

**SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA**  
**XXVII CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA**

**EVALUACIÓN DE LA RESPUESTA DEL CAUDAL MÁXIMO DIARIO MEDIANTE  
REDES LONG SHORT TERM MEMORY**

**LUIS ROJAS FREDES.<sup>1</sup>**  
**LUIS DE LA FUENTE C..<sup>2</sup>**  
**LINA CASTRO.<sup>3</sup>**

**RESUMEN**

La interpretación de caudales extremos constituye un desafío clave para la gestión hídrica y la planificación de infraestructura en Chile, donde la alta variabilidad climática, los fuertes gradientes altitudinales y la escasa densidad de observaciones dificultan la aplicación de modelos físico-conceptuales tradicionales. Estos modelos, aunque basados en principios hidrológicos explícitos, dependen de calibraciones locales y pierden robustez ante condiciones no observadas o bajo escenarios de cambio climático. En este estudio se implementó un modelo Long Short-Term Memory (LSTM) regionalizado, entrenado con trece cuencas representativas de distintos regímenes hidroclimáticos, alcanzando una mediana de Kling–Gupta Efficiency (KGE) de 0,64 en validación y 0,56 en prueba. Posteriormente se aplicaron perturbaciones controladas en precipitación, temperatura y cobertura forestal para analizar la sensibilidad del modelo y vincular sus respuestas con procesos hidrológicos reconocibles.

Los resultados muestran que el LSTM reproduce relaciones coherentes y permite abrir parcialmente la “caja negra” del aprendizaje profundo, aportando una herramienta útil para identificar cuencas vulnerables y orientar la planificación hídrica frente a la creciente variabilidad climática.

---

<sup>1</sup> Estudiante, Ingeniería Civil, Universidad Federico Santa María - email: luis.rojasfr@sansano.usm.cl

<sup>2</sup> Profesor Guía, Departamento de Obras Civiles, Universidad de Concepción - email: ladela Fuente@utep.edu

<sup>3</sup> Profesora Co-guía, Departamento de Obras Civiles, Universidad Federico Santa María - email: Lina.Castro@usm.cl

## 1. INTRODUCCIÓN

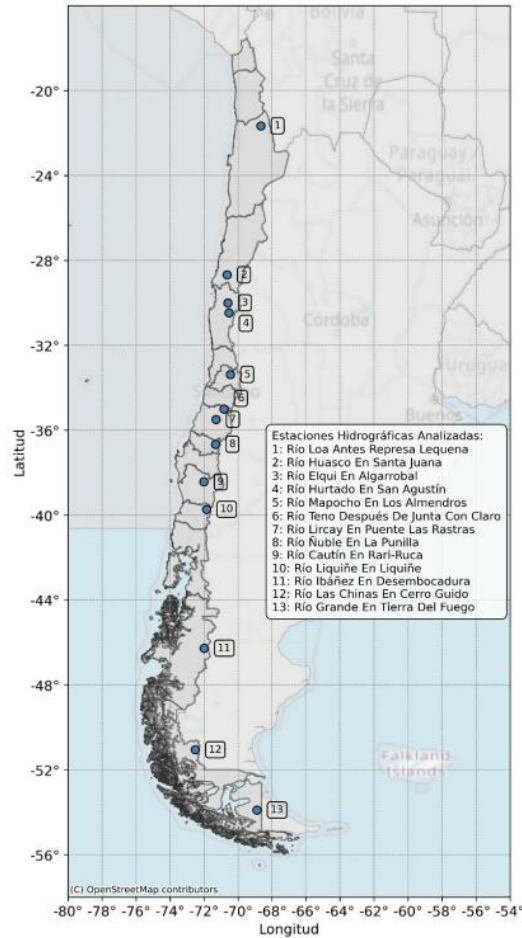
La ocurrencia de caudales extremos constituye uno de los principales desafíos para la gestión hídrica, el diseño de infraestructura y la reducción del riesgo en Chile. Comprender los factores que los originan resulta clave para anticipar crecidas y reducir sus impactos. Sin embargo, la modelación hidrológica enfrenta serias limitaciones por la escasa densidad de observaciones, especialmente en zonas altoandinas donde se generan los principales aportes hídricos del país (Álvarez-Garreton et al., 2018; MOP, 2020). En este contexto, los modelos físico-conceptuales tradicionales, como HBV o GR4J, pierden capacidad de extrapolación frente a condiciones no observadas, mostrando sensibilidad estructural y dependencia de calibraciones locales (Vicuña et al., 2011; Nauditt et al., 2017; Parra et al., 2019).

Las redes Long Short-Term Memory (LSTM) han surgido como una alternativa complementaria que permite representar dinámicas hidrológicas complejas sin parametrizaciones explícitas (Kratzert et al., 2018; Anderson & Radić, 2022). No obstante, su carácter de “caja negra” limita su uso interpretativo. Para enfrentar este problema, el presente estudio aplica un análisis de sensibilidad perturbacional como herramienta para abrir parcialmente la caja negra, identificando cómo las variables hidrometeorológicas y de cobertura forestal influyen en los caudales máximos diarios. Más que evaluar precisión, el objetivo es vincular las respuestas del modelo con procesos hidrológicos reconocibles, generando evidencia útil para comprender las causas de las crecidas y orientar la planificación hídrica frente a la creciente variabilidad climática.

