

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXVII CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

USO DE MODELOS DE APRENDIZAJE AUTOMÁTICO PARA LA SIMULACIÓN DE CAUDALES EN EL RÍO CAUTÍN A TRAVÉS DE R

GADIEL SEPÚLVEDA AGUILERA¹
HÉCTOR GARCÉS-FIGUEROA^{1,2,3}
ROCÍO CANO MANZANO¹
MAURICIO ZAMBRANO-BIGIARINI^{4,5,6}

RESUMEN

El actual contexto de cambio climático en Chile ha impulsado la búsqueda de nuevas herramientas que permitan modelar los sistemas hidrológicos. Por ello, en este trabajo, se analiza el desempeño de modelos de aprendizaje automático (ML) como alternativa a modelos hidrológicos (MH) tradicionales en la simulación de caudales diarios en la Cuenca del Río Cautín en Cajón. Se implementaron tres algoritmos de ML: *Random Forest* (RF), *eXtreme Gradient Boosting* (XGBoost) y *Long Short-Term Memory* (LSTM); junto con el MH agregado TUWmodel. Todos los modelos utilizaron forzantes meteorológicas diarias de precipitación, temperatura media del aire y evapotranspiración potencial, provenientes del producto CR2MET-v2.5 para el período 1983-2024. El rendimiento de los modelos fue evaluado mediante las métricas RMSE, KGE' y KGEIf.

Los resultados indican que los modelos ML superaron el desempeño de TUWmodel en el período de prueba (2010-2024), especialmente en la representación del tiempo de ocurrencia de eventos de crecidas y en la dinámica de caudales bajos. Entre los modelos ML, destacó LSTM por su capacidad para capturar dependencias temporales y reproducir la variabilidad estacional del caudal. Además, LSTM obtuvo valores de $KGE' = 0.88$, $KGEIf = 0.86$ y $RMSE = 44.9 \text{ m}^3/\text{s}$. Por su parte, RF y XGBoost demostraron rendimientos satisfactorios en caudales medios, aunque tendieron a sobreestimarlos. En su conjunto, estos resultados demuestran el potencial de los modelos ML para simular caudales diarios, con ventajas frente a enfoques tradicionales como los modelos de precipitación-escorrentía.

¹ Estudiante, Ingeniería Civil, Facultad de Ingeniería y Ciencias, Universidad de La Frontera.

² Asistente de Investigación, Observatorio de Recursos Hídricos de La Araucanía (Kimün-Ko), Universidad de La Frontera.

³ Asistente de Investigación, Centro de Ciencia del Clima y la Resiliencia (CR2), Universidad de Chile.

⁴ Profesor Asociado, Departamento de Obras Civiles, Universidad de La Frontera.

⁵ Director, Observatorio de Recursos Hídricos de La Araucanía (Kimün-Ko), Universidad de La Frontera.

⁶ Investigador Asociado, Centro de Ciencia del Clima y la Resiliencia (CR2), Universidad de Chile.

1. INTRODUCCIÓN

Chile es un país altamente vulnerable ante los efectos del cambio climático, pues cumple con 7 de los 9 criterios de vulnerabilidad definidos por la Convención Marco de las Naciones Unidas sobre el Cambio Climático (CMNUCC) (Ministerio del Medio Ambiente [MMA], 2017). Estos efectos se han manifestado en la intensificación de eventos hidrometeorológicos extremos en las últimas décadas, con efectos económicos y sociales considerables. Por ejemplo, desde 2010, Chile ha experimentado una megasequía en la zona central, y se estima que la frecuencia de este fenómeno aumentará en el futuro cercano (Garreaud et al., 2025); mientras que, durante los años 2023 y 2024, la zona centro-sur del país se ha visto afectada por eventos de inundación, asociados principalmente a ríos atmosféricos (Garreaud, 2024).

Considerando que la crisis climática se traslapa con la crisis hídrica (Dirección General de Aguas [DGA], 2024), es esencial contar con herramientas que permitan modelar los sistemas hidrológicos a nivel de cuenca, en búsqueda de facilitar la toma de decisiones. Para ello, tradicionalmente se han usado modelos hidrológicos de precipitación-escorrentía (MH), que incorporan relaciones físicas explícitas entre las variables meteorológicas, topográficas y de estado con el caudal de la cuenca (Mohammadi et al., 2022). Sin embargo, durante los últimos años, se han propuesto enfoques alternativos, a partir de modelos basados en técnicas de aprendizaje automático o *machine learning* (ML), impulsado por un desarrollo de nuevos algoritmos y un aumento en las fuentes de información disponibles para simular el sistema hidrológico (Y. Hu et al., 2025).

Los modelos basados en ML tienen la ventaja de requerir un menor costo computacional que los MH, y han mostrado ser capaces de capturar relaciones no lineales complejas entre las variables hidrometeorológicas de diversas cuencas y su respectivo caudal de salida (Kratzert et al., 2018). El rendimiento de los modelos ML en la simulación de caudal ha sido respaldada por múltiples estudios en distintas regiones del mundo. Un conjunto de modelos *Random Forest* (RF) mostraron un rendimiento satisfactorio al modelar cuencas en Canadá, con valores de KGE entre 0.62 y 0.99 (Pham et al., 2021). En Suiza, Meyer (2024) puso a prueba seis modelos en nueve cuencas, donde el modelo basado en *eXtreme Gradient Boosting* (XGBoost) obtuvo un KGE medio de entre 0.82 y 0.86 utilizando distintos periodos de entrenamiento, posicionándose dentro de los dos primeros lugares de la comparación. Del mismo modo, se han implementado modelos *Long Short-Term Memory* (LSTM) en China (C. Hu et al., 2018) e Italia (Luppichini et al., 2024), evidenciando el potencial de esta arquitectura tanto de simular eventos extremos como de pronosticar caudales.

