

Revisión sistemática sobre la aplicación de algoritmos de machine learning con técnicas de descomposición de señales para predecir precipitaciones y/o escorrentías

Carlo Giovanni Cetina Camacho
Universidad Autónoma de Querétaro
carlo.cetina@uaq.edu.mx
ORCID: 0009-0001-5908-5075

Hugo Jiménez Hernández
Universidad Autónoma de Querétaro
hugo.jimenez@uaq.edu.mx
ORCID: 0000-0003-0827-6645

Resumen— La predicción precisa de precipitaciones y escorrentías es esencial para la gestión de recursos hídricos, la planificación agrícola, la prevención de desastres naturales, y la toma de decisiones en diversos sectores. Debido a esto, diferentes métodos de machine learning (ML) han sido utilizados como una alternativa eficaz a los modelos meteorológicos tradicionales. Sin embargo, la dinámica que presentan las señales obtenidas a partir de estos fenómenos naturales es compleja y difícil de procesar. Por lo que, esta revisión sistemática estudia modelos que integran algoritmos de ML con técnicas de descomposición de señales con la finalidad de obtener una mejor precisión en la predicción. Las técnicas de descomposición de señales como Wavelet Transform (WT) y Empirical Mode Decomposition (EMD) han aparecido en el 33.3% y el 41.6% de los artículos analizados, respectivamente, mientras que la técnica Variational Mode Decomposition (VMD) representa el 25%. El análisis ha abarcado estudios que tienen un horizonte de predicción diaria, mensual o anual, en el que predomina la predicción mensual con un 83.3% del enfoque total. Así mismo, los algoritmos de predicción con enfoque hacia las redes neuronales como Convolutional Neural Network (CNN), Extreme Learning Machine (ELM), Multilayer Perceptrón (MLP) y Backpropagation Neural Network (BNN) han surgido como las opciones predominantes, representando colectivamente el 75% de los estudios.

Index Terms—predicción, descomposición, precipitación, escorrentías, series-temporales.

I. INTRODUCCIÓN

La predicción precisa de precipitaciones ha tomado más importancia con el paso de los años. Esto debido a que impacta directamente en diferentes áreas de la vida del ser humano y de los ecosistemas en general. Como lo son la gestión de recursos hídricos, la planificación agrícola, la prevención de desastres naturales, la protección de la infraestructura, entre otros. Sin embargo, debido a la naturaleza compleja y dinámica de los sistemas atmosféricos, predecir las precipitaciones sigue siendo un desafío significativo en meteorología.

Como resultado de esto, la Inteligencia Artificial (IA) ha emergido como una herramienta para abordar estos desafíos. Los algoritmos de IA, incluyendo técnicas de *Machine Learning* (ML) y *Deep Learning* (DL), han demostrado una capacidad notable para procesar grandes volúmenes de datos y captar patrones complejos no lineales, que son comunes en los fenómenos atmosféricos.

No obstante, a pesar de las crecientes investigaciones en esta área, la integración de la IA en la predicción de precipitaciones sigue siendo un campo en evolución debido a que los sistemas del mundo real presentan relaciones o patrones de dependencia que existen entre los valores en diferentes momentos en el tiempo. Es decir, los valores actuales de un sistema pueden estar influenciados por los valores pasados o futuros del mismo sistema. La presencia de dependencias temporales ha dado paso a la organización de los datos experimentales, obtenidos a partir de análisis, en una secuencia de datos observados en intervalos de tiempo sucesivos. Los cuales son referidos como series temporales y se recogen en puntos específicos en el tiempo y reflejan cómo una variable cambia o evoluciona a lo largo de éste [1].

Una serie temporal también puede ser definida como una señal en ciertas ocasiones. En términos generales, una señal es cualquier conjunto de datos que varía en el tiempo o en el espacio y que puede ser analizado para extraer información. Cuando estos datos se organizan en función del tiempo, las señales también pueden ser denominadas series de tiempo [2].

El análisis de señales es un campo que se enfoca en la interpretación, manipulación y extracción de información y es fundamental en diversas disciplinas científicas y tecnológicas, abarcando áreas como la ingeniería eléctrica, el procesamiento de imágenes, la biomedicina y la economía. Las señales, que representan variaciones de magnitudes físicas o abstractas en el tiempo o el espacio, contienen información importante que, al ser analizada correctamente, puede revelar patrones, tendencias, y anomalías significativas. Así mismo, dicha información es útil en diferentes métodos que engloba el área de la inteligencia artificial, debido a que se puede llegar a utilizar tanto para predecir como para clasificar tendencias que presenta algún sistema meteorológico.