## 2. METODOLOGÍA

### 2.1. Área de estudio

El estudio se aplicó en trece cuencas chilenas distribuidas a lo largo del país, seleccionadas para representar un amplio rango de condiciones hidroclimáticas y morfológicas (Figura 1). Estas incluyen cuencas áridas en el norte, mediterráneas en la zona central y pluvio-nivales en el sur, lo que permite evaluar el desempeño del modelo LSTM bajo distintos regímenes hidrológicos. La diversidad de estas cuencas dotó de robustez al entrenamiento del modelo, ya que estuvo expuesto a escenarios hidroclimáticos muy contrastantes, entregando en el periodo de prueba simulaciones coherentes frente a variaciones en precipitación, temperatura y cobertura forestal. La selección se basó en cuatro criterios principales: (1) alta disponibilidad de datos ( $\geq 80$  % de registros diarios completos); (2) representatividad climática nacional; (3) baja intervención antrópica, determinada a partir del índice de regulación de CAMELS-CL (Álvarez-Garretón et al., 2018) y la ausencia de embalses o grandes obras de control aguas arriba; y (4) uso de fuentes de datos oficiales.



**Figura 1.** Ubicación de las estaciones hidrométricas seleccionadas

## 2.2 Base de datos, variables seleccionadas y división temporal de datos (“splitting”)

La información proviene de CAMELS-CL (Álvarez-Garretón et al., 2018) y de los registros de caudales de la DGA, base de datos que integra atributos de cuencas y meteorología ampliamente utilizada en estudios hidrológicos en Chile (De la Fuente, 2021). Se seleccionaron variables dinámicas (precipitación y temperatura) y estáticas (pendiente, cobertura forestal, aridez, estacionalidad y frecuencia de eventos extremos) por su relevancia en la generación de escorrentía (Addor et al., 2018; Martel et al., 2024). Las variables estáticas se trataron como representativas del comportamiento promedio de cada cuenca, sin considerar su variación interanual. En cuanto a la división temporal de los datos, se utilizaron 19 años de registros: 13 para entrenamiento, 3 para validación y 3 para prueba, siguiendo estudios previos (Kratzert et al., 2018; Martel et al., 2024). El entrenamiento ajustó los pesos, la validación definió los hiperparámetros y la prueba evaluó la capacidad de generalización del modelo.

## 2.4 Estructura del modelo LSTM

El modelo utilizado corresponde a una red Long Short-Term Memory (LSTM) propuesta por Hochreiter y Schmidhuber (1997), diseñada para superar el problema del desvanecimiento del gradiente en redes neuronales recurrentes. Este tipo de red incorpora un estado de celda o memoria

que permite retener información relevante durante periodos prolongados, lo que resulta esencial en la representación de series temporales como el caudal máximo diario. La LSTM regula el flujo de información mediante tres compuertas: la de entrada, que controla qué datos nuevos se incorporan; la de olvido, que decide qué información almacenada se descarta; y la de salida, que determina cuánta información de la memoria se utiliza en cada instante. Estas compuertas operan de forma coordinada para equilibrar el aprendizaje de patrones de corto y mediano plazo (Kratzert et al., 2018).

Es importante distinguir la memoria hidrológica de la cuenca, asociada a la persistencia de procesos físicos a largo plazo (p. ej., almacenamiento subterráneo o nieve), de la memoria efectiva del modelo, que corresponde al horizonte temporal de información que la LSTM utiliza para mejorar sus predicciones. En este estudio, dicha longitud de entrada (sequence length) se definió en 365 días mediante búsqueda de hiperparámetros. Este valor, equivalente a un año hidrológico, permite representar influencias climáticas recientes y estacionales, sin pretender capturar la persistencia de tipo Hurst–Kolmogorov que se manifiesta en escalas mucho mayores (Kratzert et al., 2018).

## 2.5 Análisis de sensibilidad

El análisis de sensibilidad (AS) permite interpretar cómo el modelo responde a cambios en sus variables de entrada, siendo una herramienta clave para abrir la “caja negra” de los modelos LSTM. En este estudio se aplicó una versión extendida del método One-at-a-Time (OAT) (Gupta y Razavi, 2017), que combina perturbaciones individuales y binarias. Se aplicaron perturbaciones controladas a precipitación ( $\pm 5\%$ ,  $\pm 10\%$ ,  $\pm 20\%$ ), temperatura ( $\pm 1\text{ }^\circ\text{C}$ ,  $\pm 2\text{ }^\circ\text{C}$ ,  $\pm 4\text{ }^\circ\text{C}$ ) y cobertura forestal ( $\pm 5\%$ ), además de combinaciones binarias entre dos variables. Estos rangos se definieron a partir de proyecciones de cambio climático para Chile, que anticipan reducciones o aumentos de hasta  $\pm 20\%$  en precipitación y variaciones térmicas de hasta  $\pm 4\text{ }^\circ\text{C}$  hacia finales de siglo (Dirección Meteorológica de Chile, 2024), así como de estudios hidrológicos previos en zonas de montaña (Patterson et al., 2022). Las combinaciones incluyeron precipitación–temperatura, con escenarios de aumentos y disminuciones simultáneas (+/+ , -/-) y en direcciones opuestas (+/- , -/+), y precipitación–cobertura forestal, con escenarios sincronizados (+/+ y -/-) y opuestos (+/- y -/+). Este diseño permite capturar tanto sensibilidades locales como efectos sinérgicos o compensatorios, como el ascenso de la isoterma  $0\text{ }^\circ\text{C}$  que convierte nieve en lluvia durante eventos cálidos o el rol de la vegetación en la amortiguación de caudales extremos.

La respuesta del modelo se evaluó mediante la elasticidad hidrológica, calculada como el cambio relativo en el caudal máximo diario ante cambios relativos o absolutos en las variables de entrada:

$$\varepsilon = \frac{\Delta Q/Q}{\Delta X/X} \quad (1)$$

donde  $Q$  es el caudal máximo y  $X$  la variable perturbada. Valores  $|\varepsilon| > 1$  indican respuestas amplificadas y  $|\varepsilon| < 1$  respuestas amortiguadas.

