 - 2021 | "Artificial Intelligence" | 174560 | Source: Ecological Engineering/ Environmental Earth Sciences/ Environmental Engineering Research. | 107 | 1 | |
| | | | Áreas: Environmental Science | | | |
| | | | Article | | | |
| | | | Source: Water Switzerland/ Water Science and Technology Water Supply | | | |
| 2015 - 2021 | Rainfall | 66947 | Idioma: Ingles | 769 | 1 | |
| | | | Areas: Earth and Planetary Sciences | | | |
| | | | Article | | | |
| | | | Source: Climate Dynamics | | | |
| Springer Link | 2015 - 2021 | "Neural network" | 159118 | Diciplinas: Earth Sciences/Computer Science | 1387 | 8 |
| | | | | Article | | |
| | | | | Subdiscipline: Civil Engineering/ climatology/ Hydrogeology/ Hydrogeology and Water Resources/ Earth System Sciences/ Mathematical and Computational Engineering | | |
| | | | | Idioma: Ingles | | |
| | 2015 - 2021 | "Hydrological modeling" | 5606 | Diciplinas: Computer Science | 56 | 3 |
| | | | | Article / Chapter and Conference Paper | | |
| | | | | Subdiscipline Artificial Intelligence | | |
| | | | | Idioma: Ingles | | |
| | 2015 - 2021 | Evapotranspiration | 17604 | Diciplinas: Environment | 680 | 1 |
| | | | | Article | | |
| | | | | Subdiscipline environmental management | | |
| | | | | Idioma: Ingles | | |

| Base de datos | Año de búsqueda | Palabras claves | Resultados sin filtro | Filtros aplicados | Resultados con filtros | Artículos seleccionados |
|---------------|-------------------------|-------------------------|---|--|------------------------|-------------------------|
| EBSCOhost | 2015 - 2021 | Machine learning | 183705 | Materias: Machine learning | 88 | 3 |
| | | | | Base de Datos: Environment Complete | | |
| | | | | Idioma: Ingles | | |
| | | | | Publicación: Water resources research/ Water/ Hydrology & Earth System Sciences | | |
| EBSCOhost | 2015 - 2021 | "Neural network" | 115146 | Materias: Artificial neural networks | 566 | 3 |
| | | | | Base de Datos: Environment Complete/ Academic Search Complete | | |
| | | | | Idioma: Ingles | | |
| | | | | Publicación: Advances in meteorology/ Hydrological Sciences Journal; Journal des Sciences Hydrologiques/ Mathematical Problems in Engineering. | | |
| SciELO | 2015 - 2020 | "Runoff" | 462 | Área/Categorías: Engineering | 10 | 1 |
| | | | | Journal: DYNA | | |
| | | | | Idioma: Ingles | | |
| | | | | Article | | |
| ScienceDirect | 2015 - 2021 | "Neural network" | 138037 | Áreas: Earth and Planetary Sciences | 778 | 2 |
| | | | | Article | | |
| | | | | Publicación: Journal of Hydrology. | | |
| | | | | Idioma: Ingles | | |
| | 2015 - 2021 | "Hydrological modeling" | 9134 | Áreas: Earth and Planetary Sciences | 238 | 1 |
| | | | | Article | | |
| | | | | Publicación: Journal of Hydrology: Regional Studies. | | |
| | | | | Idioma: Ingles | | |
| 2015 - 2021 | "Hydrological modeling" | 9134 | Áreas: Computer Science. | 12 | 1 | |
| | | | Article | | | |
| | | | Publicación: Procedia Computer Science. | | | |
| | | | Idioma: Ingles | | | |
| Páginas web | 2015 - 2021 | "Neural network" | 816000 | SF | SF | 2 |
| | 2015 - 2021 | "Hydrological modeling" | 17100 | SF | SF | 3 |

Fuente: Los autores

Fig. 1. PROCESO DE BÚSQUEDA Y SELECCIÓN DE PUBLICACIONES



Fuente: Los autores

3. RESULTADOS

A continuación, se presenta un extracto de los artículos revisados, los mismo que aplicaron técnicas de inteligencia artificial al modelamiento de procesos hidrológicos, entre los que se destacan el modelamiento de lluvia-escorrentía, inundaciones, evapotranspiración, nivel de agua en lagos, entre otros. Asimismo, el criterio de agrupación que se adoptó fue por técnica de inteligencia artificial empleada, así se presenta indagaciones que aplicaron redes neuronales artificiales (RNA), sistema adaptativo de inferencia neuro-difuso (ANFIS), aprendizaje automático (ML) y técnicas híbridas.

3.1 Redes Neuronales Artificiales (RNA)

Si hablamos de RNA, no se puede dejar de mencionar a una de las primeras investigaciones, si no es la primera, que aplicó esta técnica de IA al modelamiento de lluvia-escorrentía, así nos referimos a lo realizado por French (1992) [19], quienes pronosticaron campos de intensidad de lluvia considerando espacio y tiempo; a partir de una red de aprendizaje de tres capas, es decir con capas de entrada, ocultas y de salida. El entrenamiento se llevó a cabo usando el algoritmo de propagación hacia atrás (BP, del inglés Backpropagation) donde los campos de lluvia de entrada y salida se presentaron a la red neuronal como una serie de conjuntos de aprendizaje. Una vez que se completó el entrenamiento, la red neuronal se usó para pronosticar los campos de intensidad de lluvia con un tiempo de anticipación de 1 hora. Los resultados indicaron que una red neuronal es capaz de identificar la compleja relación que describe la evolución espacio-tiempo de la lluvia, como lo inherente a un modelo complejo de simulación de lluvia. En función a su trabajo realizado infieren además que aumentar el número de iteraciones de entrenamiento solo, sin cambios en la estructura de la RN, se mejora el rendimiento en los datos de entrenamiento, pero no necesariamente se mejora el rendimiento en datos independientes [20].

El uso de técnicas deterministas, estadísticas y redes neuronales artificiales sin utilizar datos meteorológicos se han utilizado para realizar modelamientos de temperatura media mensual del suelo [21]. En base a ello determinaron que las RNA superaron consistentemente a los modelos clásicos, salvo algunas excepciones, y proporcionaron una mejor representación del modelamiento de temperatura media mensual del suelo, donde el modelo RNA de múltiples capas ocultas fue el mejor modelo entre todos los desarrollados. Sin embargo, en esa misma línea, realizaron un monitoreo espacio-temporal de sequías de aguas subterráneas utilizando datos multisatélites basados en una red neuronal artificial, para ello aplicaron los modelos perceptrón multicapa (MLP) de los cuales refieren que este tipo de modelos requieren un largo procedimiento de prueba y error para fijar el número óptimo de nodos ocultos [22].

El uso de RNA al pronóstico de lluvias intensas para uno de los distritos de Malasia propensos a inundaciones también ha sido utilizado. Para ello recopilaron y utilizaron datos de precipitación de 1965 a 2015 de estaciones meteorológicas locales [23].

El rendimiento del modelo de RNA se comparó con la técnica estadística denominada media móvil integrado de regresión automática (ARIMA). El rendimiento de cada enfoque se evaluó utilizando la raíz del error cuadrático medio (RMSE) y el coeficiente de correlación (R). Los resultados indicaron que el modelo de RNA fue confiable para anticipar por encima del nivel de riesgo de eventos de fuertes precipitaciones [24].

Del mismo modo, aplicaron RNA a la estimación de acumulación máxima diaria de nieve fresca (MDFSA, del inglés maximum daily fresh snow accumulation), con datos de entrada al modelo RNA como, precipitación diaria, temperatura media y temperatura mínima. Se entrenó y calibró el modelo utilizando un conjunto de 19923 datos, observados diariamente en Corea del Sur entre 1960 y 2016 (57 años). Cuando se conocieron los datos de entrada en las ubicaciones calibradas, el coeficiente de correlación entre el MDFSA observado y el estimado por el modelo RNA fue 0.90. Cuando los datos de entrada se interpolan espacialmente en ubicaciones no calibradas utilizando el método de kriging ordinario (OK), el coeficiente de correlación fue de 0.40. La diferencia en los coeficientes de correlación entre los dos métodos implica que, si bien el modelo de RNA en sí tiene un buen desempeño, una porción significativa de la incertidumbre de la MDFSA estimada en ubicaciones no calibradas proviene de una alta variabilidad espacial de las variables de entrada que no pueden ser capturadas por la red de estaciones in situ. Sin embargo, estos coeficientes de correlación fueron significativamente mayores que el coeficiente de correlación obtenido al interpolar espacialmente los valores de MDFSA con el método OK ($R = 0.20$), por lo que en base a esos resultados se sugiere que el modelo RNA reduce significativamente la incertidumbre de la MDFSA estimada causada por su alta variabilidad espacial [25].