Los antecedentes mencionados evidencian el potencial de los modelos basados en ML para la simulación hidrológica, lo que motiva su evaluación en contextos locales. El presente estudio tiene por objetivo analizar el desempeño de modelos de aprendizaje automático como alternativa a modelos hidrológicos tradicionales en la simulación de caudales del Río Cautín en Cajón.

2. METODOLOGÍA

2.1. Zona de estudio

La Cuenca del Río Cautín en Cajón (código BNA 09129002-2), señalada en la Figura 1, abarca principalmente las comunas de Lautaro y Curacautín, que cuentan con una población total de 60 472 habitantes (Instituto Nacional de Estadísticas [INE], 2025), tributando a la cuenca del Río Imperial.

El régimen hidrológico de la cuenca ha sido clasificado como pluvial con leve influencia nival (DGA, 2004). La estación fluviométrica Río Cautín en Cajón se encuentra a una altitud de 134 m s.n.m. (DGA, 2004), mientras que el rango altitudinal de la cuenca se extiende entre los 127 y los 3077 m s.n.m. Según la clasificación climática de Köppen-Geiger (Beck et al., 2023), predomina el clima templado con veranos cálidos y secos (Csb). En los sectores más elevados se presentan condiciones más frías, representadas por climas Dsc (frío con veranos secos y fríos), existiendo también presencia de zonas de tundra (ET).

Cabe mencionar que, entre 2000 y 2024, el Servicio Nacional de Prevención y Respuesta ante Desastres (SENAPRED) ha registrado múltiples emergencias asociadas a crecidas en la cuenca, destacando, en junio de 2018, el corte de la ruta S-31 producto de un desborde del Río Cautín, y, en septiembre de 2023, inundaciones en el sector de Pillanlelbún y el campamento Los Pinos (Padilla Turra, 2024).

2.2. Datos y variables

Para la simulación del caudal de salida en la cuenca (Ver Figura 2, panel 1), se utilizaron entradas hidrometeorológicas con frecuencia temporal diaria entre los años 1983 y 2024: precipitación acumulada diaria P , en mm; temperatura media diaria T , en °C, y evapotranspiración potencial PET, en mm, obtenidos a partir del producto grillado CR2MET-v2.5 (Boisier, 2023). Por otra parte, la variable objetivo fue el caudal medio diario Q en la estación fluviométrica Río Cautín en Cajón, dependiente de la Dirección General de Aguas. Los datos de esta serie se obtuvieron del sitio web de información oficial de la institución (DGA, 2025).

El periodo de estudio se subdividió en tres conjuntos (ver Tabla 1): entrenamiento, validación, y prueba. El periodo de entrenamiento, también llamado periodo de calibración en el caso de los modelos hidrológicos, fue utilizado por todos los modelos. No obstante, el periodo de validación fue de utilidad sólo en el caso de LSTM.

Tabla 1. Fechas y horas de inicio y final, y usos de los conjuntos de datos considerados.

Conjunto	Uso	Modelos	Inicio	Fin
1	Entrenamiento	Todos	01-01-1983	31-12-2003
2	Validación	LSTM	01-01-2004	31-12-2009
3	Prueba	Todos	01-01-2010	31-12-2024