Para garantizar consistencia entre cuencas y perturbaciones, los resultados se reportaron usando la mediana (Q2) y el rango intercuartílico (Q1–Q3) como estadísticas de resumen. Este enfoque permite comparar el comportamiento típico del modelo sin que los valores extremos distorsionen el análisis y evaluar la dispersión de las respuestas sin asumir simetría o normalidad.

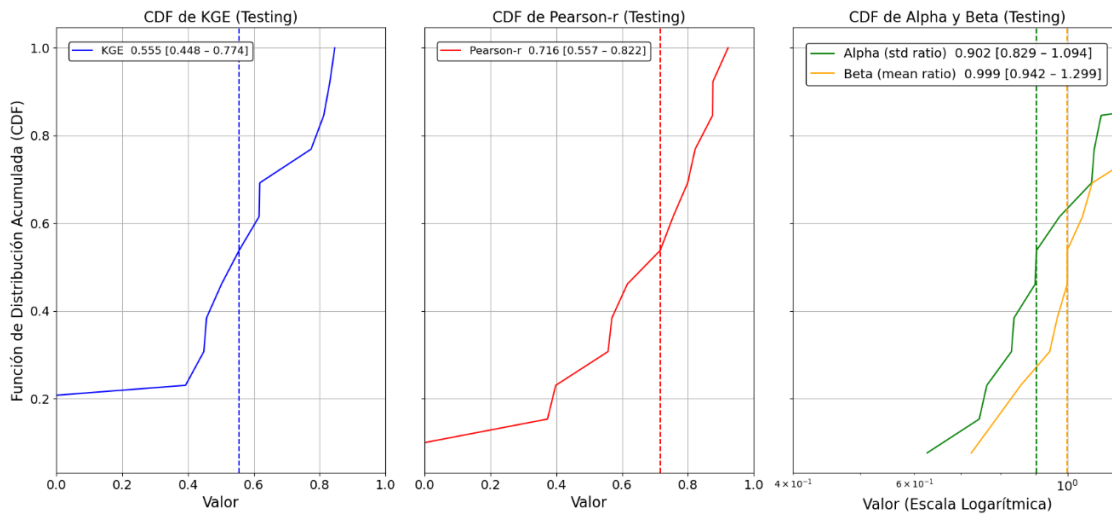
Las cuencas consideradas en el AS cumplieron dos criterios: (1)  $KGE \geq 0,6$  en la validación y (2) al menos ocho eventos extremos con periodo de retorno de 10 años (Frame et al., 2022; Addor et al., 2018). Este diseño balancea realismo físico, interpretabilidad y viabilidad computacional.

### 3. Resultados y Discusión

#### 3.1. Desempeño general del modelo LSTM

##### 3.1.1 Evaluación cuantitativa general

La Figura 2 muestra las funciones de distribución acumulada (CDF) de las métricas utilizadas para evaluar el desempeño del modelo LSTM durante el periodo de prueba: el índice Kling–Gupta Efficiency (KGE) y sus componentes —la correlación de Pearson ( $r$ ), la variabilidad ( $\alpha$ ) y el sesgo ( $\beta$ )—. Estas curvas resumen el comportamiento global del modelo en las 13 cuencas analizadas.



**Figura 2.** CDF de las métricas de desempeño del modelo LSTM durante el período de testeo (testing). Izquierda: KGE (ajuste global). Centro: correlación de Pearson  $r$  (sincronía temporal). Derecha:  $\alpha$  y  $\beta$  en escala logarítmica (variabilidad y volumen de escorrentía).

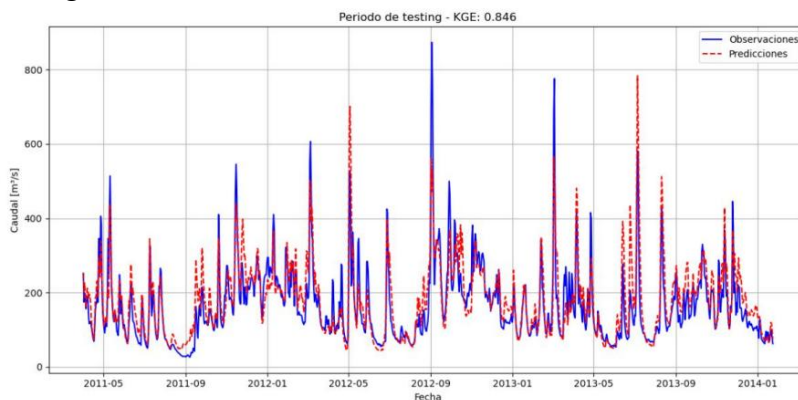
En el panel izquierdo se observa una mediana de  $KGE = 0.56$  [0.45–0.77], reflejando un ajuste moderado pero consistente entre cuencas, dentro de lo esperado para caudales máximos diarios en contextos complejos (Frame et al., 2022; Nauditt et al., 2017; Parra et al., 2019). El coeficiente de Pearson ( $r = 0.72$  [0.56–0.82]) indica una buena sincronía temporal, mientras que los componentes  $\alpha$  (0.90 [0.83–1.09]) y  $\beta$  (0.99 [0.94–1.30]) muestran que el modelo reproduce de forma razonable la variabilidad y el volumen total, con algunos casos de sobreestimación ( $\beta > 1.5$ ) vinculados a periodos de entrenamiento más húmedos.