Se ha utilizado RNA del tipo retropropagación para estimar la evapotranspiración potencial (ETo) en el Altiplano Peruano, a partir de variables de entrada como la temperatura máxima y mínima del aire ($T_{max} - T_{min}$), horas de sol (Sh), humedad relativa (Rh) y velocidad del viento (Wv), como método alternativo al método FAO Penman-Monteith (FAO-PM56) y Hargreaves-Samani (HS) [26]. En este estudio se seleccionaron conjuntos de datos climáticos diarios registrados en 12 estaciones meteorológicas entre 1963 y 2015. Por motivos de evaluación, también se consideró la ETo calculada utilizando el FAO-PM56. La principal variable de entrada para el modelado de RNA fue la T_{max} , seguida de Sh y Wv o combinaciones entre ellas. La aplicación de la fórmula de Hargreaves-Samani (HS) presentó un bajo resultado de estimación ETo en comparación con los 13 modelos de RNA [27]. Adicionalmente, se determinó que en estaciones con menor amplitud térmica ($<14.2\text{ }^{\circ}\text{C}$) los niveles de desempeño más bajos se presentan en la estimación de la ETo con la ecuación de HS, lo cual no ocurrió marcadamente con los modelos de RNA que estimaron adecuadamente la ETo [28]. Así concluyen que, los modelos de RNA representan una buena opción para reemplazar el método FAO-PM56 y HS, cuando las series de datos ETo son escasos [29].

Una investigación innovadora y significativa en la que se comparó el desempeño de tres conocidos enfoques de RNA

en el modelado de patrones de flujo turbulento basados en las características geométricas del canal (ángulo de horizonte, distancia desde la orilla exterior de la curva y distancia desde el lecho) en una curva cerrada de 180° con y sin un dique recto en forma de T [30]. De esta investigación se resaltan los siguientes aspectos: primero, los datos del patrón de flujo alrededor de los diques espirales en forma de T en una curva de 180°, dada su gran importancia en los ríos en la naturaleza, rara vez están disponibles; en segundo lugar, la aplicación de modelos de redes neuronales para comprender la naturaleza del flujo es altamente eficiente en otros puntos de flexión donde no se han realizado mediciones experimentales o de campo; y tercero, con estos modelos, el tiempo requerido, además de sus costos, ya que así podrán realizar modelos numéricos y experimentales para la predicción de la velocidad del flujo disminuyen significativamente [31]. Los resultados de la comparación de los modelos RNA con datos experimentales indican que las RNA proporcionan resultados razonables en la mayoría de los casos y pueden emplearse con éxito [32] para estimar la velocidad en curvas cerradas con y sin la presencia de un dique de derivación. Además, se puede concluir que los modelos ANN sin diques en derivación son más precisos que los que tienen diques en derivación debido a que generan menos turbulencias en el flujo.

Así mismo, se ha propuesto un modelo de red un modelo de red neuronal que entrenaron con pares de entradas y salidas de un simulador de inundación numérico estándar, a saber, la biblioteca de Python de código abierto Landlab que está basada en LISFLOOD-FP, como un modelo sustituto general eficiente y eficaz del simulador [4]. La red entrenada proporcionó un error porcentual absoluto medio de alrededor del 20%, sin embargo, la red entrenada es al menos 30 veces más rápida que el simulador numérico que se utilizó para entrenarla. Además, es capaz de simular inundaciones en terrenos de diferentes tamaños y características espaciales no representadas directamente en el entrenamiento.

Una comparación entre los productos de lluvia satelital, la Medición de Lluvias Tropicales (TRMM 3B43v7) y la Estimación de Precipitaciones utilizando RNA-Registro de Datos Climáticos (PERSIANN-CDR), con un modelo hídrico hidrológico GR2M en la cuenca del río Awash en Etiopía, en la que para la evaluación de los productos se utilizó el coeficiente de determinación (R^2), la eficiencia de Nash-Sutcliffe (NSE) y error cuadrático medio (RMSE) [33]. Una vez realizado el pronóstico de precipitación por medio de satélite, los hallazgos de los productos de lluvia satelitales asimilados con el modelo GR2M mostraron que el 80% de las cuencas hidrográficas calibradas y el 60% de las validadas, en una cuenca tenían menor magnitud de sesgo porcentual, lo que resultó en una mejor precisión en la simulación de flujo.

Hassan y colaboradores, realizaron un modelamiento de etapa-descarga con la intención de controlar las inundaciones, planificar, gestionar, desarrollar y sostener el ecosistema y los recursos hídricos [34]. Para dicho modelamiento emplearon redes neuronales artificiales basadas en ondas (WANN) para la descarga diaria (Q), además de ello se utilizó el algoritmo de Levenberg-Marquardt para el entrenamiento, y se utilizó la función de transferencia sigmoidea tangente hiperbólica para

calcular la salida de una capa a partir de su entrada neta. Los resultados de los modelos WANN se evaluaron mediante el valor observado de Q con base en indicadores de desempeño, lo que significa el RMSE, NSE, obteniendo lo siguiente (RMSE = 127.349 m³/s, NSE = 0.888).

Finalmente [35] busca la estimación de los niveles de agua subterránea (GWL) especialmente en cuencas hidrográficas relativamente no contiguas, para la evaluación se consideró aprendizaje profundo y redes neuronales artificiales (RNA), a saber, un MLP con arquitectura Long Short-Term Memory (LSTM) y una red neuronal convolucional (CNN). Se utilizaron 9 variables de entrada y 4 combinaciones para el período 2011-2017. Para las RNA, estas fueron capacitadas desde un inicio entre el periodo (2011-2015) y validadas (2016-2017). Obteniendo resultados favorables en que muestra que el MLP tuvo un mejor desempeño en la validación de las cuencas hidrográficas de Baltic River y Long Creek (RMSE = 0,471 y 1,15, respectivamente). Ahora bien, conforme con la revisión presentada podemos observar el amplio uso de las RNA en el campo de la hidrología, estas aplicadas al modelamiento de procesos hidrológicos tal como se aprecia en la Tabla III.

3.2 Sistema Adaptativo de Inferencia Neuro-Difuso (ANFIS)

Bejar y colaboradores, aplicaron RNA y el modelo ANFIS a la predicción de caudales medios diarios en una sección de la cuenca del amazonas [36]. Para ello aplicaron los procedimientos de la metodología "Descubrimiento de Conocimiento en Bases de Datos (KDD)", a la información hidrológica recopilada de las estaciones del Servicio de Observación SO HYBAM. Así obtuvieron que, aplicando técnicas de IA, los R estuvieron entre el 96.9% y 98.9%; y el error medio porcentual absoluto (MAPE) estuvo por debajo del 10%, a saber, entre 4% y 10%; lo que demostró la buena capacidad predictiva de las técnicas de inteligencia artificial empleadas, frente a métodos tradicionales del tipo lineal.

Por su parte, [11] utilizaron tres enfoques de modelado para predecir la descarga de escorrentía en la cuenca del arroyo Laonong al sur de Taiwán, estos fueron el modelo del sistema de modelado hidrológico del Centro de Ingeniería Hidrológica (HEC-HMS) y dos modelos híbridos que combinaron el modelo HEC-HMS con una red neuronal de algoritmo genético (GANN) y un enfoque de sistema ANFIS. Recopilaron datos de escorrentía por hora durante siete eventos de tifones para la calibración (entrenamiento) y validación. Los resultados de la simulación indicaron que el modelo HEC-HMS no pudo predecir satisfactoriamente la descarga de escorrentía por hora durante los tifones, sin embargo, los modelos híbridos que utilizaron los resultados del modelo HEC-HMS junto con los modelos GANN y ANFIS mejoraron significativamente la precisión de la predicción para la descarga de escorrentía [37].

Algunos otros estudios en los que se ha estimado la evapotranspiración de referencia utilizando sensores de humedad del suelo, aplicando la técnica de regresión lineal múltiple (MLR) y la red de perceptrones multicapa (MLP), han arrojado resultados en los que el modelo MLR tuvo un mejor rendimiento respecto a la red MLP [38]-[39].

Jimeno y colaboradores, empleando modelos de aprendizaje automático y la fórmula empírica en la España Peninsular para la estimación del pico de flujo instantáneo (IPF, del inglés instantaneous peak flow), con la información de 14 estaciones de medición de caudal [14]. Así compararon métodos empíricos para estimar la IPF basados en el flujo

diario medio máximo (MMDF, del inglés maximum mean daily flow), RNA y el ANFIS. Como criterios de evaluación se utilizaron el error de raíz cuadrada media (RMSE) y el coeficiente de determinación (R^2). Los resultados indicaron que ANFIS demostró una capacidad superior para estimar la IPF en comparación con cualquier fórmula empírica [40].