Sin embargo, la naturaleza intrínseca de muchas señales, que a menudo son no lineales y no estacionarias, presenta un desafío considerable para su análisis e interpretación. Lo que provoca que no sea sencillo de implementar en un método de predicción.

A lo largo de las últimas décadas, se han desarrollado una variedad de técnicas para abordar estos desafíos. Desde métodos clásicos como *Fourier Transform* (FT), que descompone las señales en sus componentes de frecuencia, hasta enfoques más avanzados como *Empirical Mode Decomposition* (EMD), *Wavelet Transform* (WT) y

Variational Mode Decomposition (VMD). Cada técnica ofrece ventajas específicas en función del tipo de señal y del contexto de la aplicación. Estas técnicas no solo permiten descomponer y analizar señales, sino que también facilitan la eliminación de ruido, la compresión de datos, y la detección de características clave.

A través de una revisión crítica de la literatura existente, se pretende identificar las tendencias actuales y las áreas emergentes en el campo, así como ofrecer una guía sobre la selección de técnicas apropiadas según las características de las señales, el modelo de predicción y los objetivos del análisis. Esta revisión no solo servirá como un recurso para investigadores y profesionales en el campo de predicción y análisis de señales, sino que también proporcionará una base para futuras investigaciones, sugiriendo posibles direcciones en las que la combinación o mejora de estas técnicas podría ofrecer nuevas capacidades y aplicaciones.

De acuerdo con el estado del arte, existen varios trabajos de revisión acerca de la predicción de series temporales mediante métodos de ML y DL [3],[4],[5]. Sin embargo, en estos trabajos no se aborda la sinergia entre estos modelos y técnicas de descomposición de señales. Por lo que el propósito de esta revisión sistemática es proporcionar un panorama exhaustivo de las principales técnicas utilizadas para la descomposición de señales en trabajos que tienen como objetivo la predicción de precipitaciones o de escorrentías, evaluando su aplicabilidad, ventajas, y precisión.

El artículo está organizado de la siguiente manera. La sección I proporciona una introducción al tema, destacando antecedentes e importancia. Así mismo, describe las contribuciones previstas de este artículo. La sección II describe la metodología usada para realizar la revisión sistemática de la literatura. La sección III presenta un resumen de los artículos centrados en utilizar algoritmos de ML con técnicas de descomposición de señales para la predicción de lluvias o escorrentías. En la sección IV se encuentra la discusión de las características clave empleadas en los trabajos recolectados, incluidos los algoritmos de ML para la predicción, las técnicas de descomposición, los horizontes de predicción, métricas de evaluación y el enfoque. Las conclusiones, sugerencias futuras obtenidas a partir del desarrollo de este artículo, así como las referencias bibliográficas, se encuentran en la sección V.

II. METODOLOGÍA

En esta sección se describen los procedimientos empleados para la recopilación, evaluación y análisis de la literatura en la revisión sistemática. La cual se desarrolló utilizando el método *Preferred Reporting Items for Systematic reviews and Meta-Analyses* (PRISMA) [6]. La Fig. 1 muestra un análisis de los documentos publicados anualmente entre 2017 y 2024, según la técnica de descomposición de señales utilizada. Para realizar esta revisión sistemática sobre la aplicación de técnicas de descomposición de señales en la predicción de precipitaciones, se llevó a cabo una búsqueda exhaustiva en la base de datos científica: Scopus, conocida por su cobertura amplia y multidisciplinaria; así como por la calidad de los estudios que contiene. Además, se establecieron los criterios de inclusión y exclusión. Para los de **inclusión**:




Figura 1. Reporte de publicación desde 2017 hasta 2024.

- La búsqueda incluyó artículos publicados desde 2017 hasta 2024, con el fin de capturar las investigaciones más recientes en este campo.
- Se aplicaron filtros para restringir los estudios a aquellos publicados en inglés y español asegurando la accesibilidad del material referenciado.
- Se limitó a considerar únicamente publicaciones que emplean técnicas de descomposición de señales en la predicción de precipitaciones o escorrentías, así como estudios que combinen estas técnicas con algoritmos de ML.
- Se revisaron artículos que manejaban evaluaciones cuantitativas de los resultados obtenidos en términos de métricas comunes de predicción.