Este desempeño debe leerse considerando que todas las variables de entrada se trabajaron a resolución diaria, mientras que la salida corresponde al caudal máximo diario. Esta diferencia atenúa los picos de crecida y limita la captura precisa de eventos extremos (Frame et al., 2022; Baste et al., 2025). Aun así, el modelo representa de manera estable los patrones generales del régimen de caudal y su variabilidad interanual entre cuencas

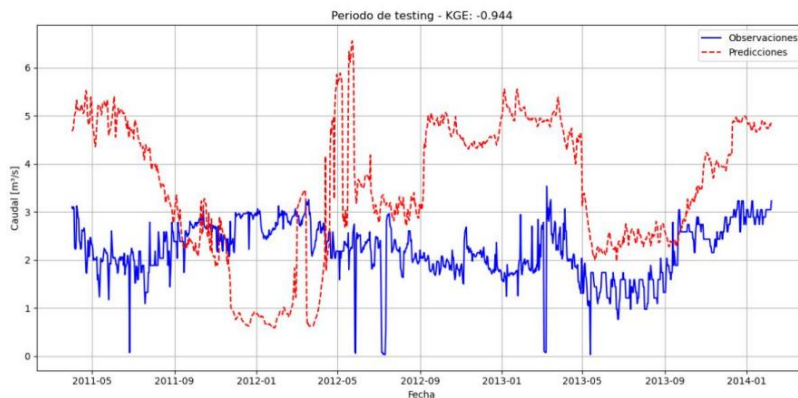
### 3.1.2 Desempeño en contextos hidroclimáticos contrastantes

La Figura 3 muestra el ajuste entre caudales observados y simulados en la cuenca del río Ibañez, representativa de una zona húmeda nivo-pluvial. El modelo alcanzó un  $KGE = 0.85$ , reproduciendo con precisión la forma y magnitud de los eventos, incluso durante crecidas.

En contraste, la Figura 4 presenta el río Huasco, ubicado en una región árida del norte, donde el modelo mostró mayores discrepancias y un  $KGE = -0.94$ . Estas diferencias reflejan la dificultad de representar procesos en zonas con baja disponibilidad hídrica y alta variabilidad interanual, patrón coherente con lo reportado por De la Fuente et al. (2023), quienes observaron un desempeño decreciente de LSTM hacia el norte de Chile por la escasez y baja resolución de datos meteorológicos. En estas regiones, las lluvias suelen estar subestimadas por productos satelitales (Zambrano-Bigiarini et al., 2017) y variables como la capacidad de almacenamiento del suelo presentan mayor incertidumbre (De la Fuente, 2021), lo que limita el aprendizaje del modelo. Además, la memoria impuesta de 365 días no siempre refleja la persistencia hidrológica de largo plazo característica de las cuencas áridas (Hashemi et al., 2022; Gauch et al., 2021). En conjunto, el LSTM rinde mejor en regiones húmedas con señales climáticas más estables y datos de mayor calidad, mientras que su precisión disminuye en zonas áridas. Esto evidencia que la robustez e interpretabilidad del modelo dependen directamente del contexto hidroclimático y la calidad de la información, reforzando la necesidad de mejorar el monitoreo meteorológico y la representación de la memoria hidrológica en zonas de montaña.



**Figura 3.** Ajuste entre caudales observados y simulados por el modelo LSTM en la cuenca del Río Ibañez (período de testeo), representativa de una zona húmeda nivo-pluvial.



**Figura 4.** Ajuste entre caudales observados y simulados por el modelo LSTM en la cuenca del Río Huasco (período de testeo), representativa de una región árida.

## 3.2 Análisis de sensibilidad ante perturbaciones

### 3.2.1 Clasificación hidrológica

Para interpretar las respuestas del análisis de sensibilidad (AS), las cuencas se clasificaron en dos grupos principales según la influencia nival en su régimen: pluvio-nival (Lircay, Ñuble, Cautín y Liquiñe) y nivo-pluvial (Ibáñez y Las Chinas). Esta clasificación se basó en la fracción de nieve, la estacionalidad de la precipitación, la altitud media y el mes de máximo caudal, siguiendo el enfoque de Báez-Villanueva et al. (2023) y complementándolo con un análisis propio de indicadores de nivalidad y fracción de nieve del dataset CAMELS-CL para las cuencas no incluidas en dicho estudio.

Las cuencas pluvio-nivales concentran sus caudales máximos en invierno y dependen principalmente de la precipitación líquida, mientras que las nivo-pluviales presentan pulsos de deshielo en primavera o verano, que amortiguan temporalmente su respuesta hidrológica. Esta distinción es clave para interpretar el AS, ya que las cuencas con mayor componente nival suelen mostrar respuestas más marcadas a los cambios térmicos, mientras que las pluviales son más sensibles a la precipitación.

### 3.2.2 Perturbaciones individuales

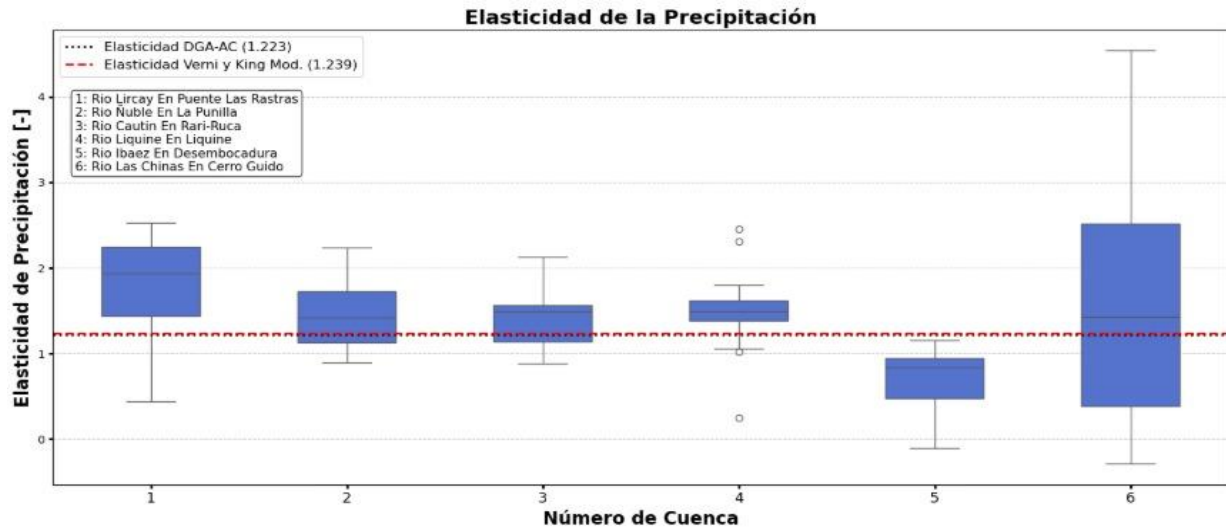
El análisis de sensibilidad evaluó la respuesta del caudal máximo diario frente a perturbaciones controladas en tres variables: precipitación, temperatura y cobertura forestal. Las Figuras 5, 6 y 7 muestran los resultados obtenidos, expresados como elasticidad, entendida como el cambio relativo en el caudal máximo diario frente a un cambio relativo en cada variable.