Tabla III
REDES NEURONALES ARTIFICIALES (RNA) APLICADAS AL MODELAMIENTO DE PROCESOS HIDROLÓGICOS

| Modelo de RNA | Capas (arquitectura) | Aplicación | Funciones de aprendizaje | Criterios de bondad de ajuste | Ref. | Tasa de aprendizaje |
|------------------------------|----------------------|---|--|--|------|---------------------|
| Retropropagación (BP). | 1 – 5 – 1 | Transitar caudales. | Logarítmica sigmoidea, tangente sigmoidea y Purelin. | $NSE_{(calibración)} = 0.881$ $NSE_{(validación)} = 0.859$ | [1] | ---- |
| Perceptrón multicapa (MLP). | 1 – 2 – 1 | Simular y modelar procesos hidrológicos. | Lineal. | $MSE = 0.0212$ $MAPE = 0.1317$ | [4] | ---- |
| Perceptrón multicapa (MLP). | 1 – 1 – 1 | Simular lluvia-escorrenría. | Sigmoidea. | $R^2 = 0.81$ $LSTM = 0.95$ | [8] | ---- |
| RNA-PSO, RNA-SSA, RNA-GA. | No se especifica. | Modelar sequías. | Sigmoidal. | $MAE = 43\%$ | [15] | ---- |
| Perceptrón multicapa (MLP). | 1 – 2 – 1 | Predecir evapotranspiración estándar de cebada | Tangente hiperbólica, log-sigmoidea, tangente hiperbólica sigmoidea, lineal | $R^2 = 0.92$ $NRMSE = 0.23$ $MAE = 0.58$ | [16] | ---- |
| Perceptrón multicapa (MLP). | 1 – 2 – 1 | Modelar nivel de agua. | Sigmoidea y lineal. | $RMSE = 29.80\%$ $MAE = 33.90\%$ | [17] | ---- |
| Perceptrón multicapa (MLP). | No se especifica. | Pronosticar sequías. | Sigmoidea. | $R^2 = 0.82$ $RMSE = 0.40$ | [18] | ---- |
| Perceptrón multicapa (MLP). | 11 – 14 – 1 | Predecir un índice de evapotranspiración. | Logarítmica sigmoidea, tangente sigmoidea, lineal y unidad lineal rectificada. | $R^2 = 0.949$ $RMSE = 0.428$ | [19] | ---- |
| Retropropagación (BP). | 1 – 1 – 1 | Estimar evapotranspiración. | Algoritmo Levenberg-Marquardt. | $R = 0.996$ $NSE = 0.980$ | [20] | ---- |
| Perceptrón multicapa (MLP). | 1 – 1 – 1 | Estimar la temperatura media mensual del suelo. | Tangente sigmoidea (Tansig) y lineal (Purelin). | $RMSE = 0.60^{\circ}C$, $MAE = 0.54^{\circ}C$ $R^2 = 0.99$ | [21] | ---- |
| Perceptrón multicapa (MLP). | 1 – 1 – 1 | Monitorear sequías de aguas subterráneas. | Logarítmica Sigmoidal. | $R = 0.87$ | [22] | ---- |
| Red neuronal autorregresiva. | 2 – 5 – 5 – 1 | Pronosticar lluvias. | Algoritmo de maximización de expectativas (EM). | $RMSE = 0.06$ $R^2 = 0.4689$ | [23] | ---- |
| Retropropagación (BP). | 4 – 10 – 10 – 1 | Estimar datos climáticos. | Algoritmo de retropropagación Levenberg-Marquardt. | $R^2 = 0.97$ $RMSE = 0.02 \text{ mm/h}$ | [24] | ---- |
| Retropropagación (BP). | 1 – 1 – 1 | Estimar la acumulación de nieve fresca. | Algoritmo de retropropagación Levenberg-Marquardt. | $R = 0.90$ | [25] | ---- |
| Retropropagación (BP). | 5 – 4 – 3 – 2 | Estimar evapotranspiración potencial. | Sigmoidea. | $MAE = 0.204$ $RMSE = 0.264$ $NE = 0.87$ $R = 0.932$ | [26] | ---- |
| Perceptrón multicapa (MLP). | 1 – 1 – 1 | Estimar evapotranspiración. | No se especifica. | No se especifica. | [27] | ---- |
| RNA GMDHNN | No se especifica. | Predecir evapotranspiración potencial. | No se especifica. | $RMSE = 0.448 \text{ mm}$ $MAE = 0.353 \text{ mm}$ $NSE = 0.898$ | [28] | ---- |
| Retropropagación (BP). | 1 – 1 – 1 | Pronosticar la humedad del suelo. | Tangente sigmoidea. | $RMSE = 0.021$ $MAE = 0.013$ $R = 0.996$ $NSE = 0.995$ | [31] | ---- |
| Perceptrón multicapa (MLP). | 1 – 10 – 1 | Estimar evapotranspiración de referencia. | Algoritmo de retropropagación Levenberg-Marquardt. | $R = 0.9470$ $MRE = 11.03\%$ $RMSE = 0.2972 \text{ mm/d}$ $MAE = 0.1521 \text{ mm/d}$ | [38] | ---- |
| Perceptrón multicapa (MLP). | 1 – 2 – 1 | Pronosticar caudales. | Tangente sigmoidea hiperbólica. | $NSE_{(río Machángara)} = 0.99$ $NSE_{(río Chulco)} = 0.99$ | [52] | ---- |
| Red neuronal autorregresiva | 1 – 1 – 1 | Validar datos hidrológicos. | Algoritmo Levenberg-Marquardt. | $R = 0.90$ | [56] | ---- |

Fuente: Los autores

Roodsari y colaboradores, realizaron el pronóstico de inundaciones en tiempo real en 9 pequeñas cuencas urbanas ubicadas cerca de la ciudad de Nueva York (NYC), mediante el modelo hidrológico Sacramento Soil Moisture Accounting (SAC-SMA) y el ANFIS [13]. Los modelos se utilizaron para simular el caudal del huracán Irene (160 mm) y una tormenta de 35 mm en tiempos de espera de 3 a 24 horas. Las diferencias en el rendimiento entre los modelos fueron pequeñas para los plazos de entrega cortos (3 horas) y fueron similares para la tormenta de 35 mm. Los pronósticos del huracán Irene con plazos de entrega de 24 horas mostraron un sólido desempeño para SAC-SMA, pero una disminución en el desempeño de ANFIS [41]. Asimismo, el desempeño del modelo SAC-SMA no varió sistemáticamente ni con el tamaño de la cuenca ni con la impermeabilidad, destacando su versatilidad para modelar este tipo de eventos meteorológicos.

Las RNA también se han aplicado para estimar enrutamiento de inundaciones, para el cual se han hecho uso de 8 diagramas de inundaciones, del cual 6 utilizadas para la etapa de entrenamiento y 2 en la etapa de prueba. Se prepararon dos modelos para el estudio, una red neuronal MLP y una RNA ANFIS mediante dos algoritmos bat e imperialista (ICA). De acuerdo a los cálculos estimados para el PM se obtuvo un RMSE de 3,01 frente al RMSE de la ANFIS (ICA) de 0,3; demostrando que ANFIS es un excelente modelo. Para culminar se estimó el hidrograma de inundación para un ciclo de retorno de 10 000 años. [42]

3.3 Aprendizaje Automático (ML)

La complejidad computacional de ANFIS es un obstáculo importante en su aplicación, por lo que [6] crearon una

versión modificada llamado (PSO ANFIS) para la estimación de la escorrentía. En ese artículo resolvieron ese problema incorporando uno de los algoritmos evolutivos conocido como optimización por enjambre de partículas (PSO) que se utilizó en la estimación de los parámetros pertenecientes a ANFIS, así los resultados del ANFIS modificado resultaron satisfactorios, presentando un mejor desempeño en términos del RMSE en comparación con ARIMA y ANFIS convencional.

En esta misma línea, la modelización de la escorrentía es uno de los desafíos clave en el campo de la hidrología, por lo que existen varios enfoques que van desde modelos basados físicamente hasta modelos totalmente basados en datos, de ahí que se ha realizado un modelamiento de escorrentía a partir de un enfoque basado en datos utilizando la red de última generación de LSTM [10], [44]. Aplicando el modelo en la cuenca del lago Poyang (PYLB) y su rendimiento se comparó con una red neuronal artificial (RNA) y la herramienta de evaluación de suelos y aguas (SWAT). Se entrenó el modelo con 2 conjuntos de datos de entrada diferentes, a saber, un conjunto de información con precipitación, además con todas las variables meteorológicas disponibles. Así se obtuvo que, aunque LSTM con datos de precipitación como única entrada puede lograr resultados deseables (donde el NSE varió de 0.60 a 0.92 para el período de prueba), el rendimiento se puede mejorar simplemente alimentando el modelo con más variables meteorológicas (donde NSE varió desde 0.74 a 0.94 para el período de prueba). Los resultados de este estudio subrayan el potencial del LSTM para modelar la escorrentía, especialmente para áreas donde no se dispone de datos topográficos detallados.