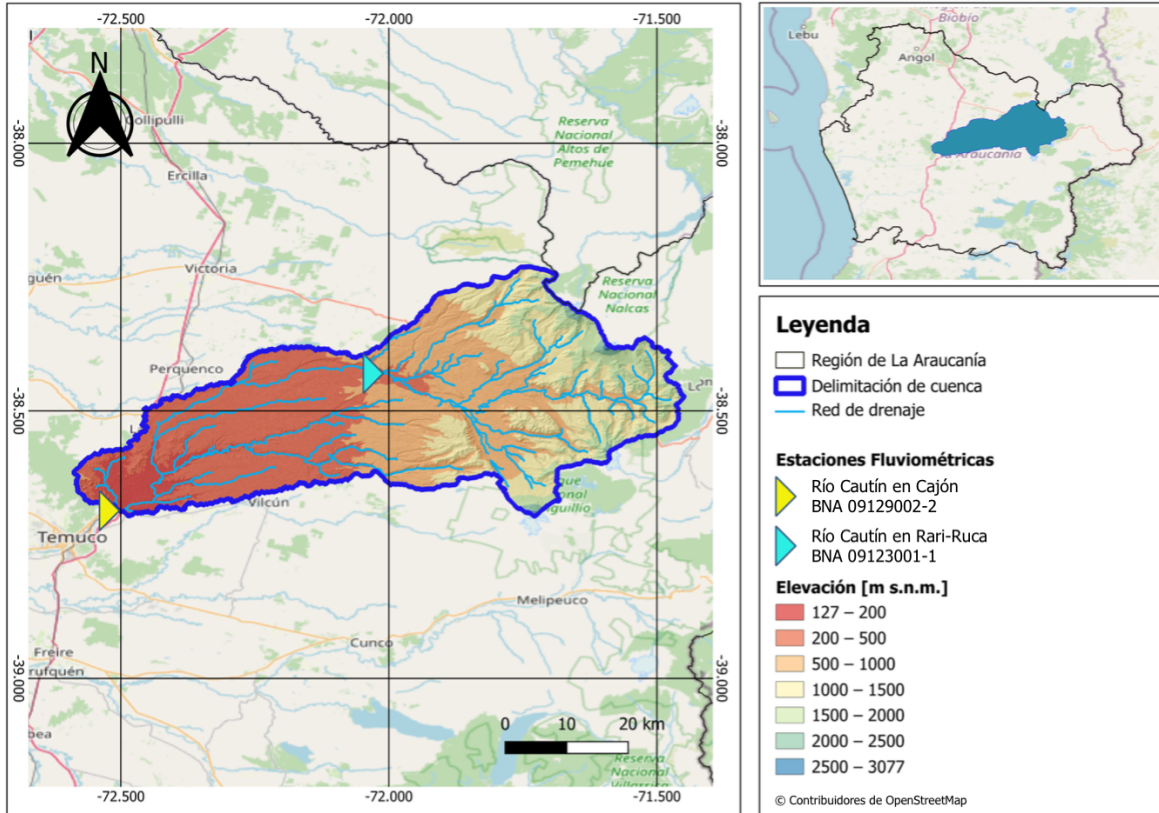


Figura 1. Ubicación espacial de la Cuenca Río Cautín en Cajón y estaciones hidrológicas en la cuenca. La delimitación de la cuenca fue obtenida del conjunto de datos CAMELS-CL (Alvarez-Garretón et al., 2018). Mapa base perteneciente a OpenStreetMap.

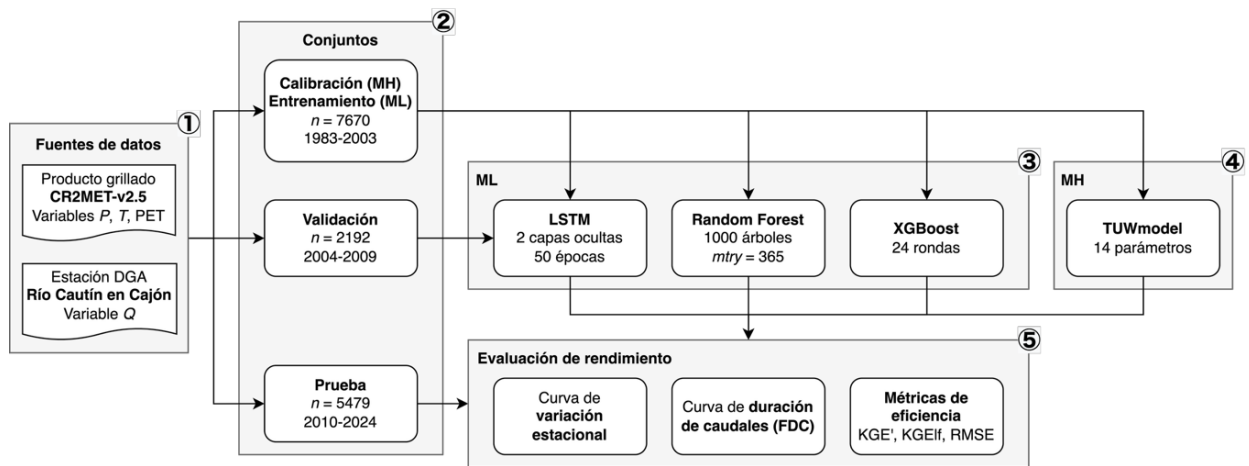


Figura 2. Resumen del proceso implementado. Las etapas se muestran en los respectivos paneles: 1) obtención e importación de datos; 2) partición de conjuntos de entrenamiento, donde n indica el número de observaciones dentro de cada conjunto; 3) entrenamiento de modelos de aprendizaje automático (ML) con los parámetros indicados; 4) calibración de TUWmodel (MH); y 5) evaluación de rendimiento en el conjunto de prueba.

2.3. Modelos utilizados

Se implementaron 4 modelos, de los cuales 3 corresponden a modelos ML basados en técnicas de aprendizaje automático diferentes: XGBoost, Random Forest y LSTM. Además, se utilizó el modelo hidrológico TUWmodel. Detalles sobre la implementación de estos modelos pueden ser revisados en la Figura 2 (panel 3).

Random Forest (RF) es un algoritmo de aprendizaje automático, que, en su versión para regresión, genera múltiples árboles de decisión. Cada uno captura un subconjunto de las variables utilizadas, y produce un valor de salida (Breiman, 2001). El valor simulado por el modelo se obtiene promediando las simulaciones producidas por todos los árboles. Para este modelo, se utilizaron 1000 árboles de decisión y su implementación fue realizada mediante el paquete *randomForest* (Liaw y Wiener, 2024) del ambiente estadístico R, considerando un máximo de 365 variables seleccionadas aleatoriamente en cada partición del árbol.