La Figura 5 muestra que todas las cuencas mostraron elasticidades positivas, confirmando a la precipitación como principal forzante del caudal. Las cuencas pluvio-nivales respondieron con mayor intensidad, mientras que las nivales mostraron una reacción más amortiguada por el almacenamiento nival (Báez-Villanueva et al., 2024). Para referencia, se incluyeron los valores promedio de los métodos empíricos DGA-AC (1.22) y Verni & King modificado (1.24) (DGA, 2005). En cuencas australes como Las Chinas, la dispersión de elasticidades refleja la influencia del gradiente altitudinal y de la sombra de lluvia, donde pequeñas variaciones térmicas o en la posición de la isoterma 0 °C pueden modificar drásticamente la fracción de precipitación efectiva.

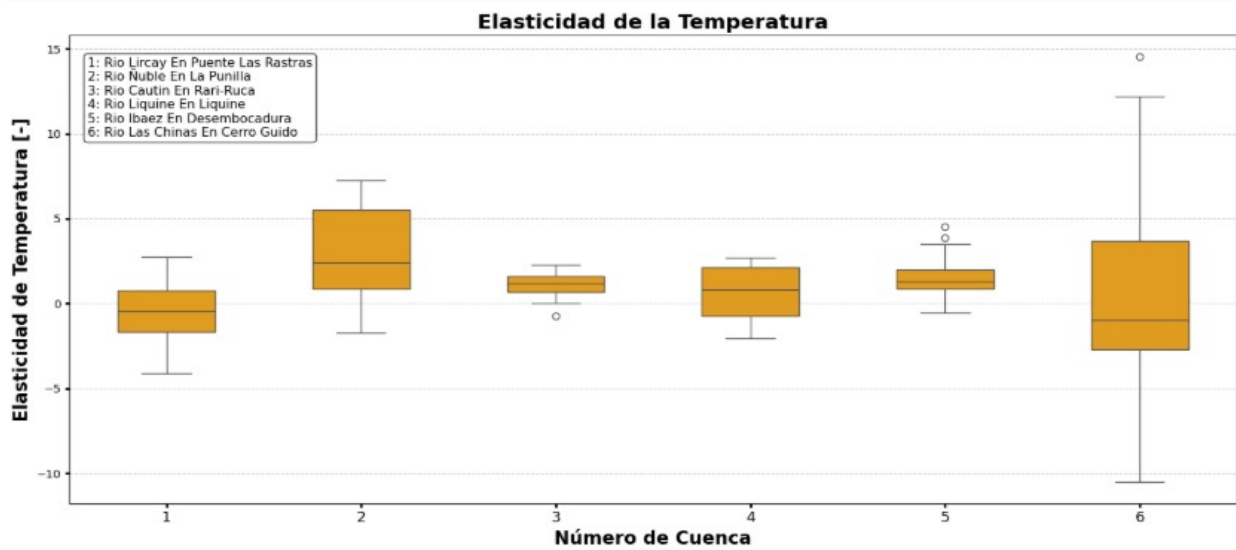
En el caso de las perturbaciones de temperatura (Figura 6), las respuestas fueron más heterogéneas: algunas cuencas, como Ñuble y Las Chinas, presentaron aumentos del caudal por el ascenso de la isoterma 0 °C y eventos de lluvia sobre nieve (ROS), mientras que otras, principalmente pluviales como Lircay, mostraron reducciones ligadas a la evapotranspiración (Escanilla-Minchel et al., 2020). La magnitud de la respuesta depende de la relación entre la altitud máxima de la cuenca y el rango de variación de la isoterma 0 °C, coherente con lo documentado por Musselman et al. (2018) y Brandt et al. (2022).

Por último, las perturbaciones de cobertura forestal (Figura 7) fueron en general bajas y negativas, confirmando el rol regulador del bosque. Un aumento en la vegetación redujo el caudal máximo por mayor interceptación y evapotranspiración, efecto más notorio en Liquiñe, Lircay y Cautín, cuencas con alta cobertura inicial, y mínimo en Ñuble, Ibáñez y Las Chinas. Estos resultados

concuerdan con lo descrito por Hall et al. (2024) y Li et al. (2024) sobre la capacidad del bosque para amortiguar las crecidas.



**Figura 5.** Elasticidad del caudal máximo diario frente a perturbaciones en la precipitación para las seis cuencas aptas para el análisis de sensibilidad (AS). La línea punteada negra representa el valor promedio reportado por Método DGA-AC para Crecidas Pluviales (1.223), y la línea discontinua roja representa el valor obtenido por Método de Verni y King Modificado (1.239).