Tabla IV
SISTEMA ADAPTATIVO DE INFERENCIA NEURO-DIFUSO (ANFIS) APLICADO AL MODELAMIENTO DE PROCESOS HIDROLÓGICOS

| Modelo ANFIS | Capas (arquitectura) | Aplicación | Funciones de aprendizaje | Criterios de bondad de ajuste | Ref. | Tasa de aprendizaje | Momentum |
|------------------------|----------------------|---|--|---|------|---------------------|----------|
| ANFIS | 1 - 3 - 1 | Estimar la escorrentía | Gaussiana. | R ² = 0.91 NSE = 0.86 RMSE = 1.52 | [6] | ----- | ----- |
| ANFIS | 1 - 1 - 1 | Pronosticar inundaciones en tiempo real. | No se especifica. | NSE (calibración) = 0.72 NSE (validación) = 0.87 | [13] | ----- | ----- |
| ANFIS | 1 - 2 - 1 | Estimar caudal máximo instantáneo. | Algoritmo de retropropagación Levenberg-Marquardt. | RMSE = 2.13% R ² = 0.86 | [14] | ----- | ----- |
| ANFIS | 1 - 3 - 1 | Estimar la temperatura media mensual del suelo. | Tangente sigmoidea (Tansig) y lineal (Purelin). | RMSE = 0.38°C, MAE = 0.34°C R ² = 0.996 | [21] | ----- | ----- |
| ANFIS | 1 - 1 - 1 | Modelar evapotranspiración. | Tangente Sigmoidea. | NSE = 0.8245 RMSE = 0.1274 | [32] | ----- | ----- |
| ANFIS | 1 - 3 - 1 | Predecir caudales. | Algoritmo de retropropagación Levenberg-Marquardt. | R = 97.72% MAPE = 9.2452% | [36] | ----- | ----- |
| Takagi-Sugeno (ANFIS). | 1 - 1 - 1 | Predecir caudales. | Gaussiana y lineal. | NSE = 88.7% R ² = 90.74% MSE = 0.00122 | [37] | ----- | ----- |
| Takagi-Sugeno (ANFIS). | 1 - 3 - 1 | Predecir evapotranspiración. | Gradiente de retropropagación. | R = 0.993 RMSE = 0.151 mm/día | [40] | ----- | ----- |
| ANFIS | 4 - 5 - 3 | Modelar evapotranspiración potencial mensual. | Triangular, trapezoidal, gaussiana, gaussiana 2. | R ² = 0.26 RMSE = 6.66 MAE = 0.528 | [41] | ----- | ----- |
| MIKE 11-RNA | No se especifica. | Pronosticar inundaciones. | Regresión lineal, Gaussiana normalizada. | RMSE = 89.05% | [43] | 0.10 | ----- |

Fuente: Los autores.

Hu y colaboradores, aplicaron técnicas de aprendizaje profundo con un enfoque de LSTM para la simulación de lluvia-escorrentía basándose en 98 eventos de inundación desde 1971 a 2013 en la cuenca del río Fen monitoreados a través de 14 estaciones de lluvia y una estación hidrológica. 86 eventos se utilizaron para la fase de entrenamiento, y 12 para la fase de validación. Los resultados demostraron que las dos redes RNA y LSTM son adecuadas para modelar el proceso de lluvia-escorrentía, siendo mejores que los modelos conceptuales y físicos, sin embargo, los modelos LSTM superaron a los modelos RNA con valores de R^2 y NSE superiores a 0.9, respectivamente.

Mediante la técnica de aprendizaje automático (ML, del inglés machine learning), se realizó un modelamiento hidrológico aplicado al pronóstico de inundaciones urbanas en Tailandia, aplicando cinco técnicas alternativas de aprendizaje automático; regresión lineal, regresión de redes neuronales, regresión lineal bayesiana y regresión de árbol de decisión potenciada, para lo cual utilizaron el llamado modelo de pronóstico hidrológico MIKE-11, desarrollado por el Instituto Danés de Hidráulica (DHI) de Dinamarca. Aunque el modelado basado en datos es un trabajo cómodo, existen límites para la precisión. Para el modelo físico, incluso si es de alta precisión, pero para los datos, la preparación es de alto presupuesto, y si las técnicas de recopilación de datos son ineficientes, el resultado de los datos físicos es una falta de precisión. El propósito del modelado heterogéneo es descubrir el error en MIKE11 y reducirlo [43].

Yaseen y colaboradores, desarrollaron un nuevo modelo híbrido de inteligencia de datos (DI) basado en la integración del Perceptrón multicapa (MLP) y el algoritmo de optimización de la ballena (WOA) para el modelado del nivel del agua del lago Van, al este de Turquía, con una escala mensual durante un período de tiempo de más de siete décadas (1943-2016). El potencial del modelo híbrido propuesto, MLP_WOA, se valida contra varios modelos DI bien establecidos en la literatura, incluido el modelo de red neuronal cascada correlación (CCNNM), el mapa auto organizado (SOM), la regresión del árbol de decisiones (DTR), la regresión del bosque aleatorio (RFR) y el Perceptrón multicapa clásico (MLP). Los resultados indicaron que el modelo MLP_WOA obtuvo resultados de predicción superiores a los modelos comparables basados en el rendimiento de la predicción. Los plazos de entrega de cinco meses obtuvieron los mejores resultados para el procedimiento de predicción. En términos cuantitativos, el RMSE y MAE se reducen en 29.8% y 33.9%, 48.3% y 52%, 57.6% y 59.7%, 53.9% y 58.3%, y 25.3% y 23.9% utilizando el modelo MLP_WOA sobre CCNNM, SOM, modelos DTR, RFR y MLP, respectivamente. Asimismo, en comparación con otros estudios de la literatura, el uso de un intervalo más largo de datos históricos elevó la precisión de las simulaciones [17].

3.4 Modelos híbridos

Utilizando un modelo híbrido de red neuronal artificial y físicamente basado, [45] realizaron la predicción y modelado de lluvia-escorrentía durante eventos de tifones en la cuenca de Sandimen al sur de Taiwán. Recopilaron datos de descarga de

escorrentía por hora (1200 conjuntos de datos) de siete eventos de fuertes precipitaciones para la calibración (entrenamiento) y validación del modelo. Emplearon cuatro enfoques de modelado, a saber, HEC-HMS, RNA, ARMAX y HEC-HMS-ANN, así como cuatro eventos de fuertes lluvias (un total de 696 conjuntos de datos) para la calibración (entrenamiento), y tres eventos de tifones (504 conjuntos de datos) que se utilizaron para la validación. Finalmente, el modelo híbrido HEC-HMS-ANN desarrollado demostró una precisión mejorada en la predicción recursiva de descargas de escorrentía con anticipación, especialmente para descargas de flujo máximo y el tiempo [45]. En esa misma línea podemos citar a [46] que investigaron respecto al evento del Niño Costero de 2017 que azotó al Perú, el cual no se veía en tal magnitud desde El Niño de 1997-1998. La cantidad de lluvia registrada entre enero y marzo de 2017 solo se comparaba con los eventos de El Niño de los últimos 40 años, a saber, 1982-1983 y 1997-1998; y superó el percentil 90 de los registros disponibles (1981-2017) en gran parte de la costa norte y central del Perú, la región andina y la Amazonia [47]. Lo ocurrido fue muy peculiar por el hecho que sucedió durante el primer verano austral después del desarrollo y la descomposición de un El Niño muy fuerte en 2015-2016. La causa probable de las precipitaciones anómalas estuvo relacionado a la combinación de una ola de lluvia especialmente intensa sobre los Andes Centrales relacionada con un anticiclón profundo y duradero ubicado adyacente a la costa chilena, y al desarrollo inusual de lluvias cálidas frente a la costa de Perú en la región nominal de El Niño 1 + 2. Este evento provocó daños catastróficos en viviendas e infraestructura, que afectó a más de 660000 personas y dejó más de 100 muertes.

Bloschl y colaboradores, presentaron una investigación muy particular sobre veintitrés problemas no resueltos en hidrología, en el que destacan la utilidad de nuevas técnicas para el manejo de gran cantidad de información con los que se trabaja en hidrología, incentivando así al uso de técnicas híbridas basadas en inteligencia artificial que contribuyan con ello, siempre además ligados con el cuidado y no alteración del medio ambiente [48].