En cuanto a los criterios de **exclusión**:

- Artículos que no aplicaran directamente las técnicas de descomposición de señales para la predicción de precipitaciones, sino para otros fenómenos meteorológicos o contextos no relacionados.
- Se excluyeron trabajos que no fueran artículos.
- Artículos que no pertenecían a las subáreas de matemáticas, ingeniería o computación.

Así mismo, se emplearon palabras clave como “*precipitation*”, “*decomposition*”, “*prediction*”, “*forecasting*”, así como nombres de técnicas de descomposición y de métodos de ML y DL, con la finalidad de incluir los estudios más relevantes para los objetivos de la revisión. Las palabras clave se combinaron con los siguientes operadores lógicos para filtrar la búsqueda:

- “*precipitation*” OR “*runoff*” AND “*forecasting*”.
- “*rainfall prediction*” AND “*wavelet transform*” OR “*Fourier transform*”.
- “*machine learning*” AND “*signal decomposition techniques*” AND “*precipitation*”.
- “*empirical mode decomposition*” AND “*weather prediction*”.

Para la selección y filtrado de los estudios se aplicó el diagrama de la Fig. 2. Inicialmente se recopilieron 64 artículos, de los cuales solo 12 cumplieron con los criterios establecidos. Entre ellos, el año de publicación, las subáreas a las que pertenece el trabajo, tipo de documento, el lenguaje y la exclusión de trabajos que no estuvieran relacionados con precipitaciones o que no usaban alguna técnica de descomposición de señales. Además, este artículo también aborda los siguientes puntos:

- ¿Qué métodos de IA se utilizan frecuentemente para la predicción de precipitaciones y/o escorrentías?
- ¿Cuáles son las métricas de evaluación más usadas para los modelos de predicción de precipitaciones y/o escorrentías?
- ¿Qué técnicas de descomposición de señales son las más usadas para integrar con un método de predicción?

A partir de las palabras clave de los trabajos investigados se obtuvo la representación visual de la red bibliométrica de los autores, la cual se desarrolló con la herramienta VOSviewer y revela 3 grupos importantes, como se muestra en la Fig. 3.

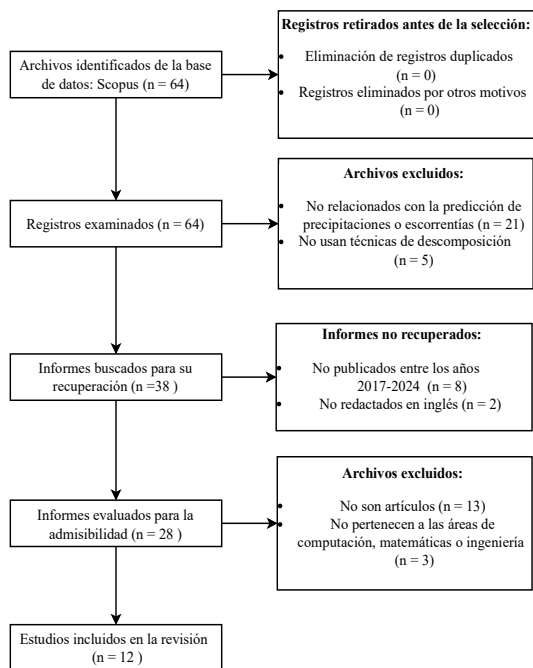


Figura 2. Diagrama de flujo PRISMA adaptado

Esta visualización ayuda a entender los patrones de las palabras claves encontradas en los diferentes estudios, lo que proporciona una comprensión intuitiva de la relación de los temas de investigación tratados en la revisión. El grupo azul contiene el nodo con la palabra clave EMD, el cual es el que tiene más relaciones tanto con otras técnicas de descomposición como con los algoritmos de ML. El grupo rojo pertenece a los algoritmos ML que están relacionados con las técnicas de descomposición. Por último, el grupo verde muestra las diferentes técnicas de descomposición de señales utilizadas en los diferentes estudios.

III. RESULTADOS

En esta sección se describen diversos estudios, encontrados en la literatura, para predecir precipitaciones y escorrentías de lluvia mediante modelos de ML, haciendo uso de algún método de descomposición de señales para su optimización. En la Tabla 1 se muestra una comparación de los artículos recuperados, así como los algoritmos de predicción, la técnica de descomposición, el horizonte de predicción, los resultados y el enfoque que utilizó cada uno.