**Figura 6.** Elasticidad del caudal máximo diario frente a perturbaciones en la temperatura.

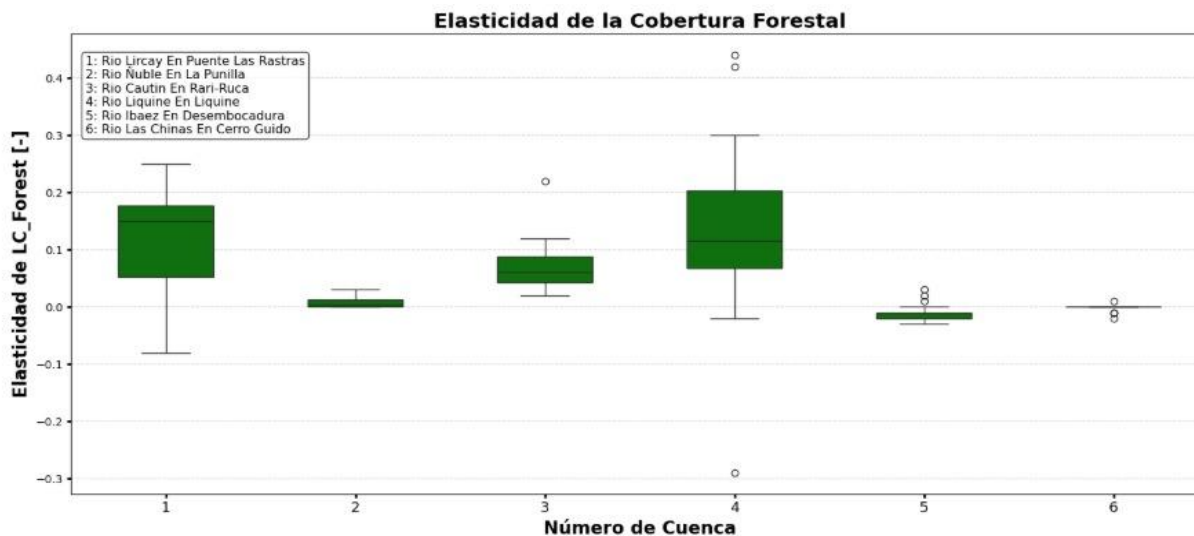
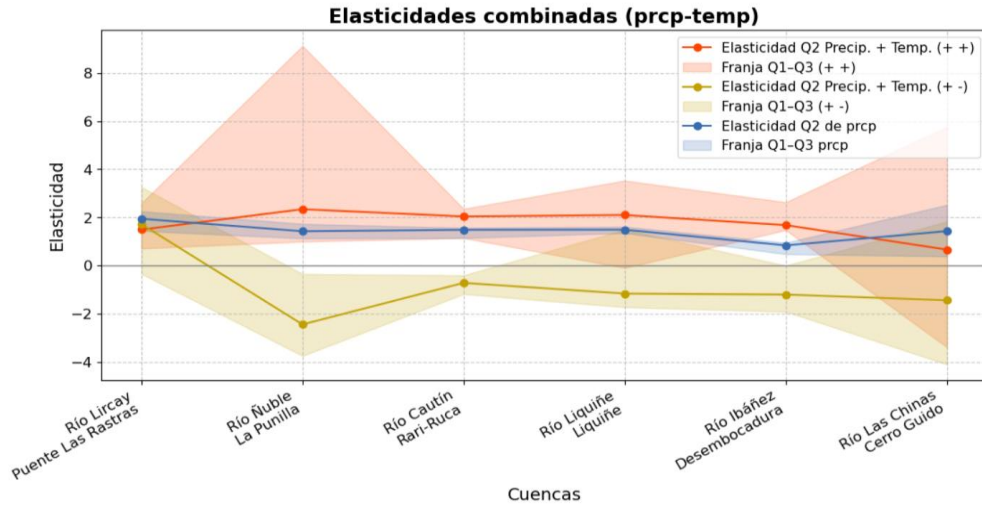


Figura 7. Distribución de la elasticidad del caudal frente a perturbaciones en la cobertura forestal (LC\_Forest).