Barrientos y colaboradores, analizaron los cambios en la escorrentía de cuencas forestales experimentales en el centro-sur de Chile, para determinar en qué medida las tendencias que observaron podían atribuirse a los efectos de la silvicultura intensiva y/o el cambio climático. Para lograr ello, aplicaron el modelo distribuido TETIS a ocho cuencas que tenían áreas de entre 7.1 a 413.6 hectáreas representativas de los usos del suelo y actividades forestales en esta área geográfica. Para modelar y calibrar el modelo emplearon datos de precipitación y caudales recopilados entre 2008 y 2015. Asimismo, para la simulación trabajaron con tres usos del suelo (cobertura actual, aprovechamiento parcial y bosque nativo) y 25 combinaciones de escenarios climáticos (aumentos o disminuciones porcentuales de las series de entrada, de hasta el 20% de las precipitaciones y la evapotranspiración relativa al escenario sin cambios), descubriendo que las variaciones sobre la tierra y el clima tuvieron efectos contrastantes en la escorrentía [49].

Ayala y colaboradores, realizaron el enrutamiento del flujo en el cauce natural de la cuenca experimental del río Ichu mediante RNA, para ello desarrollaron un modelo de lluvia-es-

correntía con datos registrados en 6 estaciones meteorológicas automáticas y una estación hidrológica. En primera instancia para generar escorrentía emplearon el software HEC-HMS y el método Muskingum-Cunge para el tránsito de crecidas [50], generando registros históricos para 5 tramos del cauce del río Ichu, habiendo así obtenido 39 registros históricos máximos en los periodos 2016 y 2017. De dicho modelamiento realizado con HEC-HMS obtuvieron valores de coeficientes de NSE iguales a 0.851 y 0.828 para la etapa de calibración y validación, respectivamente. En una segunda etapa modelaron los resultados antes obtenidos con redes neuronales, habiendo construido diferentes arquitecturas para entrenar y obtener la que mejor se adaptase a los fenómenos históricos. Finalmente, la arquitectura 1-5-1 presentó un mejor ajuste, cuyo estadístico de NSE alcanzó valores de 0.881 y 0.859 en el proceso de entrenamiento y validación respectivamente. Vale indicar que el modelamiento con RNA se realizó empleado Matlab [1].

Fang y Fan en su investigación, sobre los impactos de las variaciones climáticas y de uso de la tierra en la producción de agua y sedimentos para la región del suelo negro al noreste de China; emplearon el modelo distribuido TETIS durante 1978-2014 en la cuenca de Yian. Así, los resultados indicaron que el escenario con solo cambio climático aumentó el agua y el rendimiento de sedimentos (SY) en 31.55% y 92.1%, respectivamente. Los escenarios con los cambios en el uso de la tierra en 1985, 1995, 2000 y 2010 aumentaron el agua y SY en 1.28% y 12.54%, respectivamente. Con respecto al periodo de referencia en 1978-1987, las tasas promedio de aumento de agua y SY fueron 31.7% y 114.5%. Las contribuciones del cambio climático fueron 99.5% para el rendimiento de agua y 69.2% para el SY, respectivamente. Este estudio indicó que la configuración y gestión racional del uso de la tierra puede aliviar el impacto adverso derivado del cambio climático en la región del suelo negro y regiones similares en todo el mundo [51].

Farfán y colaboradores, emplearon una técnica híbrida basada en RNA para mejorar el pronóstico de flujo de modelos físicos y en datos en cuencas hidrográficas andinas, a saber, en las cuencas pertenecientes a la cuenca Paute de Ecuador. Ahora, en estas regiones, a causa de la importante variabilidad en clima y el poco empleo de redes de seguimiento, la cuantificación y predicción, consideran que la precisión del flujo de agua es un desafío [52].

Basándose en el ML, se han empleado redes LSTM, en cuencas no calibradas, entrenando y probando varios LSTM en 531 cuencas del conjunto de datos CAMELS, utilizando la validación cruzada de k-fold, de modo que las predicciones se hicieron en cuencas que no proporcionaron entrenamiento de datos. El conjunto de datos de entrenamiento y prueba incluyó 30 años de datos diarios de precipitación y escorrentía de cuencas en los Estados Unidos con un tamaño de 4 a 2000 km² con un índice de aridez de 0.22 a 5.20, e incluyendo 12 de las 13 clasificaciones de cobertura vegetal con vegetación IGPB. Este modelo efectivamente "no calibrado" se comparó durante un periodo de validación de 15 años con el modelo de Contabilidad de la humedad del suelo de

Sacramento (SAC-SMA) y también con el nuevo análisis del Modelo Nacional de Agua de la NOAA. SAC-SMA se calibró por separado para cada cuenca utilizando 15 años de datos diarios. Finalmente, el LSTM fuera de la muestra tuvo una mediana de eficiencia de Nash-Sutcliffe más alta en las 531 cuencas (0.69) que el SAC-SMA calibrado (0.64) o el modelo Nacional de Agua (0.58) [9], [53].

Una revisión de la literatura acerca de la predicción de inundaciones mediante modelos de aprendizaje automático (ML, del inglés machine learning), a saber, RNA, máquinas de vectores de soporte (SVM), regresión vectorial de soporte (SVR), ANFIS, red neuronal Wavelet (WNN), sistemas de predicción de conjuntos (EPSs) y el árbol de decisión (DT), reportada en [12] y [54] para imitar las complejas expresiones matemáticas de los procesos físicos de las inundaciones, durante las últimas dos décadas, los métodos de aprendizaje automático (ML) contribuyeron en gran medida al avance de los sistemas de predicción que proporcionan mejor rendimiento y soluciones rentables. Como resultado, su artículo presentó los métodos de predicción más prometedores para inundaciones tanto a largo como a corto plazo. Además, se investigaron las principales tendencias para brindar una buena calidad y mejora de los métodos de predicción de inundaciones, entre ellos, la hibridación, la descomposición de datos, el conjunto de algoritmos y la optimización del modelo, se informan como las estrategias más efectivas para la mejora de los métodos de aprendizaje automático.

Nabipour y colaboradores, emplearon la hibridación de nuevos algoritmos de optimización inspirados en la naturaleza y RNA para el pronóstico hidrológico de sequía a corto plazo, en escalas de tiempo de 1, 3 y 6 meses. Para ello, calcularon el Índice de Sequía Hidrológica Estandarizada (SHDI) y el Índice de Precipitación Estandarizado (SPI) en uno, tres y seis meses. Se utilizaron algoritmos de optimización como el Grasshopper (GOA), el algoritmo Salp Swarm (SSA), la optimización basada en biogeografía (BBO) y la optimización por enjambre de partículas (PSO), todos esos algoritmos hibridados con RNA para el pronóstico del SHDI y los resultados comparados con las RNA convencional. Los resultados indicaron que el modelo hibridado superó en comparación con las RNA convencional. PSO funcionó mejor que los otros algoritmos de optimización, así los mejores modelos pronosticaron SHDI1 con $R^2 = 0.67$ y $RMSE = 0.57$, SHDI3 con $R^2 = 0.80$ y $RMSE = 0.44$ y SHDI6 con $R^2 = 0.81$ y $RMSE = 0.39$. [18]

Kratzert y colaboradores, como parte de un modelamiento hidrológico de nieve emplearon el modelo distribuido TETIS en una cuenca de alta montaña. Evaluaron los efectos de la variabilidad en el modelado hidrológico y el modelado de deshielo a escala de celda y ladera, así como propusieron introducir la variabilidad espacial y temporal del factor grado-día utilizando mapas de índices de radiación, los cuales consideran la posición del sol según la época del año, radiación solar, insolación, topografía y topografía de relieve sombreado. Así los resultados mostraron mejoras significativas en el modelado hidrológico en el periodo primaveral cuando el deshielo es más importante [55].

Aplicando técnicas de inteligencia artificial, [56] validaron datos hidrológicos de niveles de agua en ríos mediante un modelo híbrido basado en RNA, para ello se utilizaron datos de series de tiempo históricas. Desarrollaron modelos individuales que fueron desde redes neuronales hasta predictores estadísticos, y de forma independiente se incorporó un modelo de lógica difusa basado en reglas para proporcionar una entrada de modelo adicional. Cada uno de estos modelos individuales se integró mediante técnicas de lógica difusa y bayesiana. La adición de la lógica difusa al nítido modelo bayesiano arrojó resultados generales que fueron superiores a los otros enfoques de múltiples modelos e individuales al considerar las medidas de evaluación global.

Dazzi y colaboradores, presentan en su investigación la evaluación y rendimiento de 3 métodos de aprendizaje automático (ML) para predecir las etapas de inundación utilizando principalmente observaciones aguas arriba, el lugar en el que se realizó el estudio es en un tramo del río Parma (Italia). El rendimiento de tres algoritmos ML, a saber, la regresión vectorial de soporte (SVR), el MLP y las LSTM, demostraron entre ellos comparaciones en términos de precisión y tiempo de cálculo, reflejando a través de los resultados que el modelo LSTM, a pesar de requerir el mayor tiempo de entrenamiento, este puede considerarse el mejor para establecer un modelo operativo sólido para el pronóstico de inundaciones en tiempo real [57].

