



UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA

Departamento de Obras Civiles

Evaluación de la respuesta del caudal máximo diario mediante redes Long Short Term Memory

Memoria de Título presentada por

Luis Daniel Rojas Fredes

como requisito parcial para optar al título de la carrera de

Ingeniería Civil

Profesor Guía:

Luis De La Fuente Contreras

Profesora Co-referente:

Lina Castro

Abril de 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: Evaluación de la respuesta del caudal máximo diario mediante redes Long Short Term Memory

Nombre del candidato(a): Luis Daniel Rojas Fredes

Carrera / Grado: Ingeniería Civil

Campus: Santiago Santiago San Joaquín ; **Departamento:** Obras Civiles

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Luis Andrés De la Fuente Contreras, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 17 de Noviembre, 2025 **Firma:**

Estudiante o Candidato(a):

Fecha: 17 de Noviembre, 2025 **Firma:**

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.



UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA

TITULO DE LA TESIS:

**Evaluación de la respuesta del caudal máximo diario mediante redes
Long Short Term Memory (LSTM)**

AUTOR:

Luis Daniel Rojas Fredes

TRABAJO DE MEMORIA, presentado como requisito parcial para optar al título de la
carrera de INGENIERIA CIVIL de la Universidad Técnica Federico Santa María.

	Nombre	Firma
Prof. Guía	Luis De La Fuente Contreras	
Miembro 1 Comisión		
Miembro 2 Comisión		

Valparaíso/Santiago, Chile, abril de 2025

Evaluación de la respuesta del caudal máximo diario mediante redes Long Short Term Memory (LSTM)

Luis Daniel Rojas Fredes, Luis De La Fuente Contreras

Universidad Técnica Federico Santa María

1 Resumen

La predicción e interpretación de caudales extremos representa un desafío crucial para la gestión hídrica y la planificación de infraestructura en Chile, donde la fuerte variabilidad climática, los gradientes altitudinales y la escasa cobertura de observaciones —menos de 0,3 estaciones por cada 100 km² sobre los 2000 m s.n.m. (Álvarez-Garretón et al., 2018)— limitan 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 cambio climático (Vicuña et al., 2011; Nauditt et al., 2017; Parra et al., 2019).

Ante esta limitación, se implementó un modelo Long Short-Term Memory (LSTM) regionalizado, entrenado con trece cuencas representativas de las seis macrozonas climáticas del país. Este enfoque multicuenca permitió compensar la falta de datos locales mediante la diversidad espacial, siguiendo la evidencia de que las LSTM regionales pueden generalizar patrones hidrológicos entre cuencas (Kratzert et al., 2019; De la Fuente et al., 2023). Más que buscar un mejor desempeño predictivo, el objetivo fue abrir la caja negra del aprendizaje profundo mediante un análisis de sensibilidad ante perturbaciones controladas en precipitación, temperatura y cobertura forestal, constituyendo la primera aplicación de este tipo en Chile.

El modelo reprodujo relaciones hidrológicas coherentes: la precipitación surgió como forzante dominante; la temperatura mostró respuestas asociadas a la posición de la isoterma 0 °C, y la cobertura forestal evidenció un efecto amortiguador sobre los caudales máximos. En escenarios combinados, se observaron interacciones no lineales: las lluvias cálidas amplificaron las crecidas, mientras que el aumento de vegetación o el enfriamiento térmico tendieron a atenuarlas. El desempeño, expresado como mediana del coeficiente Kling-Gupta Efficiency ($KGE = 0.64$ en validación y 0.56 en prueba), confirma una representación estable y físicamente consistente pese a la resolución diaria y la ausencia de calibraciones locales.

En conjunto, este estudio demuestra que los modelos LSTM pueden ser interpretables y útiles para explorar la sensibilidad hidrológica en cuencas con datos escasos. Su aplicación permite identificar sistemas más vulnerables ante cambios climáticos o de cobertura vegetal, entregando información valiosa para el diseño de obras hidráulicas, la planificación territorial y las estrategias de adaptación en un contexto de creciente variabilidad climática.