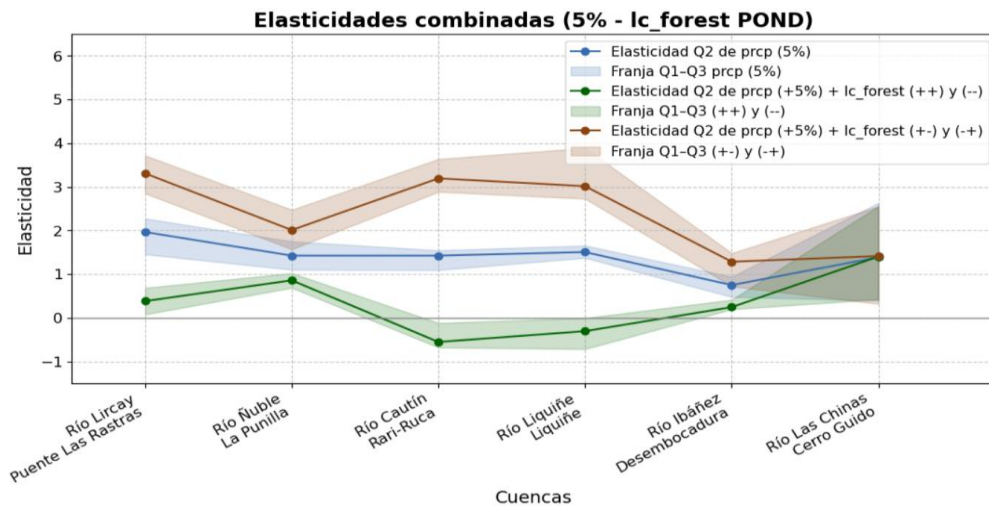
### 3.2.3 Perturbaciones combinadas

Las perturbaciones combinadas mostraron que la interacción entre variables climáticas o estructurales genera respuestas no lineales en el caudal máximo diario. En el caso de la precipitación y la temperatura (Figura 8), el escenario de aumentos simultáneos (+/+) produjo incrementos más intensos en el caudal que las perturbaciones de precipitación por sí solas, especialmente en cuencas con influencia nival, donde el ascenso de la isoterma 0 °C transforma nieve en lluvia y acelera la escorrentía (Patterson et al., 2022). Por el contrario, cuando la temperatura disminuye (+/-), se observó una reducción en la elasticidad del caudal, ya que una mayor fracción de la precipitación se acumula como nieve. Este comportamiento confirma que la altitud, la fracción nival y la posición relativa de la isoterma son factores determinantes en la sensibilidad de cada cuenca (Martel et al., 2024). Estos resultados reflejan la acción conjunta del ascenso de la isoterma 0 °C y del gradiente altitudinal de la precipitación, factores que potencian los eventos de lluvia sobre nieve (ROS) y explican las diferencias observadas entre zonas centro-sur y australes (Musselman et al., 2018; Brandt et al., 2022; Ocampo-Melgar et al., 2020; Zarzycki et al., 2024).

La combinación de precipitación y cobertura forestal (Figura 9) también reveló interacciones relevantes. Cuando ambas variables aumentaron o disminuyeron en conjunto, las cuencas con mayor cobertura forestal inicial mostraron una reducción clara en la elasticidad del caudal, evidenciando el rol regulador de la vegetación frente a eventos extremos (Calder & Aylward, 2006). En cambio, cuando los cambios fueron opuestos (por ejemplo, aumento de precipitación y disminución de cobertura), la elasticidad se amplificó en cuencas pluviales y pluvio-nivales con alta densidad de bosque, como Lircay y Liquiñe, debido a la pérdida de la capacidad de almacenamiento e infiltración del dosel vegetal. En cuencas con menor vegetación, el efecto combinado fue menor, lo que indica que factores como la aridez, la pendiente y el tamaño de la cuenca limitan la influencia del bosque. Esto confirma que el bosque modula la escorrentía mediante procesos de interceptación, infiltración y evapotranspiración, funciones que se debilitan al reducirse la cobertura vegetal (Li et al., 2024; Hall et al., 2024).



**Figura 8.** Elasticidad del caudal máximo diario frente a perturbaciones combinadas de precipitación y temperatura en seis cuencas andinas. La línea azul muestra el caso base (solo precipitación), la roja el aumento simultáneo (+prcp, +temp) y la amarilla el aumento de precipitación con disminución de temperatura (+prcp, -temp). Cada línea corresponde a la mediana (Q2) y las bandas sombreadas al rango intercuartílico (Q1–Q3), mostrando la variabilidad de la respuesta.



**Figura 9.** Elasticidad del caudal máximo diario frente a perturbaciones combinadas de precipitación (+5 %) y cobertura forestal en seis cuencas. La línea azul muestra el efecto de modificar solo la precipitación, la verde los cambios sincronizados en ambas variables (++ o --) y la café los cambios opuestos (+/- o -/+). Las líneas indican la mediana (Q2) y las bandas sombreadas el rango intercuartílico (Q1–Q3), reflejando la variabilidad de la respuesta.

#### 4. Conclusiones

Este estudio evaluó la capacidad de una red Long Short-Term Memory (LSTM) para representar y comprender la generación de caudales máximos diarios en trece cuencas chilenas con regímenes hidroclimáticos contrastantes. Más que sustituir a los modelos físico-conceptuales, este enfoque busca complementarlos, combinando la capacidad predictiva del aprendizaje profundo con la posibilidad de interpretar su comportamiento hidrológico mediante análisis de sensibilidad (AS). El modelo alcanzó un KGE de 0.64 en validación y 0.56 en prueba, con mejor desempeño en cuencas húmedas del sur y Patagonia, y menor ajuste en regiones áridas del norte, donde la escasez y baja resolución de los datos limitan la representación de procesos. Aun así, el LSTM reprodujo

patrones coherentes con la dinámica de cada régimen, confirmando que su estructura de memoria puede capturar interacciones entre forzantes climáticos y atributos del paisaje incluso sin parametrizaciones explícitas.

El AS reveló que la precipitación es el principal forzante de los caudales extremos, seguida por la temperatura —cuyo efecto depende de la posición de la isoterma 0 °C— y por la cobertura forestal, que actúa como un amortiguador natural. Las perturbaciones combinadas mostraron respuestas no lineales: el aumento simultáneo de lluvia y temperatura intensificó las crecidas al favorecer la fusión nival y la lluvia sobre nieve, mientras que la pérdida de vegetación amplificó los picos de escorrentía, en contraste con el efecto atenuante del bosque.

En conjunto, los resultados demuestran que los modelos de Machine Learning pueden ser interpretables y físicamente consistentes mediante metodologías como el AS, permitiendo abrir parcialmente la “caja negra” y comprender los mecanismos que originan las crecidas extremas. Este enfoque, basado en la regionalización del aprendizaje entre cuencas, representa una herramienta prometedora para identificar sistemas vulnerables, fortalecer la gestión del riesgo y orientar medidas de adaptación en un contexto de creciente variabilidad climática.