El método *eXtreme Gradient Boosting* (XGBoost) es un método iterativo de potenciación de gradiente, que consiste en generar una sucesión de árboles de decisión, minimizando una función de costo, que consiste en la suma de una función diferenciable y un término de ajuste (Chen y Guestrin, 2016). El valor simulado se obtiene sumando los valores generados por cada uno de los árboles. Cada nuevo árbol incorpora un valor adicional a partir de las diferencias calculadas con el valor objetivo y el valor simulado por el árbol anterior. Se implementó este modelo a través del paquete *xgboost* (Chen et al., 2025), escogiendo como hiperparámetro 24 rondas de entrenamiento.

Long Short-Term Memory (LSTM) es un tipo de red neuronal recurrente (RNN), que busca corregir el fenómeno de desvanecimiento de gradiente, el cual aparece al entrenar una red a través de retropropagación (Hochreiter y Schmidhuber, 1997). Este algoritmo incorpora información de estado y de memoria que permite capturar dependencias temporales extensas, lo que lo hace particularmente útil en la modelación hidrológica (Kratzert et al., 2018). Esta arquitectura se implementó en R a través de los paquetes *torch* (Falbel et al., 2025) y *luz* (Falbel y Regouby, 2025). El modelo LSTM se construyó considerando dos capas ocultas, donde cada una de ellas posee 16 nodos, y fue entrenado considerando 50 épocas. Además, los datos de los predictores fueron estandarizados en base a la media y desviación estándar del Q en el conjunto de entrenamiento, lo que se revierte en el cómputo de las simulaciones.

Además de los tres modelos de aprendizaje automático, se utilizó TUWmodel (Parajka et al., 2007), un modelo hidrológico conceptual basado en la estructura del modelo HBV (Bergström, 1976), que opera con tres forzantes meteorológicas diarias: precipitación, temperatura media del aire y evapotranspiración potencial. Su estructura comprende tres módulos principales: nieve, humedad del suelo, y escorrentía; y requiere la calibración de 14 parámetros. Los parámetros del modelo se calibraron mediante optimización por enjambre de partículas (PSO; Kennedy y Eberhart, 1995; Zambrano-Bigiarini y Rojas, 2013), considerando como función objetivo la eficiencia de Kling-Gupta modificada (KGE^* ; Kling et al., 2012). La calibración se implementó a través del paquete *hydroPSO* (Zambrano-Bigiarini y Rojas, 2018), considerando los rangos de parámetros propuestos por Viglione y Parajka (2020).

2.4. Simulación de caudales

Con el fin de garantizar una comparación justa, todos los modelos recibieron la misma información para simular cada paso de tiempo en la serie temporal. En cada uno de ellos, el caudal Q_i para un paso i se obtiene en función del valor de cada predictor durante los 365 pasos anteriores (Ec. 1). Esto se puede expresar matemáticamente como:

$$Q_i = f(\mathbf{x}_{i-1}, \dots, \mathbf{x}_{i-365}) \quad (1)$$

donde se definieron los vectores de forzantes $\mathbf{x}_{i-j} = (P_{i-j}, T_{i-j}, PET_{i-j})$, cuyas componentes corresponden al valor de la variable correspondiente en el paso $i - j$, para todo $j = 1, \dots, 365$. Particularmente, en XGBoost y RF, se unieron los 365 vectores de observaciones para conformar un solo vector que recoge la información del periodo completo, puesto que sus arquitecturas no recogen dependencias temporales de forma explícita.

2.5. Métricas de evaluación

Se evaluó el desempeño de las simulaciones de caudal mediante tres métricas: raíz del error cuadrático medio (RMSE; Ec. 2), Eficiencia de Kling-Gupta modificada (KGE'; Ec. 3; Kling et al., 2012), y KGE para caudales bajos (KGEIf; Ec. 4, Garcia et al., 2017). El cálculo de estas métricas se realizó en el entorno estadístico R utilizando el paquete *hydroGOF* (Zambrano-Bigiarini, 2024). Las fórmulas de las métricas se detallan a continuación:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i - O_i)^2} \quad (2)$$

$$\text{KGE}' = 1 - \sqrt{(r - 1)^2 + \left(\frac{\bar{S}}{\bar{O}} - 1\right)^2 + \left(\frac{\text{CV}_s}{\text{CV}_o} - 1\right)^2} \quad (3)$$

$$\text{KGEIf} = \frac{\text{KGE}(\mathbf{S}, \mathbf{O}) + \text{KGE}(\mathbf{S}^{-1}, \mathbf{O}^{-1})}{2} \quad (4)$$

donde \mathbf{S} y \mathbf{O} son las series simulada y observada, \bar{S} y \bar{O} son sus respectivas medias, S_i y O_i son los i -ésimos caudales simulados y observados, \mathbf{S}^{-1} y \mathbf{O}^{-1} son las series de los recíprocos de los caudales simulados y observados respectivamente, N es el número de observaciones, CV_s y CV_o corresponden a los coeficientes de variación de las series simulada y observada respectivamente, definidos como la desviación estándar dividida por la media; mientras que r representa el coeficiente de correlación de Pearson (Ec. 5) entre ambas series, calculado como:

$$r = \frac{\sum_{i=1}^N (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \cdot \sum_{i=1}^N (S_i - \bar{S})^2}} \quad (5)$$

3. RESULTADOS

3.1. Rendimiento general

La Tabla 2 resume el rendimiento obtenido durante los periodos de entrenamiento (1983-2003) y de prueba (2010-2024) por cada uno de los modelos en términos de KGE', KGEIf, y RMSE para la cuenca del Río Cautín en Cajón. Durante el período de entrenamiento, el modelo con mejor desempeño en términos de KGE' es XGBoost, seguido por TUWmodel, RF y LSTM. Sin embargo, las diferencias en el comportamiento de los modelos frente a las distintas métricas durante el período de entrenamiento impiden identificar uno con desempeño consistentemente superior.