A. WT

Múltiples estudios han implementado WT junto con diferentes modelos de ML con el fin de mejorar la precisión eficiencia de las predicciones, debido a que ofrece la ventaja de proporcionar información tanto en el dominio del tiempo como en el de la frecuencia, lo que la hace ideal para analizar señales no estacionarias y con cambios repentinos.

La referencia [7] desarrolló un modelo para la predicción de precipitaciones sobre la cuenca del río Langat en Selangor, Malasia. Usaron *Convolutional Neural Network* (CNN) y la WT, específicamente la *Daubechis Wavelet* (DB). Los autores reportan una mejora significativa en la precisión de las predicciones al utilizar el modelo integrado. El orden elegido para DB fue de 5 (db5) para obtener un nivel de descomposición final de 4.4. El modelo obtuvo una *Root Mean Square Error* (RMSE) de 22.02 mm y un *Mean Absolute Error* (MAE) de 16.68 mm para la predicción mensual. Y una RMSE de 2.6 mm y un MAE de 1.77 mm para la predicción diaria.

La referencia [8] presentó un modelo para predecir precipitaciones al sur de la península Ibérica, en la comunidad de Andalucía. Haciendo uso de la DB, con un orden de db5, para la descomposición y *Multilayer Perceptron* (MLP), con 8 capas ocultas para la predicción mensual. Los resultados mostraron RMSE de 21.49 mm y *Mean Absolute Percentage Error* (MAPE) de 23.61%.

La referencia [9] llevó a cabo un estudio en el que compara WT con *Seasonal Decomposition* (SD), usando *Artificial Neural Network* (ANN) para la predicción mensual de precipitaciones. Se utilizó DW con un orden de 4 (db4) y un total de 3 neuronas para la red neuronal. Se encontró que el modelo que utilizó WT (RMSE de 45.4499 mm y MAE de 34.4683 mm) fue más preciso que el que empleó SD (RMSE de 94.8184 mm y MAE de 68.5089 mm).

La referencia [10] implementó un modelo para la predicción mensual del caudal (por medio de datos de precipitaciones) de una cuenca del río Jinsha, China. Se utilizó *Backpropagation Neural Network* (BNN) integrada con la WT. Con una DW de orden 3 (db3) se muestra que la descomposición de la serie temporal contribuye a mejorar la precisión de la predicción del caudal. Obteniendo valores de 660 m³/s para RMSE, 423 m³/s para MAE y 13% en MAPE.

B. EMD

Diferentes investigaciones han integrado EMD con distintos algoritmos de predicción con el objetivo de mejorar la precisión, debido a que es una técnica de análisis de señales utilizada para descomponer señales no lineales y no estacionarias en componentes más simples, conocidos como *Intrinsic Mode Function* (IMF). A diferencia de otras técnicas de descomposición como la FT o la WT, que requieren suposiciones sobre la periodicidad o la base de descomposición, la EMD es completamente adaptativa, lo que la hace buena opción ante señales complejas que varían en el tiempo.

En [11] se desarrolló un modelo híbrido integrando *Random Forest* (RF) y *Kernel Ridge Regression* (KRR) para la predicción mensual de precipitaciones y EMD para el preprocesamiento y descomposición de la señal. El estudio se llevó a cabo a partir de datos recolectados del Departamento Meteorológico de Pakistán y se aplicó en 3 diferentes regiones. En la región de Gilgit el modelo obtuvo 9 IMFs y una señal de residuo y demostró tener mejores resultados que