Las técnicas tradicionales utilizadas por la ingeniería civil para predecir variables como lluvia-escorrentía, inundaciones, evapotranspiración, sequías, nivel de lagos entre otros, no han cubierto las necesidades de diseño de los ingenieros, motivo por el cual en los últimos años los investigadores están buscando nuevos métodos para estimar estas variables con mayor precisión, se puede observar que el uso de técnicas de IA se han venido incorporando con el fin de mejorar la eficiencia de las estimaciones, es así, que se puede notar un incremento exponencial de publicaciones de esta naturaleza, pasando de 2 artículos en el año 2015 a 57 en el año 2021, demostrando mayor interés por parte

de la comunidad científica en los procesos de diseño de la ingeniería civil basado en la inteligencia artificial.

4. DISCUSIÓN

Algunos de los autores citados en esta revisión, han utilizado una variedad de métodos para estimar lluvia-escorrentía, inundaciones, evapotranspiración, sequías, nivel de lagos entre otros, que han surgido a causa de los fenómenos naturales y en otras ocasiones provocados por cambios meteorológicos, al respecto tenemos a [5] que al desarrollar el modelo basándose en datos como LSTM para estimar la escorrentía, obtiene resultados favorables, que al compararlo con una RNA se muestra mejor rendimiento, logrando un $R^2= 0.84$ y $NSE= 0.83$. Del mismo modo [8] utilizó técnicas de aprendizaje automático basados en modelos de RNA utilizando un perceptrón de retroalimentación (MLP) de múltiples capas y la arquitectura LSTM con 50 neuronas o celdas de memoria para predecir la descarga de lluvia-escorrentía, en cuanto a los resultados tanto la RNA como LSTM son adecuadas para modelar el proceso de lluvia-escorrentía, sin embargo, aquí el autor comparte resultados similares, ya que señala que LSTM supera a los modelos RNA con valores de $R^2= 0.95$ y $NSE= 0.97$, esto demuestra que los métodos de estimación basados en inteligencia artificial son eficientes, además que la arquitectura basado en celdas de memoria tienen mejor comportamiento para datos hidrológicos.

Otros modelos de red como el que plantea [11], realizan la predicción de descarga de escorrentía combinando el modelo HEC-HMS con una red neuronal de algoritmo genético (GANN) y un ANFIS, obteniendo como resultados que en la simulación indicaron que el HEC-HMS no pudo predecir la descarga de escorrentía de manera individual, sin embargo, los modelos híbridos que utilizaron los resultados del modelo HEC-HMS junto con los modelos GANN y ANFIS mejoraron significativamente la precisión de la predicción, obteniendo un $R = 0.967$, lo que demuestra ser una herramienta eficaz para este propósito.

Tabla V
MODELOS HÍBRIDOS APLICADOS AL MODELAMIENTO DE PROCESOS HIDROLÓGICOS

| Modelo híbrido | Capas (arquitectura) | Aplicación | Funciones de aprendizaje | Criterios de bondad de ajuste | Ref. | Tasa de aprendizaje | Momentum |
|----------------|----------------------|------------------------------------|---|---|------|---------------------|----------|
| LSTM | 1 – 1 – 1 | Simular escorrentía. | Sigmoidea y la función tangente hiperbólica. | $R^2 = 0.84$ $NSE = 0.83$ | [5] | 0.0001 | ---- |
| LSTM | No se especifica. | Modelar variables meteorológicas. | Sigmoidea, tangente hiperbólica y multiplicación por elementos. | $NSE_{(entrenamiento)} = 0.74$ $NSE_{(validación)} = 0.94$ | [9] | ---- | ---- |
| LSTM | 1 – 1 – 1 | Simular escorrentía. | Sigmoidea tangente hiperbólica. | $NSE_{(entrenamiento)} = 0.74$ $NSE_{(validación)} = 0.94$ | [10] | 0.2 | ---- |
| HEC-HMS-ANFIS | 1 – 3 – 1 | Modelar lluvia-escorrentía. | Algoritmo de retropropagación Levenberg-Marquardt. | $RMSE = 63.81 m^3/s$ $R = 0.967$ $CE = 0.932$ | [11] | ---- | ---- |
| HEC-HMS-ANN | 1 – 1 – 1 | Modelar lluvia-escorrentía. | Algoritmo de retropropagación Levenberg-Marquardt. | $RMSE = 104.91 m^3/s$ $R = 0.91$ $CE = 0.824$ | [45] | 0.01 | 0.3 |
| LSTM | 1 – 1 – 1 | Modelar datos de muestras grandes. | Sigmoidea, tangente hiperbólica y multiplicación por elementos. | $NSE = 0.73$ | [53] | ---- | ---- |

Fuente: Los autores

Por otra parte, también se han realizado modelamientos en la que se utilizaron RNA para el monitoreo y estimación de la temperatura media mensual del suelo y la sequía de agua subterránea ambos esenciales del ciclo hidrológico, en la que [21] y [22] usan datos multi satélites basados en una RNA, aplicando los modelos perceptrón multicapa (MLP), obtuvieron resultados destacados como, $R^2=0.99$, esto indica que el comportamiento de algunas variables pueden ser estimadas con buena precisión, mientras que otras requieren del ensamble de modelos denominados híbridos.

Varios de los autores citados en esta revisión, utilizan parámetros o criterios de evaluación del desempeño, los mismos que se han utilizado para medir el rendimiento de los modelos, como el Nash–Sutcliffe Efficiency (NSE), el Coefficient of correlation (R), el coefficient of determination (R^2) y el root mean square error (RMSE), por ejemplo [33] estimo lluvia tropical obteniendo un valor de NSE de 0.85 considerado como un buen resultado, debido a que se encuentra entre . Es necesario indicar que otros parámetros como el RMSE son satisfactorios si su valor tiende a 0 [23].

En suma, muchos de estos trabajos generan avances en el modelamiento hidrológico, tomando como base a las RNA que, al combinarlas con otras técnicas hacen más eficiente su desempeño para responder a la transformación que está sucediendo en la hidrología debido a los cambios meteorológicos que ocurren en el planeta motivados por el cambio climático que afectan la seguridad de los recursos hídricos y la población.

5. CONCLUSIONES

En esta revisión se identificó los buenos resultados de la aplicación de técnicas de IA en el campo de la hidrología, debido a que son capaces de ser utilizados en entornos complejos con datos simplificados y además permiten completar la información cuando se tienen datos escasos. Es preciso señalar que las técnicas que se han mencionado en este artículo, han ayudado a solucionar diferentes inconvenientes, que se presentan cuando hay cambios meteorológicos y fenómenos naturales, con resultados significativos, siendo la más destacada las RNA, que desde los años 90 hasta la actualidad sigue siendo uno de las técnicas más aplicadas en la ingeniería civil, dado que este tipo de modelamientos son muy útiles en procesos hidrológicos como lluvia-escorrentía, inundaciones, evapotranspiración, entre otros, toda vez que nos permite tomar medidas de planificación y prevención. Con base en los resultados, se puede afirmar que las RNA hoy en día se siguen implementando en combinación con diferentes técnicas para generar modelos híbridos con el fin de obtener mejores estimaciones.

Finalmente, se puede destacar que las RNA son de gran utilidad e importancia, pues, como se ha verificado de acuerdo con los diferentes resultados, este tipo de técnicas de IA en comparación a los métodos tradicionales requeriría menos tiempo de respuesta, y el aprovechamiento de los recursos hídricos sería mayor. Asimismo, el aprovechamiento de nuevas técnicas permitirá un mayor avance en la ingeniería

civil debido a las ventajas ya mencionadas líneas arriba, pues a pesar de que no es una técnica moderna, muchos de los profesionales y empresas desconocen sus ventajas.