Tabla 2. Métricas de eficiencia en los conjuntos de entrenamiento/calibración (CC) y prueba (CT).

Modelo	KGE'		KGEIf		RMSE [m ³ /s]	
	CC	CT	CC	CT	CC	CT
Random Forest	0.89	0.72	0.87	0.73	25.15	48.68
XGBoost	0.97	0.82	0.91	0.69	17.53	49.31
LSTM	0.83	0.88	0.83	0.86	51.97	44.86
TUWmodel	0.91	0.83	0.34	0.41	1.85	50.01

Por otra parte, en el conjunto de prueba, LSTM obtiene el mejor rendimiento en todas las métricas, siendo especialmente relevante mencionar que incrementó su rendimiento en el periodo de prueba, a diferencia del resto de modelos, exceptuando el aumento en KGEIf de TUWmodel. Las simulaciones de caudal obtenidas a partir de cada uno de los modelos pueden ser revisadas en la Figura 3, donde es posible evidenciar que RF sobreestima los caudales bajos, mientras que TUWmodel reproduce inadecuadamente la dinámica de las curvas de recesión.

Evaluando la curva de variación estacional (CVE) simulada en el período de prueba (ver Figura 4, panel a), es posible notar que XGBoost y RF tienden a sobreestimar los caudales medios mensuales observados, y muestran un adelanto de dos meses en la ocurrencia de los valores promedio más altos de caudal en la cuenca. Por otro lado, LSTM y TUWmodel presentan una forma que se asemeja a la CVE observada en los meses de invierno y primavera. Sin embargo, TUWmodel tiende a subestimar los caudales medios de febrero y marzo debido a su reproducción deficiente de los caudales bajos, mientras que LSTM subestima los meses de noviembre a enero.

De forma complementaria, al analizar la curva de duración de caudales (FDC; ver Figura 4, panel b), se aprecia que los modelos presentan una forma similar a la FDC observada para probabilidades de excedencia inferiores a 20%, destacando el desempeño de XGBoost. En el tramo comprendido entre probabilidades de excedencia del 20 al 70%, el modelo LSTM exhibe un comportamiento atípico, posiblemente asociado a la subestimación de caudales que se evidencia en la CVE estacional durante noviembre a enero; mientras que, los modelos TUWmodel, XGBoost y RF tienden a sobrestimar la FDC observada en aquel rango. Para el tramo de caudales bajos (i.e., probabilidades de excedencia superiores a 70%), tanto el modelo TUWmodel como XGBoost presentan subestimaciones, alcanzando caudales inferiores a los observados.