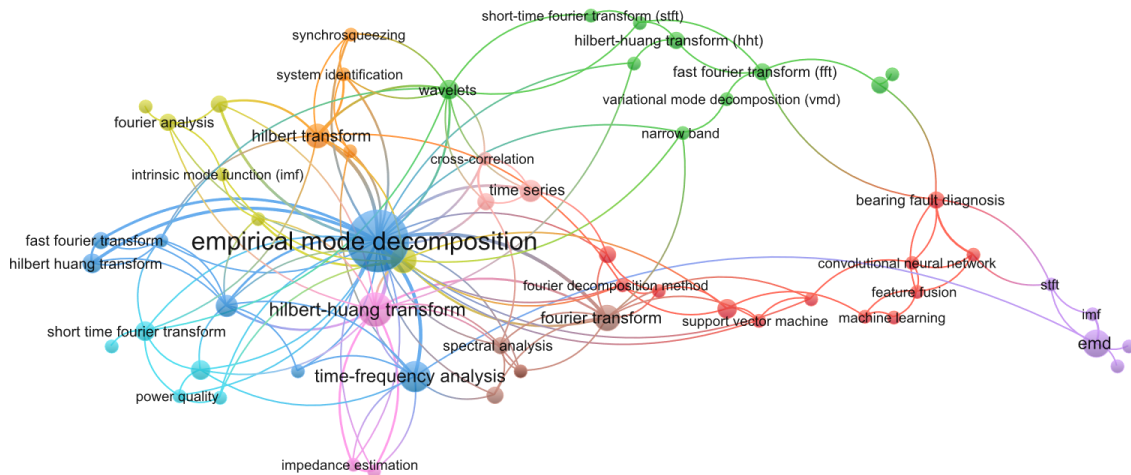


Figura 3. Red bibliométrica de palabras clave en la literatura, para la predicción de precipitaciones y/o escorrentía

la aplicación de RF y KRR por sí solos. Obteniendo 2.52 mm en RMSE y 1.98 mm en MAE

En el estudio hecho por [12], se desarrolló un modelo híbrido para la predicción de precipitaciones, combinando BNN (en donde se utilizó la función de activación sigmoide) con EMD. La etapa de descomposición presentó 5 IMFs más el residuo. Esta propuesta utilizó datos recolectados en distintas estaciones meteorológicas en la India, demostrando un rendimiento de 34.28 mm en MAE y 0.14 en RMSE normalizado (NRMSE).

La referencia [13] presenta un modelo híbrido que utiliza EMD para descomponer la señal original, *Support Vector Regression* (SVR) como componente para las predicciones de periodos cortos y BNN para las predicciones de periodos largos. El análisis se aplicó en 3 diferentes estaciones meteorológicas localizadas en Kuming, Lincang y Megnzi, China. Mediante la EMD se obtuvieron 8 IMFs y otra de residuo. De las cuales IMF₁ Se utilizó para la predicción en un periodo corto, y las restantes para la predicción en un periodo largo. En la ciudad de Megnzi, el modelo logro un RMSE de 21.1878 mm y un MAE de 16.7503 mm.

El estudio [14] propone un modelo para la predicción mensual de caudales, provenientes de lluvias, especialmente para temporadas de inundaciones. Para llevar a cabo el estudio se seleccionaron 3 estaciones (Ertan, Yichang and Cuntan stations) a lo largo del río Yangtze, China. Y se Integró BNN con EMD para obtener mejores resultados. La BNN se conformó de 9 capas ocultas y la señal original se descompuso en un total de 9 componentes, 8 IMFs y un residuo. El rendimiento del modelo en la estación de Ertan fue de 378 m³/s y 259 m³/s para el RMSE Y MAE, respectivamente.

En [15] se presenta un estudio que integra EMD con *Stepwise Linear Regression* (SLR) para la predicción mensual de precipitaciones en diferentes regiones de la India. Se obtuvieron 6 IMFs y un residuo mediante EMD y los resultados indicaron un valor de 55.668 mm para RMSE.

C. VMD

A pesar de que EMD y WT son las técnicas más utilizadas, existen otras que se han aplicado de manera exitosa para la predicción tanto de precipitaciones como de escorrentías, como es el caso de VMD

El estudio desarrollado por [16] utilizó *Gradient Boosting Regression Tree* (GBRT), como método de predicción

mensual de escorrentías, y lo integró con VMD para realizar la descomposición de la señal original. Las mediciones fueron obtenidas a partir de 3 diferentes estaciones hidrológicas (Huaxian, Lintong y Xianyang) a lo largo de río Wei, China. En la etapa de descomposición se obtuvieron 7 IMFs y los resultados indicaron, en la estación de Lintong, un MAPE de 13.1542% y un NRMSE de 0.2791.

El artículo [17] propone dos modelos híbridos de ML acoplados con VMD para mejorar la precisión de predicción diaria de precipitaciones y escorrentías. Los modelos de ML utilizados fueron ANN de una sola capa oculta y *Least Squares Support Vector Regression* (LS-SVR). El estudio se llevó a cabo con datos de la cuenca del río Geumho, Corea del Sur. Para este estudio se ocuparon 5 IMFs en la etapa de descomposición. En cuanto a la ANN, se utilizó la función de activación sigmoide. Los resultados obtenidos sugieren un mejor desempeño para el modelo LS-SVR con un RMSE de 2.887 m³/s y un MAE de 1.418 m³/s.