6. REFERENCIAS

- [1] I. Ayala, J. Oré, D. Requena, R. Oré, E. Torres and E. Montes, "Flow routing in the natural channel of the Ichu river experimental basin through artificial neural networks," *Journal of Environmental Science and Engineering*, vol. 7, pp. 387-403, 2018. DOI: <https://doi.org/10.17265/2162-5298/2018.10.001>
- [2] S. K. Mishra, S. Rupper, S. Kapnick, H. G. Chan, E. Ciraci, U. Haritashya, J. Hayse, J. S. Kargel, R. B. Kayastha, N. Y. Krakauer, S. V. Kumar, R. B. Lammers, V. Maggioni, S. A. Margulis, M. Olson, B. Osmanoglu, Y. Qian, S. McLarty, K. Rittger, D. R. Rounce, D. Shean, I. Velicogna, T. D. Veselka and A. Arendt, "Grand challenges of hydrologic modeling for food-energy-water nexus security in high mountain Asia," *Frontiers in Water*, vol. 3, 2021, DOI: <https://doi.org/10.3389/frwa.2021.728156>.
- [3] J. Rodrigo Comino, M. López Vicente, V. Kumar, A. Rodríguez Seijo, O. Valkó, C. Rojas, H. Reza Pourghasemi, L. Salvati, N. Bakr, E. Vaudour, E. C. Brevik, M. Radziemska, M. Pulido, S. Di Prima, M. Dondini, W. De Vries, E. S. Santos, M. d. L. Mendonça Santos, Y. Yu and P. Panagos, "Soil science challenges in a new era: A transdisciplinary overview of relevant topics," *Air, Soil and Water Research*, vol. 13, pp. 1-17, 2020, doi: 10.1177/1178622120977491.
- [4] R. Zhang, R. Zen, J. Xing, D. M. S. Arsa, A. Saha and S. Bressan, "Hydrological process surrogate modelling and simulation with neural networks," *Advances in Knowledge Discovery and Data Mining*, vol. 12085, p. 449-461, 2020, doi:10.1007/978-3-030-47436-2_34.
- [5] Y. Liu, T. Zhang, A. Kang, J. Li and X. Lei, "Research on runoff simulations using deep-learning methods," *Sustainability*, vol. 13, no. 3, pp. 1336-1356, 2021, doi:10.3390/su13031336.
- [6] A. Nath, F. Mthethwa and G. Saha, "Runoff estimation using modified adaptive neuro-fuzzy inference system," *Environmental Engineers*, vol. 25, no. 4, pp. 545-553, 2020, doi:10.4491/eer.2019.166.
- [7] E. M. Villena Martínez, J. I. Torregrosa Lopez and V. G. Lo Iacono Ferreira, "State of the art of hydrological models and suitability in basins with limited information," *22nd International Congress on Project Management and Engineering*, pp. 4-13, 2018.
- [8] C. Hu, Q. Wu, H. Li, S. Jian, N. Li and Z. Lou, "Deep learning with a long short-term memory networks approach for rainfall-runoff simulation," *Water*, vol. 10, no. 11, pp. 1543-1558, 2018, doi:10.3390/w10111543.
- [9] F. Kratzert, D. Klotz, M. Herrnegger, A. K. Sampson, S. Hochreiter and G. S. Nearing, "Toward improved predictions in ungauged basins: Exploiting the power of machine learning," *Water Resources Research*, vol. 55, no. 12, pp. 11344-11354, 2019, doi:10.1029/2019WR026065.
- [10] H. Fan, M. Jiang, L. Xu, H. Zhu, J. Cheng and J. Jiang, "Comparison of long short term memory networks and the hydrological model in runoff simulation," *Water*, vol. 12, no. 1, pp. 175-190, 2020, doi:10.3390/w12010175.
- [11] Y. Chih Chieh, L. Wen Cheng and C. Chung-En, "Genetic algorithm and fuzzy neural networks combined with the hydrological modeling system for forecasting watershed runoff discharge," *Neural Computing and Applications*, vol. 26, pp. 1631-1643, 2015, doi:10.1007/s00521-015-1832-0.

- [12] A. Mosavi, "Flood prediction using machine learning models: Literature review," *Atmospheric Science*, 2020.
- [13] B. K. Roodsari, D. G. Chandler, C. Kelleher and C. N. Kroll, "A comparison of SAC-SMA and ANFIS for real-time flood forecasting in small urban catchments," *Journal of Flood Risk Management*, vol. 12, no. S1, pp. 12492- 12505, 2019, doi:10.1111/jfr3.12492.
- [14] P. Jimeno, J. Senent, J. Pérez, D. Pulido and J. M. Cecilia, "Estimation of instantaneous peak flow using machine-learning models and empirical formula in peninsular Spain," *Water*, vol. 9, no. 5, pp. 347-359, 2017, doi:10.3390/w9050347.
- [15] B. Banadkooki Fatemeh, V. P. Singh and M. Ehteram, "Multi-timescale drought prediction using new hybrid artificial neural network models network models," *Natural Hazards*, vol. 106, no. 3, pp. 2461-2478, 2021, doi:10.1007/s11069-021-04550-x.
- [16] M. Hashemi and A. R. Sepaskhah, "Evaluation of artificial neural network and penman-monteith equation for the prediction of barley standard evapotranspiration in a semi-arid region," *Theoretical and Applied Climatology*, vol. 139, pp. 275-285, 2020, doi:10.1007/s00704-019-02966-x.
- [17] Z. M. Yaseen, S. Naghshara, S. Q. Salih, S. Kim, A. Malik and M. A. Ghorbani, "Lake water level modeling using newly developed hybrid data intelligence model," *Theoretical and Applied Climatology*, vol. 141, pp. 1285-1300, 2020, doi:10.1007/s00704-020-03263-8.
- [18] N. Nabipour, M. Dehghani, S. Shamshirband and A. Mosavi, "Short-term hydrological drought forecasting based on different nature-inspired optimization algorithms hybridized with artificial neural networks," *IEEE Access*, vol. 8, no. 8951168, pp. 15210-15222, 2020, doi:10.1109/ACCESS.2020.2964584.
- [19] M. Getachew Mehabie and L. Yuei An, "Application of artificial neural networks in forecasting a standardized precipitation evapotranspiration index for the upper blue Nile basin," *Water*, vol. 12, no. 3, pp. 643-661, 2020, doi:10.3390/w12030643.
- [20] M. K. Nema, D. Khare and S. K. Chandniha, "Application of artificial intelligence to estimate the reference evapotranspiration in sub-humid Doon valley," *Applied Water Science*, vol. 7, pp. 3903-3910, 2017, doi:10.1007/s13201-017-0543-3.
- [21] S. Mehdizadeh, J. Behmanesh and K. Khalili, "Evaluating the performance of artificial intelligence methods for estimation of monthly mean soil temperature without using meteorological data," *Environmental Earth Sciences*, vol. 76, no. 325, pp. 1-16, 2017, doi:10.1007/s12665-017-6607-8.
- [22] S. Jae Young and L. Sang Il, "Spatio-temporal groundwater drought monitoring using multi-satellite data based on an artificial neural network," *Water*, vol. 11, no. 9, pp. 1953-1972, 2019, doi:10.3390/w11091953.
- [23] J. Sulaiman and S. H. Wahab, "Heavy rainfall forecasting model using artificial neural network for flood prone area," *Soft Computing and Intelligent System Research Group*, vol. 449, pp. 68-76, 2018, doi:10.1007/978-981-10-6451-7_9.
- [24] E. Selim Koksai, B. Cemek, S. Cetin, P. H. Gowda and T. A. Howell, "Estimating missing hourly climatic data using artificial neural network for energy balance based ET mapping applications," *Meteorological Applications*, vol. 24, no. 3, pp. 457-465, 2017, doi:10.1002/met.1644.
- [25] L. Gun, K. Dongkyun, K. Hyun-Han and C. Eunsoo, "Estimation of maximum daily fresh snow accumulation using an artificial neural network model," *Advances in Meteorology*, vol. 2019, no. 2709351, pp. 1-11, 2019, doi:10.1155/2019/2709351.
- [26] W. Laqui, R. Zubieta, P. Rau, A. Mejía, W. Lavado and E. Ingol, "Can artificial neural networks estimate potential evapotranspiration in Peruvian highlands?," *Modeling Earth Systems and Environment*, vol. 5, p. 1911-1924, 2019, doi:10.1007/s40808-019-00647-2.
- [27] Y. Z. Kaya, M. Zelenakova, F. Üneş, M. Demirci and H. Hlavata, "Estimation of daily evapotranspiration in Košice City (Slovakia) using several soft computing techniques," *Theoretical and Applied Climatology*, vol. 144, no. 1-2, pp. 287-298, 2021, doi:10.1007/s00704-021-03525-z.
- [28] R. Muhammad Adnan, S. Heddham, Z. Mundher Yaseen, S. Shahid, O. Kisi and B. Li, "Prediction of potential evapotranspiration using temperature-based heuristic approaches," *Sustainability*, vol. 13, no. 1, pp. 297-318, 2021, doi:10.3390/su13010297.
- [29] K. I. Muhammad Mohd, S. Shamsuddin, I. Tarmizi, H. Sobri and O. Kisi, "The development of evolutionary computing model for simulating reference evapotranspiration over Peninsular Malaysia," *Theoretical and Applied Climatology*, vol. 144, no. 3-4, pp. 1419-1434, 2021, doi:10.1007/s00704-021-03606-z.
- [30] M. Vaghefi, K. Mahmoodi, S. Setayeshi and M. Akbari, "Application of artificial neural networks to predict flow velocity in a 180° sharp bend with and without a spur dike," *Soft Computing*, vol. 24, no. 12, pp. 8805-8821, 2019, doi:10.1007/s00500-019-04413-5.
- [31] A. A. Masrur Ahmed, R. C. Deo, N. Raj, A. Ghahramani, Q. Feng, Z. Yin and L. Yang, "Deep learning forecasts of soil moisture: Convolutional neural network and gated recurrent unit models coupled with satellite-derived MODIS, observations and synoptic-scale climate index data," *Remote Sensing*, vol. 13, no. 4, pp. 554-584, 2021, doi:10.3390/rs13040554.
- [32] V. Nourani, G. Elkiran and J. Abdullahi, "Multi-station artificial intelligence based ensemble modeling of reference evapotranspiration using pan evaporation measurements," *Journal of Hydrology*, vol. 557, pp. 1-20, 2019, doi: 10.1016/j.jhydrol.2019.123958.
- [33] A. Girma Berhe, H. Birtukan Abebe, G. Belay Manjur, S. Cholho and L. Woo-Kyun, "Integrating satellite rainfall estimates with hydrological water balance model: Rainfall-runoff modeling in Awash river basin, Ethiopia," *Water*, vol. 13, no. 6, pp. 800-819, 2021, doi:10.3390/w13060800.
- [34] K. Manish, K. Anuradha, D. Prakash Kushwaha, K. Pravendra, M. Anurag, A. Rawshan and A. Kuriqi, "Estimation of daily stage-discharge relationship by using data-driven techniques of a perennial river, India," *Sustainability*, vol. 12, no. 19, 2020, doi:10.3390/su12197877.
- [35] A. Hassan, F. Aitazaz, A. Farhat, A. Bishnu and E. Travis, "Groundwater estimation from major physical hydrology components using artificial neural networks and Deep Learning," *Water*, vol. 12, no. 1, pp. 5-23, 2020, doi:10.3390/w12010005.
- [36] W. E. Béjar, K. Y. Valeriano, J. C. Ilachoque and J. Sulla, "Predicción de caudales medios diarios en la cuenca del Amazonas aplicando redes neuronales artificiales y el modelo neurodifuso ANFIS," *Research in Computing Science*, vol. 113, no. 2016, pp. 23-35, 2016, doi:10.13053/rcs-113-1-2.
- [37] R. Tabbussum and A. Qayoom Dar, "Comparison of fuzzy inference algorithms for stream flow prediction," *Neural Computing and Applications*, vol. 33, pp. 1643-1653, 2020, doi:10.1007/s00521-020-05098-w.