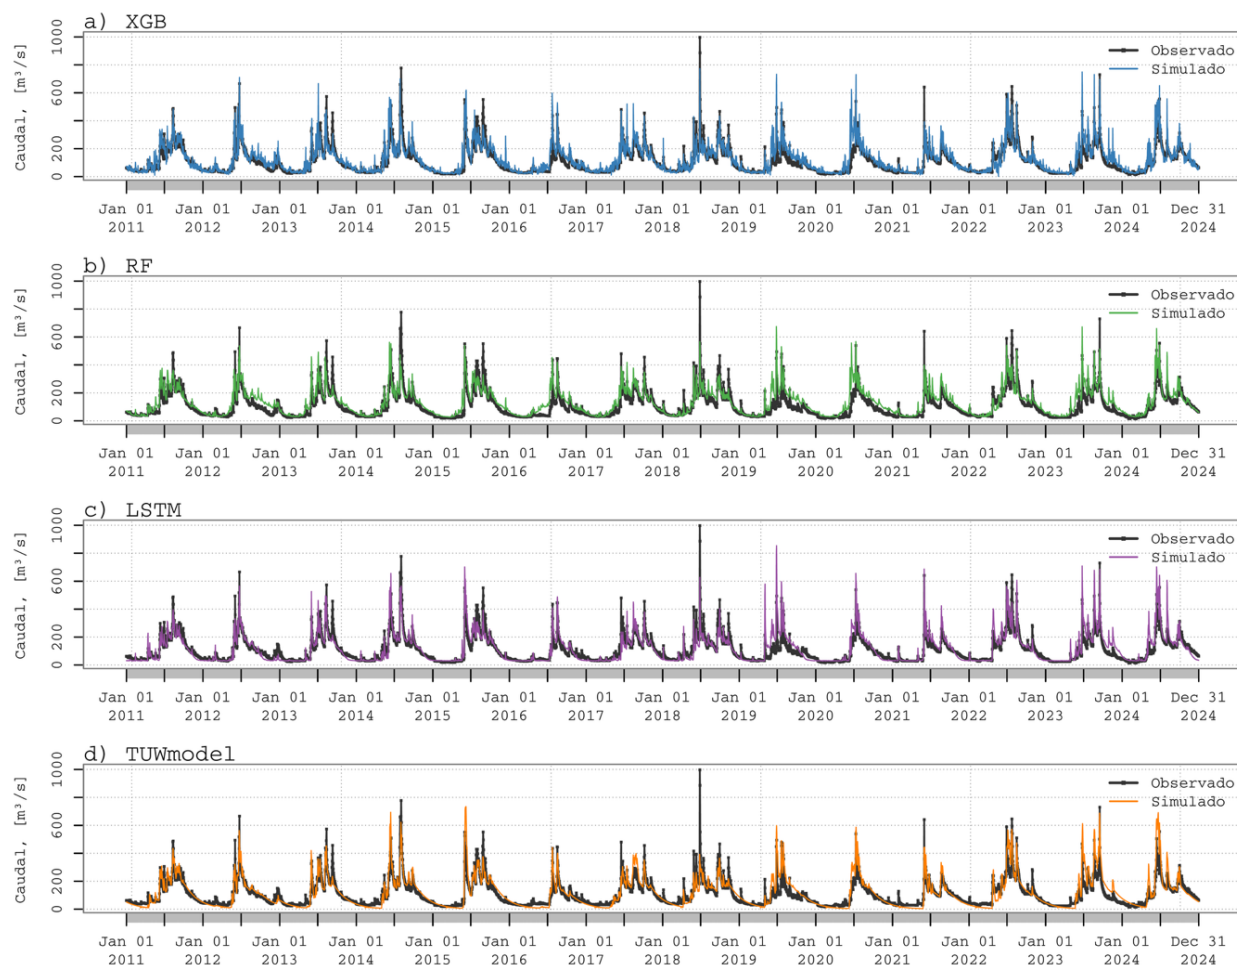


Figura 3. Comparación de Q observado con Q simulado por cada modelo en el conjunto de prueba. De arriba abajo: a) XGBoost, b) Random Forest, c) LSTM, y d) TUWmodel.

3.2. Crecidas de invierno de 2023

Para evaluar con mayor detalle el desempeño de los modelos durante el período de prueba, en la Figura 5, se presentan las simulaciones de caudales correspondientes al intervalo comprendido entre junio y septiembre de 2023. Los valores de KGE' obtenidos fueron 0.73 para el modelo LSTM, 0.63 para XGBoost, y 0.53 tanto para RF como para TUWmodel.

El modelo LSTM logra reproducir adecuadamente la forma general del hidrograma, aunque tiende a sobreestimar los caudales observados. En contraste, RF muestra una buena correspondencia con la magnitud de gran parte de las observaciones, mas no consigue representar adecuadamente el caudal de septiembre de 2023 que causó inundaciones en la zona de estudio. A pesar de presentar el segundo valor de KGE' más alto, XGBoost presenta un comportamiento errático en la simulación de caudales, debido a aumentos y disminuciones abruptas en los valores de caudal, lo cual afecta principalmente a la reproducción de la curva de recesión.




Figura 4. Gráfica de resumen de desempeño de modelos ML y TUWmodel contra serie observada en el conjunto de prueba: a) curva de variación estacional (CVE), con frecuencia mensual; y b) curva de duración de caudales (FDC).




Figura 5. Comparación de Q observado con Q simulado por cada modelo en el intervalo comprendido entre junio y septiembre de 2023. De arriba abajo: a) XGBoost, b) Random Forest, c) LSTM, y d) TUWmodel.

Por su parte, TUWmodel presenta limitaciones evidentes en la reproducción de los eventos de crecida. En particular, se evidencia un retraso de dos días en la simulación de un evento alto durante junio de 2023; mientras que, para el evento observado en septiembre de 2023, se evidencia un adelanto de un día. Resulta relevante mencionar que todos los modelos ML aciertan en el tiempo de ocurrencia de los eventos altos, lo cual podría ser de especial utilidad para una potencial implementación de un sistema de pronóstico de crecidas.

Para facilitar la visualización de los resultados obtenidos durante el periodo de prueba, se encuentra disponible la aplicación web "mlflow", en la URL <https://gsepulveda.shinyapps.io/mlflow>.

4. CONCLUSIONES

En este trabajo, se implementaron tres modelos basados en diferentes algoritmos de ML (i.e., RF, XGBoost y LSTM), además del MH TUWmodel, con el fin de simular caudales diarios en la cuenca del Río Cautín en Cajón. Los resultados muestran que los modelos ML alcanzan un desempeño comparable e incluso superior al de TUWmodel en términos de las métricas KGE_f y RMSE, destacando por su mejor representación de la dinámica de caudales bajos y del tiempo de ocurrencia de las crecidas.

Más específicamente, durante el periodo de prueba (2010-2024), el modelo LSTM obtuvo los mejores valores de eficiencia (i.e., KGE' = 0.88, KGE_f = 0.86 y RMSE = 44.9 m³/s), mostrando su capacidad para capturar dependencias temporales complejas y reproducir la variabilidad estacional del caudal. No obstante, presentó un comportamiento atípico en la forma de la FDC en caudales medios, exhibiendo una subestimación de los valores observados. Los modelos XGBoost y RF mostraron un rendimiento satisfactorio en la simulación de caudales medios, aunque con una tendencia a la sobreestimación, como se evidencia en la CVE. En contraste, el MH TUWmodel, a pesar de presentar un comportamiento estable en el rango medio de caudales, presentó dificultades en la reproducción de valores tanto altos como bajos. En particular, para eventos de caudales altos (Figura 5), presentó desfases temporales con respecto a los eventos observados.