Tabla de contenido

1	Resumen	3
1	Introducción	5
3	Metodología.....	7
3.1.	Área de estudio	7
3.2.	Base de datos y variables utilizadas.....	9
3.3.	División temporal del análisis	10
3.4.	Estructura del modelo LSTM y configuración de entrada	11
3.5.	Análisis de sensibilidad	13
3.5.1.	Fundamento y aplicación del análisis de sensibilidad	13
3.5.2.	Índices de elasticidad utilizados.....	16
3.5.3.	Criterios de selección de cuencas	18
3.4.	Evaluación del Desempeño	20
4	Resultados y discusión.....	20
4.1	Desempeño general del modelo LSTM	20
4.1.1.	Evaluación cuantitativa general	20
4.1.2.	Desempeño del modelo en contextos hidroclimáticos contrastantes.....	22
4.1.3.	Caso especial: cuenca del río Lircay.....	24
4.2.	Análisis de sensibilidad ante perturbaciones	26
4.2.1.	Clasificación hidrológica de las cuencas para análisis de sensibilidad	26
4.2.2.	Resultados de perturbaciones individuales	28
4.2.3.	Resultados de perturbaciones combinadas	34
4.2.4.	Síntesis interpretativa del análisis de sensibilidad	37
5	Conclusiones.....	39
6	Referencias	41
7	Anexos.....	48

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 de desastres naturales (Barrera et al., 2020; Broderick et al., 2019). Comprender qué factores los originan y anticipar sus efectos resulta fundamental para reducir impactos en la población y en los sistemas productivos. En Chile, la marcada variabilidad climática, los fuertes gradientes altitudinales y la baja densidad de observaciones complejizan la modelación y la transferencia entre cuencas, por lo que disponer de herramientas explicativas resulta especialmente relevante (De la Fuente, 2021; De la Fuente et al., 2023).

Estudios recientes han evidenciado que la red hidrometeorológica chilena presenta una cobertura particularmente deficiente en zonas de montaña. Álvarez-Garretón et al. (2018) documentaron que cerca del 90 % de los ~500 pluviómetros al sur de los 34° S se ubican por debajo de los 1000 m s.n.m., dejando sin observación directa la mayor parte de las áreas nivosas y altoandinas. En promedio, Chile cuenta con apenas una estación de precipitación por cada 1364 km², mientras que países como Suiza alcanzan densidades superiores a una por cada 100 km². Por encima de los 2000 m, la densidad nacional cae incluso bajo 0,3 estaciones/100 km², lo que limita severamente la posibilidad de calibrar y validar modelos en cabeceras de cuenca (Ministerio de Obras Públicas, 2020). Este vacío de información no solo restringe el monitoreo de los procesos de acumulación y fusión nival, sino que también impide representar adecuadamente la respuesta hidrológica en las zonas donde se originan los principales aportes hídricos del país.

Modelos físico-conceptuales y distribuidos como VIC, SAC-SMA o HBV han sido ampliamente utilizados en hidrología para representar el ciclo lluvia–escorrentía. Su principal virtud es la estructura explícita, que permite relacionar parámetros con procesos hidrológicos. Sin embargo, en contextos de alta montaña o bajo condiciones cambiantes, estos modelos enfrentan serias limitaciones. Diversos trabajos han mostrado que su desempeño se degrada al extrapolar fuera de las condiciones de calibración, introduciendo incertidumbre estructural (Merz et al., 2011; Coron et al., 2012). En Chile, Vicuña et al. (2011) y Parra et al. (2019) observaron que modelos como HBV y GR4J pierden capacidad predictiva en escenarios de cambio climático o en regiones semiáridas y andinas, donde la representación de procesos nivales, la variabilidad estacional y la falta de datos meteorológicos reducen su robustez. Nauditt et al. (2017) encontraron resultados similares en cuencas del norte chico, evidenciando que incluso con ajustes en los datos de entrada las simulaciones mantienen sesgos sistemáticos y alta sensibilidad a la calibración. Estas limitaciones reflejan que la estructura rígida de los modelos conceptuales responde mal a nuevos escenarios hidrológicos —por ejemplo, retroceso nival o cambios de cobertura vegetal—, lo que ha sido reportado también en aplicaciones recientes a nivel nacional (Duethmann et al., 2020; Nearing et al., 2021).