- [38] A. Fernández López, D. Marín Sánchez, G. García Mateos, A. Ruiz Canales, M. Villena García and J. M. Molina Martínez, "A machine learning method to estimate reference evapotranspiration using soil moisture sensors," *Applied Sciences*, vol. 10, no. 6, pp. 1912-1928, 2020, doi:10.3390/app10061912.
- [39] A. Rashid Niaghi and X. Jia, "New approach to improve the soil water balance method for evapotranspiration estimation," *Water*, vol. 11, no. 12, pp. 2478-2493, 2019, doi:10.3390/w11122478.
- [40] D. Kumar Roy, R. Barzegar, J. Quilty and J. Adamowski, "Using ensembles of adaptive neuro-fuzzy inference system and optimization algorithms to predict reference evapotranspiration in subtropical climatic zones," *Journal of Hydrology*, vol. 591, pp. 1-18, 2020, doi:10.1016/j.jhydrol.2020.125509.
- [41] J. P. Omolbani Mohammadrezapour and K. Ozgur, "Comparison of SVM, ANFIS and GEP in modeling monthly potential evapotranspiration in an arid region (Case study: Sistan and Baluchestan Province, Iran)," *Water Science and Technology: Water Supply*, vol. 19, no. 2, pp. 392-403, 2019, doi:10.2166/ws.2018.084.
- [42] M. R. Hassanvand, H. Karami and S.-F. Mousavi, "Investigation of neural network and fuzzy inference neural network and their optimization using meta-algorithms in river flood routing," *Natural Hazards*, vol. 94, no. 3, pp. 1057-1080, 2018, doi:10.1007/s11069-018-3456-z.
- [43] J. Noymanee and T. Theeramunkong, "Flood forecasting with machine learning technique on hydrological modeling," *Procedia Computer Science*, vol. 156, pp. 377-386, 2019, doi: 10.1016/j.procs.2019.08.214.
- [44] G. Nearing, F. Kratzert, C. Pelissier, D. Klotz, J. Frame and H. Gupta, "Machine learning is central to the future of hydrological modeling," *EGU General Assembly*, 2020, doi:10.5194/egusphere-egu2020-6111.
- [45] Y. Chih Chieh and L. Wen Cheng, "Prediction and modelling of rainfall-runoff during typhoon events using a physically-based and artificial neural network hybrid model," *Hydrological Sciences Journal*, vol. 60, no. 12, pp. 2102-2116, 2015, doi:10.1080/02626667.2014.959446.
- [46] C. Rodríguez, H. Díaz, J. Ballesteros, M. Rohrer and M. Stoffel, "The anomalous 2017 coastal el niño event in Peru," *Climate Dynamics*, vol. 52, no. 9-10, p. 5605-5622, 2019, doi:10.1007/s00382-018-4466-y.
- [47] C. A. Montesinos Cáceres, *Modelamiento hidrológico mensual distribuido para el monitoreo de sequías hidrológicas en la vertiente hidrográfica del Atlántico*, Lima: Servicio Nacional De Meteorología E Hidrología Del Perú-Senamhi, 2019.
- [48] G. Blöschl, M. F. Bierkens, A. Chambel, C. Cudennec, G. Destouni, A. Fiori, J. W. Kirchner, J. J. McDonnell, H. H. G. Savenije, M. Sivapalan, C. Stumpp, E. Toth, E. Volpi and G. Carr, "Twenty-three unsolved problems in hydrology (UPH) – a community perspective," *Hydrological Sciences Journal*, vol. 64, no. 10, p. 1141-1158, 2019, doi:10.1080/02626667.2019.1620507.
- [49] G. Barrientos, A. Herrero, A. Iroumé, O. Mardones and R. J. Batalla, "Modelling the effects of changes in forest cover and climate on hidrology of headwater catchments in south-central Chile," *Water*, vol. 12, no. 6, pp. 1828-1850, 2020, doi:10.3390/w12061828.
- [50] J. J. Cabrera Balarezo, L. Timbe and P. Crespo, "Evaluation of the HEC-HMS model for the hydrological simulation of a paramo basin," *Dyna*, vol. 86, no. 210, pp. 338-344, 2019, doi:10.15446/dyna.v86n210.70738.
- [51] H. Fang and Z. Fan, "Impacts of climate and land use changes on water and sediment yields for the black soil region, northeastern China," *Environment, Development and Sustainability*, vol. 23, p. 6259-6278, 2020, doi:10.1007/s10668-020-00871-2.
- [52] J. F. Farfán, K. Palacios, J. Ulloa and A. Avilés, "A hybrid neural network-based technique to improve the flow forecasting of physical and data-driven models: Methodology and case studies in Andean watersheds," *Journal of Hydrology: Regional Studies*, vol. 27, 2020, doi:10.1016/j.ejrh.2019.100652.
- [53] F. Kratzert, D. Klotz, G. Shalev, G. Klambauer, S. Hochreiter and G. Nearing, "Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets," *Hydrology and Earth System Sciences*, vol. 23, no. 12, pp. 5089-5110, 2019, doi:10.5194/hess-23-5089-2019.
- [54] A. Mosavi, P. Ozturk and K.-w. Chau, "Flood prediction using machine learning models: Literature review," *Water*, vol. 10, no. 11, pp. 1536-1576, 2018, doi:10.3390/w10111536.
- [55] I. Orozco, F. Francés and J. Mora, "Parsimonious modeling of snow accumulation and snowmelt processes in high mountain basins," *Water*, vol. 11, no. 6, pp. 1288-1307, 2019, doi:10.3390/w11061288.
- [56] A. Madueño, M. López, J. Estévez and J. V. Giráldez, "Validación de datos hidrológicos con redes neuronales artificiales. Aplicación a niveles en ríos," *II Simposio Nacional de Ingeniería Hortícola: Automatización y TICS en agricultura*, 2016.
- [57] S. Dazzi, R. Vacondio and P. Mignosa, "Flood stage forecasting using machine-learning methods: A case study on the Parma river (Italy)," *Water*, vol. 13, no. 12, pp. 1612-1634, 2021, doi:10.3390/w13121612.