Estos resultados confirman la aplicabilidad de modelos basados en ML en la simulación de caudales diarios, destacando el desempeño del modelo LSTM. Se debe considerar, sin embargo, que siguen existiendo aspectos a evaluar que van más allá del alcance de este estudio, como la cuantificación de la incertidumbre en los valores simulados; y, como comentan Kratzert et al. (2024), que los modelos de ML como LSTM suelen presentar un mejor rendimiento al entrenarse sobre múltiples cuencas, en lugar de una, como se hizo en este trabajo. De este modo, la incorporación de modelos ML representa un enfoque complementario a la modelación hidrológica tradicional, con la capacidad de mejorar la simulación de caudales, y cuya utilidad se potencia considerando un criterio adecuado en su entrenamiento y aplicación.

AGRADECIMIENTOS

Los autores de este trabajo agradecen el financiamiento otorgado por los proyectos PCI CONICYT Chile – NSFC China NSFC190018 (*“Management of global change impacts on hydrological extremes by coupling remote sensing data and an interdisciplinary modelling approach”*) y Fondecyt Regular 1212071 (*“The catchment’s memory: understanding how hydrological extremes are modulated by antecedent soil moisture conditions in a warmer climate”*).

REFERENCIAS

- Alvarez-Garreton, C., Mendoza, P. A., Boisier, J. P., Addor, N., Galleguillos, M., Zambrano-Bigiarini, M., Lara, A., Puelma, C., Cortes, G., Garreaud, R., McPhee, J., & Ayala, A. (2018). The CAMELS-CL dataset [Dataset]. En *Supplement to: Alvarez-Garreton, C et al. (2018): The CAMELS-CL dataset: Catchment attributes and meteorology for large sample studies—Chile dataset. Hydrology and Earth System Sciences, 22(11), 5817-5846*, <https://doi.org/10.5194/hess-22-5817-2018>. PANGAEA. <https://doi.org/10.1594/PANGAEA.894885>
- Beck, H. E., McVicar, T. R., Vergopolan, N., Berg, A., Lutsko, N. J., Dufour, A., Zeng, Z., Jiang, X., van Dijk, A. I. J. M., & Miralles, D. G. (2023). High-resolution (1 km) Köppen-Geiger maps for 1901–2099 based on constrained CMIP6 projections. *Scientific Data, 10(1)*, 724. <https://doi.org/10.1038/s41597-023-02549-6>
- Bergström, S. (1976). *Development and application of a conceptual runoff model for Scandinavian catchments*. <https://urn.kb.se/resolve?urn=urn:nbn:se:smhi:diva-5738>
- Boisier, J. P. (2023). *CR2MET: A high-resolution precipitation and temperature dataset for the period 1960-2021 in continental Chile*. [Dataset]. Zenodo. <https://doi.org/10.5281/zenodo.7529682>
- Breiman, L. (2001). Random Forests. *Machine Learning, 45(1)*, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chen, T., & Guestrin, C. (2016). *XGBoost: A Scalable Tree Boosting System*. 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., Zhou, T., Li, M., Xie, J., Lin, M., Geng, Y., Li, Y., & Yuan, J. (2025). *xgboost: Extreme Gradient Boosting (Versión 1.7.11.1)* [R]. <https://cran.r-project.org/web/packages/xgboost/index.html>
- Dirección General de Aguas [DGA]. (2004). *Diagnóstico y clasificación de los cursos y cuerpos de agua según objetivos de calidad: Cuenca del Río Imperial*.
- Dirección General de Aguas [DGA]. (2024). *Caracterización del sector, vulnerabilidad y evaluación de efectos adversos del cambio climático y riesgos* (Plan de Adaptación al Cambio Climático: Recursos Hídricos). Dirección General de Aguas. <https://cambioclimatico.mop.gob.cl/archivos/sites/2/2024/07/Caracterizacion-del-sector-vulnerabilidad-y-evaluacion-de-efectos-adversos-del-cambio-climatico-y-riesgos-mayo-2024.pdf>
- Dirección General de Aguas [DGA]. (2025). *Información Oficial Hidrometeorológica y de Calidad de Aguas en Línea*. <https://snia.mop.gob.cl/BNAConsultas/reportes>
- Falbel, D., Luraschi, J., Selivanov, D., Damiani, A., Regouby, C., Joachimiak, K., Badr, H. S., Fischer, S., & Pichler, M. (2025). *torch: Tensors and Neural Networks with “GPU” Acceleration (Versión 0.16.0)* [Software]. <https://cran.r-project.org/web/packages/torch/index.html>
- Falbel, D., & Regouby, C. (2025). *luz: Higher Level “API” for “torch” (Versión 0.5.0)* [Software]. <https://cran.r-project.org/web/packages/luz/index.html>
- García, F., Folton, N., & Oudin, L. (2017). Which objective function to calibrate rainfall–runoff models for low-flow index simulations? *Hydrological Sciences Journal, 62(7)*, 1149–1166. <https://doi.org/10.1080/02626667.2017.1308511>
- Garreaud, R. (2024, 6 de agosto). *Análisis CR2 | Junio versus junio*. Departamento de Geofísica, Universidad de Chile. <http://www.dgf.uchile.cl/noticias/219071/analisis-cr2--junio-versus-junio>
- Garreaud, R., Boisier, J. P., Álvarez-Garreton, C., Christie, D., Carrasco-Escaff, T., Vergara, I., Chávez, R. O., Aldunce, P., Camus, P., Suazo-Álvarez, M., Masiokas, M., Castro, G., Muñoz, A., Zambrano-Bigiarini, M., Fuster, R., & Godoy, L. (2025). Hyperdroughts in central Chile: Drivers, Impacts and Projections. *EGU Sphere, 1–31*. <https://doi.org/10.5194/egusphere-2025-517>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation, 9(8)*, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hu, C., Wu, Q., Li, H., Jian, S., Li, N., & Lou, Z. (2018). Deep Learning with a Long Short-Term Memory Networks Approach for Rainfall-Runoff Simulation. *Water, 10(11)*, 1543. <https://doi.org/10.3390/w10111543>