En los últimos años, las redes neuronales Long Short-Term Memory (LSTM) han surgido como una alternativa prometedora, mostrando desempeños competitivos en distintos regímenes hidrológicos (Kratzert et al., 2018, 2019; Martel et al., 2024). Estas redes son capaces de capturar dinámicas complejas, como la acumulación y fusión de nieve, directamente a partir de series meteorológicas, sin requerir parametrizaciones explícitas (Anderson & Radić, 2022). Kratzert et al. (2018) demostraron que una LSTM puede reproducir internamente los procesos de almacenamiento y liberación nival, incluso sin incluir variables de nieve entre sus entradas, mientras que Anderson y Radić (2022)

mostraron que este tipo de redes logra representar de manera realista la transición estacional lluvia–nieve en cuencas de montaña. Sin embargo, su principal crítica sigue siendo su carácter de “*caja negra*”: aunque predicen con solidez, resulta difícil comprender qué patrones internos están aprendiendo y cómo estos se relacionan con procesos hidrológicos reales (Jiang et al., 2022).

De esta forma, tanto los modelos físico-conceptuales como los de aprendizaje profundo enfrentan una tensión común: la falta de interpretabilidad. En los primeros, la estructura explícita puede no reflejar fielmente los procesos reales debido a simplificaciones y calibraciones locales; en los segundos, la opacidad de sus representaciones internas limita la posibilidad de explicar las relaciones entre insumos y salidas. Esta disyuntiva se agrava en Chile, donde la escasez de datos en cabeceras impide calibraciones detalladas, pero existe abundante información espacial sobre atributos de cuenca. Esta combinación abre una oportunidad para enfoques regionalizados que, como el implementado en este estudio, sustituyen la carencia temporal por diversidad espacial, entrenando la red con cuencas representativas de seis macrozonas climáticas.

El enfoque regionalizado utilizado en este trabajo se sustenta en la evidencia internacional más reciente. Kratzert et al. (2019) desarrollaron un modelo *Entity-Aware LSTM* (EA-LSTM) capaz de combinar entradas dinámicas —precipitación, temperatura y radiación— con atributos estáticos de cuenca, demostrando que una única red entrenada con 531 cuencas del dataset CAMELS logra un desempeño superior a modelos hidrológicos clásicos calibrados cuenca por cuenca e incluso a modelos regionales tradicionales. Este hallazgo probó que un modelo LSTM regional es capaz de “aprender” comportamientos hidrológicos generales y luego especializarse en cada cuenca según sus atributos físicos, mejorando su capacidad de generalización y su estabilidad en condiciones no observadas. De forma coherente, estudios recientes como Martel et al. (2024) y De la Fuente et al. (2023) han replicado con éxito esta estrategia en distintos contextos climáticos, incluyendo cuencas chilenas, confirmando que la regionalización del aprendizaje permite aprovechar la heterogeneidad espacial para compensar la escasez local de datos. En un país con baja densidad de observaciones hidrometeorológicas, como Chile, esta aproximación ofrece una ventaja estratégica: el modelo puede transferir información entre cuencas, fortaleciendo la predicción y la interpretabilidad incluso en zonas altoandinas donde los registros son escasos.

Para enfrentar el problema de la opacidad, se han desarrollado técnicas de interpretación que buscan abrir parcialmente la caja negra de los modelos de aprendizaje automático. Una de ellas es el análisis de sensibilidad, que evalúa cómo varían las predicciones frente a perturbaciones controladas de las entradas (Scholbeck et al., 2024). A nivel internacional, el uso de estos enfoques ha comenzado a extenderse a redes neuronales aplicadas a la hidrología, pero aún son escasos los trabajos que los aplican a eventos extremos o en contextos de alta complejidad hidroclimática. En este sentido, el presente estudio representa la primera aplicación en Chile de un análisis de sensibilidad perturbacional sobre un modelo LSTM, orientado específicamente a caudales máximos diarios. Este aporte no solo busca predecir, sino también interpretar: vincular las respuestas del modelo con mecanismos hidrológicos conocidos —como la elevación de la isoterma 0 °C, los eventos de lluvia sobre nieve o el efecto regulador del bosque— y evaluar su coherencia con la dinámica real de las cuencas.