## REFERENCIAS

Addor, N., Nearing, G., Prieto, C., Newman, A. J., Le Vine, N., & Clark, M. P. (2018). A ranking of hydrological signatures based on their predictability in space. *Water Resources Research*, 54(11), 8792–8812. <https://doi.org/10.1029/2018WR022606>

Álvarez-Garreton, C., Mendoza, P. A., Boisier, J. P., Addor, N., Galleguillos, M., Zambrano-Bigiarini, M., Lara, A., Puelma, C., Cortés, G., Garreaud, R., McPhee, J., & Ayala, Á. (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>

Anderson, S., & Radić, V. (2022). Interpreting deep machine learning for streamflow modeling across glacial, nival, and pluvial regimes in southwestern Canada. *Frontiers in Water*, 4, Article 934709. <https://doi.org/10.3389/frwa.2022.934709>

Baez-Villanueva, O. M., Zambrano-Bigiarini, M., Miralles, D. G., Beck, H. E., Siegmund, J. F., Alvarez-Garreton, C., Verbist, K., Garreaud, R., Boisier, J. P., & Galleguillos, M. (2023). Supplementary material for “On the timescale of drought indices for monitoring streamflow drought considering catchment hydrological regimes”. *EGU sphere*. <https://doi.org/10.5194/egusphere-2023-1911>

Barrera, C., Núñez Cobo, J., Souvignet, M., Oyarzún, J., & Oyarzún, R. (2020). Streamflow elasticity, in a context of climate change, in arid Andean watersheds of north-central Chile. *Hydrological Sciences Journal*, 65(10), 1707–1719. <https://doi.org/10.1080/02626667.2020.1770764>

Calder, I. R., & Aylward, B. (2006). Forest and floods: Moving to an evidence-based approach to watershed and integrated flood management. *Water International*, 31(1), 87–99. <https://doi.org/10.1080/02508060608691918>

De la Fuente, L. A. (2021). Using big-data to develop catchment-scale hydrological models for Chile (Tesis de maestría). University of Arizona, Tucson, Estados Unidos. <http://hdl.handle.net/10150/656824>

De la Fuente, L. A., Gupta, H. V., & Condon, L. E. (2023). Toward a multi-representational approach to prediction and understanding, in support of discovery in hydrology. *Water Resources Research*, 59, e2021WR031548. <https://doi.org/10.1029/2021WR031548>

Dirección General de Aguas. (s.f.). Manual de cálculo de crecidas y caudales mínimos en cuencas sin información fluviométrica. Ministerio de Obras Públicas, Gobierno de Chile. Recuperado de <https://www.dga.cl>

Dirección Meteorológica de Chile. (2024). Reporte anual de la evolución del clima en Chile: Informe climático del año 2023. Oficina de Cambio Climático, Sección Climatología, Dirección General de Aeronáutica Civil. <https://www.meteochile.gob.cl>

Escanilla-Minchel, R., Alcayaga, H., Soto-Alvarez, M., Kinnard, C., & Urrutia, R. (2020). Evaluation of the impact of climate change on runoff generation in an Andean glacier watershed. *Water*, 12(12), 3547. <https://doi.org/10.3390/w12123547>

Feng, D., Fang, K., & Shen, C. (2020). Enhancing streamflow forecast and extracting insights using long-short term memory networks with data integration at continental scales. *Water Resources Research*, 56(9), e2019WR026793. <https://doi.org/10.1029/2019WR026793>

Frame, J. M., Kratzert, F., Klotz, D., Gauch, M., Shalev, G., Gilon, O., Qualls, L. M., Gupta, H. V., & Nearing, G. S. (2022). Deep learning rainfall–runoff predictions of extreme events. *Hydrology and Earth System Sciences*, 26(12), 3377–3392. <https://doi.org/10.5194/hess-26-3377->

Gupta, H. V., & Razavi, S. (2017). Challenges and future outlook of sensitivity analysis. En H. Vereecken (Ed.), *Sensitivity analysis in earth observation modelling* (Cap. 20, pp. 397–415). Elsevier. <https://doi.org/10.1016/B978-0-12-803011-0.00020-3>

Hall, J., Scholl, M., Shanley, J., Matt, S., & Uriarte, M. (2024). Forest cover lessens hurricane impacts on peak streamflow. *Hydrological Processes*, 38(8), e15249. <https://doi.org/10.1002/hyp.15249>

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>

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>

Kratzert, F., Klotz, D., Herrnegger, M., Sampson, A. K., Hochreiter, S., & Nearing, G. S. (2019). Toward improved predictions in ungauged basins: Exploiting the power of machine learning. *Water Resources Research*, 55(12), e2019WR026065. <https://doi.org/10.1029/2019WR026065>

Martel, J.-L., Brissette, F., Arsenault, R., Turcotte, R., Castañeda-Gonzalez, M., Armstrong, W., Mailhot, E., Pelletier-Dumont, J., Rondeau-Genesse, G., & Caron, L.-P. (2024). Assessing the adequacy of traditional hydrological models for climate change impact studies: A case for long-short-term memory (LSTM) neural networks. *EGUsphere*. <https://doi.org/10.5194/egusphere-2024-2133>

Nauditt, A., Birkel, C., Soulsby, C., & Ribbe, L. (2017). Conceptual modelling to assess the influence of hydro-climatic variability on runoff processes in data scarce semi-arid Andean catchments. *Hydrological Sciences Journal*, 62(4), 515–532. <https://doi.org/10.1080/02626667.2016.1240870>

Parra, V., Arumí, J. L., & Muñoz, E. (2019). Identifying a suitable model for low-flow simulation in watersheds of South-Central Chile: A study based on a sensitivity analysis. *Water*, 11(7), 1506. <https://doi.org/10.3390/w11071506>

Patterson, N. K., Lane, B. A., Sandoval-Solis, S., Persad, G. G., & Ortiz-Partida, J. P. (2022). Projected effects of temperature and precipitation variability change on streamflow patterns using a functional flows approach. *Earth's Future*, 10(7), e2021EF002631. <https://doi.org/10.1029/2021EF002631>

Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. *Water Resources Research*, 54(11), 8558–8593. <https://doi.org/10.1029/2018WR022643>