Hu, Y., Li, H., Zhang, C., Shen, D., Xu, B., Chen, M., Chu, W., & Li, R. (2025). Exploring Diverse Modeling Schemes for Runoff Prediction: An Application to 544 Basins in China. *EGUsphere*, 1–51. <https://doi.org/10.5194/egusphere-2025-1161>

Instituto Nacional de Estadísticas [INE]. (2025). *Censo 2024—Resultados Nacionales* [Dataset]. <https://censo2024.ine.gob.cl/resultados/>

Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, 1942–1948 vol.4. <https://doi.org/10.1109/ICNN.1995.488968>

Kling, H., Fuchs, M., & Paulin, M. (2012). Runoff conditions in the upper Danube basin under an ensemble of climate change scenarios. *Journal of Hydrology*, 424–425, 264–277. <https://doi.org/10.1016/j.jhydrol.2012.01.011>

Kratzert, F., Gauch, M., Klotz, D., & Nearing, G. (2024). HESS Opinions: Never train a Long Short-Term Memory (LSTM) network on a single basin. *Hydrology and Earth System Sciences*, 28(17), 4187–4201. <https://doi.org/10.5194/hess-28-4187-2024>

Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks. *Hydrology and Earth System Sciences*, 22(11), 6005–6022. <https://doi.org/10.5194/hess-22-6005-2018>

Liaw, A., & Wiener, M. W. (2024). *randomForest: Breiman and Cutlers Random Forests for Classification and Regression* (Versión 4.7-1.2) [R]. <https://cran.r-project.org/web/packages/randomForest/index.html>

Luppichini, M., Vailati, G., Fontana, L., & Bini, M. (2024). Machine learning models for river flow forecasting in small catchments. *Scientific Reports*, 14(1), 26740. <https://doi.org/10.1038/s41598-024-78012-2>

Meyer, B. (2024). *Performance of Different Machine Learning Algorithms in Rainfall Runoff Modelling Compared to the Conceptual Model PREVAH in Selected Swiss Catchments* [Master thesis]. University of Bern.

Ministerio del Medio Ambiente [MMA]. (2017). *Plan de Acción Nacional de Cambio Climático: 2017-2022*. <https://bibliotecadigital.ciren.cl/handle/20.500.13082/26856>

Mohammadi, B., Safari, M. J. S., & Vazifehkhah, S. (2022). IHACRES, GR4J and MISD-based multi conceptual-machine learning approach for rainfall-runoff modeling. *Scientific Reports*, 12(1), 12096. <https://doi.org/10.1038/s41598-022-16215-1>

Padilla Turra, D. I. (2024). *Registros institucionales y análisis de desborde de río y riesgos por inundación durante el siglo XXI en la ribera del río Cautín, Región de La Araucanía* [Master thesis, Universidad de Oviedo]. <https://digibuo.uniovi.es/dspace/handle/10651/75655>

Parajka, J., Merz, R., & Blöschl, G. (2007). Uncertainty and multiple objective calibration in regional water balance modelling: Case study in 320 Austrian catchments. *Hydrological Processes*, 21(4), 435–446. <https://doi.org/10.1002/hyp.6253>

Pham, L. T., Luo, L., & Finley, A. (2021). Evaluation of random forests for short-term daily streamflow forecasting in rainfall- and snowmelt-driven watersheds. *Hydrology and Earth System Sciences*, 25(6), 2997–3015. <https://doi.org/10.5194/hess-25-2997-2021>

Viglione, A., & Parajka, J. (2020). *TUWmodel: Lumped/Semi-Distributed Hydrological Model for Education Purposes* (Versión 1.1-1) [Software]. <https://cran.r-project.org/web/packages/TUWmodel/index.html>

Zambrano-Bigiarini, M. (2024). *hydroGOF: Goodness-of-Fit Functions for Comparison of Simulated and Observed Hydrological Time Series* (Versión 0.6-0.1) [Software]. <https://cran.r-project.org/web/packages/hydroGOF/index.html>

Zambrano-Bigiarini, M., & Rojas, R. (2013). A model-independent Particle Swarm Optimisation software for model calibration. *Environmental Modelling & Software*, 43, 5–25. <https://doi.org/10.1016/j.envsoft.2013.01.004>

Zambrano-Bigiarini, M., & Rojas, R. (2018). *hydroPSO: Particle Swarm Optimisation, with Focus on Environmental Models* (Versión 0.4.0) [R]. <https://github.com/hzambran/hydroPSO>