Desde una perspectiva operativa, los resultados de sensibilidad del LSTM pueden dialogar con instrumentos nacionales de gestión del riesgo ya en uso. En Chile, el Atlas de Riesgo Climático (ARClím, 2023) despliega, con cobertura nacional y resolución comunal, mapas de amenaza, exposición y sensibilidad que se combinan para estimar el riesgo por cadenas de impacto del sector recursos hídricos, incluyendo inundaciones por desbordes de ríos, inundaciones urbanas, estrés hídrico y sequías hidrológicas. En particular, para los desbordes fluviales ARClím publica mapas de riesgo para períodos de retorno de 25, 50 y 100 años, derivados de índices de Amenaza, Exposición y Vulnerabilidad. En este marco, un análisis de sensibilidad como el propuesto permite identificar qué cuencas verían incrementos más marcados en sus caudales máximos diarios ante cambios plausibles en lluvia o temperatura. Esa información constituye un insumo directo para priorizar medidas de adaptación: refuerzo de defensas fluviales, actualización de caudales de diseño o planes de contingencia en las cuencas más sensibles, coherente con los lineamientos nacionales que llaman a considerar el riesgo hidroclimático en la planificación territorial y a fortalecer el monitoreo en zonas nivasas.

Así, esta memoria busca contribuir a un problema de fondo en la hidrología actual: cómo alcanzar interpretabilidad en modelos de aprendizaje profundo aplicados a caudales extremos, especialmente en regiones con escasa observación directa. Más que presentar un modelo con métricas superiores, el valor de este trabajo radica en mostrar que, mediante análisis de sensibilidad, es posible abrir parcialmente la caja negra de las LSTM, vincular sus respuestas con procesos hidrológicos reconocibles y extraer conocimiento útil para la gestión del agua y la planificación de infraestructura en un contexto de creciente incertidumbre climática (Shen, 2018; Anderson & Radić, 2022).

3 Metodología

A continuación, detallan las etapas y procedimientos considerados para el desarrollo de esta memoria. Primero, se describe la selección de las cuencas de análisis y las variables empleadas. Luego, se expone la estructura del modelo LSTM y el proceso de entrenamiento seguido. Posteriormente, se explica el diseño del análisis de sensibilidad implementado, incluyendo la especificación de las perturbaciones aplicadas y las métricas utilizadas para evaluar la respuesta del modelo. Finalmente, se presentan los criterios para la evaluación del desempeño del modelo en las distintas cuencas seleccionadas.

3.1. Área de estudio

El presente estudio se desarrolla sobre un conjunto de trece cuencas hidrográficas distribuidas a lo largo del territorio chileno, seleccionadas con el objetivo de representar una amplia gama de condiciones hidroclimáticas y morfológicas. Esta diversidad es clave para evaluar el desempeño y la sensibilidad de modelos basados en aprendizaje profundo, como las redes LSTM, frente a contrastes marcados en variables físicas, climáticas y de cobertura vegetal.

La selección de las cuencas se realizó en base a cuatro criterios principales: (1) alta disponibilidad de datos, exigiendo al menos un 80 % de registros diarios completos en el periodo de análisis; (2) representatividad climática a nivel nacional, incorporando cuencas de seis macrozonas del país (Norte Lejano, Norte Cercano, Zona Central, Zona Sur, Zona Austral y Patagonia Austral); (3) baja intervención antrópica, medida mediante

el índice disponible en la base de datos CAMELS-CL; y (4) uso exclusivo de fuentes de datos oficiales.

La Figura 1 muestra la ubicación geográfica de las estaciones hidrométricas correspondientes a estas trece cuencas, cubriendo un rango latitudinal que va desde el extremo norte árido (Río Loa) hasta la Patagonia austral (Río Grande). Esta distribución permite incluir cuencas con regímenes hídricos contrastantes —nival, pluvial y mixto—, con diferencias significativas en altitud media, cobertura de bosque y precipitaciones anuales. Tales contrastes son fundamentales para el objetivo interpretativo de este trabajo, ya que ayudan a identificar cómo atributos físicos y climáticos influyen en la generación de caudales máximos diarios bajo diferentes condiciones geográficas y climáticas.




Figura 1. Ubicación de las estaciones hidrométricas seleccionadas.

Fuente: Elaboración propia con base en datos de CAMELS-CL.