La referencia [18] propone un modelo híbrido para la predicción mensual de precipitaciones basado en VMD acoplado con *Extreme Learning Machine* (ELM). Los datos usados para la investigación fueron recolectados de la ciudad de Yan'an y del monte Huashan, China. La serie original de ambos conjuntos de datos fueron descompuestas en 6 diferentes IMFs. Los valores obtenidos en las métricas de evaluación, en el monte Huashan, fueron 13.5179 mm en MAE y 16.7612mm en RMSE.

IV. DISCUSIÓN

Como se muestra en la Tabla 1, Se observa que la Transformada Wavelet ha sido combinada con diversos modelos de redes neuronales, mostrando resultados variables en términos de error. Al combinar WT con una CNN, se logró un RMSE de 22.02 mm y un MAE de 16.68 mm en la predicción de precipitaciones mensuales, lo que refleja una precisión relativamente buena para este tipo de pronósticos. Las CNN parecen ser eficientes en captar patrones espaciales y temporales complejos.

En combinación con MLP, se obtiene un RMSE más bajo (21.49 mm) en comparación con la CNN, pero el MAPE de 23.61% indica que la precisión relativa es inferior, sugiriendo que la CNN puede ser más efectiva para este conjunto de datos. Sin embargo, cuando ANN se combina con la misma técnica de descomposición, el RMSE aumenta

Tabla 1. Los siguientes artículos integran técnicas de descomposición de señales con algoritmos de ML para la predicción de precipitaciones y/o escorrentías

Autor	Técnica de descomposición	Método de predicción	Horizonte de predicción	Resultados	Aplicación
[7]	WT	CNN	mensual	RMSE 22.02mm y MAE 16.68mm	precipitaciones
[8]	WT	MLP	mensual	RMSE 21.49 mm y MAPE 23.61%	precipitaciones
[9]	WT	ANN	mensual	RMSE 45.4499 mm y MAE de 34.4683 mm	precipitaciones
[10]	WT	BNN	mensual	RMSE 660 m ³ /s, MAE 423 m ³ /s y MAPE 13%	escorrentías
[11]	EMD	RF/KRR	mensual	RMSE 2.52mm y MAE 1.98 mm	precipitaciones
[12]	EMD	BNN	mensual	NRMSE 0.14 y MAE 34.28 mm	precipitaciones
[13]	EMD	SVR/BNN	mensual/anual	RMSE 21.1878 mm y MAE 16.7503 mm	precipitaciones
[14]	EMD	BNN	mensual	RMSE 378 m ³ /s y MAE 259 m ³ /s	escorrentías
[15]	EMD	SLR	mensual	RMSE 55.668 mm	precipitaciones
[16]	VMD	GBRT	mensual	MAPE 13.1542 % y NRMSE 0.2791	escorrentías
[17]	VMD	ELM/LS-SVR	diaria	RMSE 2.887 m ³ /s y MAE 1.418 m ³ /s	escorrentías
[18]	VMD	ELM	mensual	RMSE 16.76122 mm y MAE13.5179 mm	precipitaciones

significativamente a 45.44 mm y el MAE a 34.46 mm, indicando que ANN tiene un rendimiento inferior para la predicción mensual de precipitaciones. Este aumento en el error puede sugerir que las ANN tradicionales tienen limitaciones para capturar los detalles temporales en los datos de precipitación cuando se combinan con la TW.

La descomposición mediante EMD proporciona mejores resultados cuando se combina con modelos más complejos. La combinación de EMD con RF y KRR para la predicción de precipitaciones mensuales logra un RMSE de 2.52 mm y un MAE de 1.98 mm, lo que refleja una buena precisión. Esto sugiere que el EMD, junto con métodos de regresión no lineales, es altamente eficaz para manejar la complejidad de las señales de precipitación.

En combinación con BNN, el NRMSE de 0.14 y el MAE de 34.28 mm para la predicción de precipitaciones mensuales es un resultado intermedio. Aunque el NRMSE es bajo, el MAE relativamente alto puede indicar que, aunque el error relativo es bajo, las diferencias absolutas son más significativas en algunos casos.

En el caso de la escorrentía, la combinación de EMD y BPNN genera un RMSE de 378 m³/s y un MAE de 259 m³/s, lo que sugiere que la predicción de la escorrentía es más difícil que la predicción de las precipitaciones, posiblemente debido a la naturaleza más compleja de los datos de escorrentía.

VMD también demuestra buenos resultados, especialmente cuando se combina con técnicas avanzadas de ML. Al combinar VMD con GBRT para la predicción de escorrentías mensuales, se alcanza un MAPE de 13.15% y un NRMSE de 0.2791, lo que indica una buena capacidad

predictiva. El GBRT es conocido por su capacidad de manejar relaciones complejas y no lineales, lo que parece ser ventajoso en este contexto.

Por otro lado, la combinación de VMD con ELM y LS-SVR para la predicción diaria de escorrentías resulta en un RMSE de 2.887 m³/s y un MAE de 1.418 m³/s, lo que sugiere un buen rendimiento en este horizonte temporal. ELM y LS-SVR se destacan por su capacidad de aprender rápidamente y ajustar de manera eficiente los pesos en redes neuronales, lo que ayuda a reducir los errores de predicción.

De forma general, las técnicas de descomposición, como WT, EMD y VMD, han demostrado ser herramientas para mejorar el rendimiento de los modelos de ML en la predicción de fenómenos naturales como las precipitaciones y la escorrentía. Sin embargo, es evidente que el rendimiento de cada técnica de descomposición depende en gran medida del modelo predictivo con el que se combine.

V. CONCLUSIÓN

En este estudio, la aplicación de técnicas de descomposición de señales, en conjunto con algoritmos de ML para la predicción de precipitaciones o escorrentías, fue explorado. Los resultados han resaltado la eficacia predominante de la técnica EMD, que demostró ser las más usada, representando el 41.6% en la literatura revisada, seguido de cerca por WT con el 33.3%. Esto indica la adaptabilidad de estas técnicas en el tratamiento de señales con dinámica compleja, como es el caso en los datos obtenidos para la predicción de precipitaciones y escorrentías. Los

resultados también muestran que la integración de técnicas de descomposición con algoritmos avanzados de ML mejora significativamente la precisión de las predicciones, al permitir una separación más eficiente de las escalas temporales y la captura de patrones no lineales en las series temporales de datos meteorológicos e hidrológicos.

Además, se observó que las combinaciones de EMD con RF y KRR han mostrado un alto rendimiento en la predicción de precipitaciones mensuales, con bajos valores de RMSE y MAE. Esto sugiere que los enfoques basados en EMD son especialmente adecuados para manejar la dinámica compleja y no linealidad de los datos de precipitación. Por otro lado, la VMD combinada con modelos como GBRT y ELM ha sido particularmente efectiva en la predicción de escorrentías, demostrando la capacidad de estos modelos para capturar tanto las fluctuaciones de corto plazo como las tendencias de largo plazo en este fenómeno.

No obstante, se observan variaciones importantes en el rendimiento de los modelos según el tipo de técnica de descomposición y el algoritmo de ML empleado. Por ejemplo, las CNN muestran un rendimiento sólido cuando se combinan con la WT, mientras que los modelos más tradicionales, como las ANN, presentan mayores errores de predicción, lo que resalta la necesidad de utilizar arquitecturas más complejas para capturar la naturaleza intrínsecamente dinámica de las precipitaciones.

Esta revisión ha resaltado el potencial de las técnicas de descomposición de señales en combinación con ML para mejorar la precisión de las predicciones de precipitaciones y escorrentías. Sin embargo, la elección óptima de las técnicas de descomposición y los modelos predictivos depende del contexto específico y de las características del conjunto de datos. Futuras investigaciones podrían centrarse en optimizar la configuración de estos modelos, explorar nuevas técnicas híbridas y aplicar estas metodologías a diferentes horizontes temporales y espaciales.

AGRADECIMIENTOS

Los autores agradecen sinceramente al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por el apoyo prestado a través de la beca. Los agradecimientos se extienden por financiar el proyecto de investigación.

REFERENCES

[1] Athiyarath, S., Paul, M., & Krishnaswamy, S. (2020). A Comparative Study and Analysis of Time Series Forecasting Techniques. *SN Computer Science*, 1(3). doi:10.1007/s42979-020-00180-5.

[2] Goswami, B. (2019). A Brief Introduction to Nonlinear Time Series Analysis and Recurrence Plots. *Vibration*, 2(4), 332–368. doi:10.3390/vibration2040021.

[3] Chen, J., Zeng, G.-Q., Zhou, W., Du, W., & Lu, K.-D. (2018). Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization. *Energy Conversion*

and *Management*, 165, 681–695. doi:10.1016/j.enconman.2018.03.098.

[4] Hua, Y., Zhao, Z., Li, R., Chen, X., Liu, Z., & Zhang, H. (2019). Deep Learning with Long Short-Term Memory for Time Series Prediction. *IEEE Communications Magazine*, 1–6. doi:10.1109/mcom.2019.1800155.

[5] Lara-Benitez, P., Carranza-Garcia, M., & Riquelme, J. C. (2020). An Experimental Review on Deep Learning Architectures for Time Series Forecasting. *International Journal of Neural Systems*. doi:10.1142/s0129065721300011.

[6] M. J. Page, J. E. McKenzie, P. M. Bossuyt, I. Boutron, T. C. Hoffmann, C. D. Mulrow, L. Shamseer, J. M. Tetzlaff, E. A. Akl, and S. E. Brennan, “The PRISMA 2020 statement: An updated guideline for reporting systematic reviews,” *Int. J. surgery*, vol. 88, Mar. 2020, Art. no. 105906.

[7] Chong, K. L., Lai, S. H., Yao, Y., Ahmed, A. N., Jaafar, W. Z. W., & El-Shafie, A. (2020). Performance Enhancement Model for Rainfall Forecasting Utilizing Integrated Wavelet-Convolutional Neural Network. *Water Resources Management*. doi:10.1007/s11269-020-02554-z.

[8] Estévez, J., Bellido-Jiménez, J. A., Liu, X., & García-Marín, A. P. (2020). Monthly Precipitation Forecasts Using Wavelet Neural Networks Models in a Semiarid Environment. *Water*, 12(7), 1909. doi:10.3390/w12071909.

[9] Tran Anh, D., Duc Dang, T., & Pham Van, S. (2019). Improved Rainfall Prediction Using Combined Pre-Processing Methods and Feed-Forward Neural Networks. *J*, 2(1), 65–83. doi:10.3390/j2010006.

[10] Tayyab, M., Zhou, J., Dong, X., Ahmad, I., & Sun, N. (2017). Rainfall-runoff modeling at Jinsha River basin by integrated neural network with discrete wavelet transform. *Meteorology and Atmospheric Physics*. doi:10.1007/s00703-017-0546-5.

[11] Ali, M., Prasad, R., Xiang, Y., & Yaseen, Z. M. (2020). Complete ensemble empirical mode decomposition hybridized with random forest and Kernel ridge regression model for monthly rainfall forecasts. *Journal of Hydrology*, 124647. doi:10.1016/j.jhydrol.2020.124647.

[12] Johny, K., Pai, M. L., & Adarsh, S. (2020). Adaptive EEMD-ANN hybrid model for Indian summer monsoon rainfall forecasting. *Theoretical and Applied Climatology*, 141(1-2), 1–17. doi:10.1007/s00704-020-03177-5.

[13] Xiang, Y., Gou, L., He, L., Xia, S., & Wang, W. (2018). A SVR-ANN combined model based on ensemble EMD for rainfall prediction. *Applied Soft Computing*. doi:10.1016/j.asoc.2018.09.018.

[14] Tan, Q.-F., Lei, X.-H., Wang, X., Wang, H., Wen, X., Ji, Y., & Kang, A.-Q. (2018). An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of Hydrology*. doi:10.1016/j.jhydrol.2018.01.015.

[15] Adarsh, S., & Reddy, M. J. (2017). Multiscale characterization and prediction of monsoon rainfall in India using Hilbert–Huang transform and time-dependent intrinsic correlation analysis. *Meteorology and Atmospheric Physics*. doi:10.1007/s00703-017-0545-6.

[16] He, X., Luo, J., Li, P., Zuo, G., & Xie, J. (2020). A Hybrid Model Based on Variational Mode Decomposition and Gradient Boosting Regression Tree for Monthly Runoff Forecasting. *Water Resources Management*. doi:10.1007/s11269-020-02483-x .

[17] Seo, Y., Kim, S., & Singh, V. (2018). Machine Learning Models Coupled with Variational Mode Decomposition: A New Approach for Modeling Daily Rainfall-Runoff. *Atmosphere*, 9(7), 251. doi:10.3390/atmos9070251.

[18] Li, G., Ma, X., & Yang, H. (2018). A Hybrid Model for Monthly Precipitation Time Series Forecasting Based on Variational Mode Decomposition with Extreme Learning Machine. *Information*, 9(7), 177. doi:10.3390/info9070177.