La Tabla 1 resume las principales características morfológicas y climáticas de las cuencas seleccionadas, incluyendo su número de identificación, nombre, área, elevación media, cobertura de bosque, precipitación media diaria y temperatura media anual. La cobertura de bosque se incluye debido a su influencia en procesos hidrológicos como la interceptación de la precipitación, la evapotranspiración y la regulación de caudales extremos, lo que la convierte en una variable clave para el análisis de sensibilidad. Los valores de precipitación y temperatura presentados en la Tabla 1 corresponden a la serie histórica completa de CAMELS-CL para cada cuenca, y se incluyen únicamente con fines de caracterización general. No obstante, el análisis de este estudio se basa en un subconjunto temporal específico (1995–2014), cuyo detalle de división en fases se presenta en la sección 3.3. Este abanico de condiciones —que va desde cuencas áridas y sin vegetación como el río Loa, hasta otras con abundante cobertura forestal y alta pluviosidad como Liquiñe— permite contextualizar adecuadamente el rango de condiciones al que fue sometido el modelo durante el entrenamiento.

Tabla 1. Características morfológicas y climáticas de las cuencas seleccionadas para el estudio.

Fuente: Elaboración propia en base a CAMELS-CL.

Nº E.H.	Nombre de la Estación Hidrográfica	Área [km²]	Elev. Media [m]	Pend. Media [%]	Cobertura de Bosque [%]	Precip. media [mm/día]	Temp. Media [°C]
1	Río Loa Antes Represa Lequena	2053	4094	10.0	0.0	0.4	4.1
2	Río Huasco En Santa Juana	7384	3344	24.6	0.0	0.3	6.6
3	Río Elqui En Algarrobal	5670	3418	26.1	0.0	0.4	6.0
4	Río Hurtado En San Agustín	672	3724	24.6	0.1	0.7	3.8
5	Río Mapocho En Los Almendros	638	2779	25.2	0.4	1.3	6.6
6	Río Teno Después De Junta Con Claro	1205	2090	26.6	10.2	4.2	8.1
7	Río Lircay En Puente Las Rastras	382	1052	16.6	66.0	4.4	11.5
8	Río Ñuble En La Punilla	1254	1696	23.9	13.6	5.0	8.0
9	Río Cautín En Rari-Ruca	1306	1125	15.2	55.0	7.1	8.4
10	Río Liquiñe En Liquiñe	368	1122	21.1	75.8	8.5	7.5
11	Río Ibáñez En Desembocadura	2405	1055	21.0	24.2	4.0	4.4
12	Río Las Chinas En Cerro Guido	901	741	15.5	6.5	1.3	4.6
13	Río Grande En Tierra Del Fuego	2841	259	8.6	17.7	1.9	4.4

3.2. Base de datos y variables utilizadas

La información utilizada en este estudio proviene principalmente de CAMELS-CL (Catchment Attributes and Meteorology for Large-Sample Studies – Chile Dataset; Álvarez-Garreton et al., 2018) y de los registros oficiales de caudales entregados por la Dirección General de Aguas de Chile (DGA), que se emplean para obtener la secuencia temporal del caudal máximo diario, variable objetivo de la investigación.

El conjunto CAMELS-CL, desarrollado por Álvarez-Garreton et al. (2018), corresponde a una base de datos estandarizada que reúne atributos de cuencas y meteorología para 516 unidades de análisis distribuidas entre los 17,8°S y los 55°S. Este dataset integra información obtenida a partir de observaciones satelitales, productos de reanálisis climático y registros de terreno. Ha sido utilizado en estudios hidrológicos recientes que aplican modelos basados en aprendizaje automático en el contexto chileno, al facilitar una

caracterización espacialmente coherente de las condiciones hidroclimáticas del país (De la Fuente, 2021; De la Fuente et al., 2023).

Dentro de los múltiples atributos disponibles en CAMELS-CL, se seleccionaron aquellos que, según antecedentes de la literatura y en particular el estudio de Addor et al. (2018), se consideran más relevantes para explicar la dinámica de escorrentía. En cuanto a las variables dinámicas, se utilizan series diarias de precipitación y de temperatura máxima y mínima, obtenidas del producto climático CR2MET y calculadas como el promedio espacial de todas las celdas de la malla que cubren cada cuenca. Las series utilizadas para el modelado corresponden al periodo 1995–2014, definido en función de la disponibilidad y calidad de datos, mientras que la división en fases de entrenamiento, validación y testeo se detalla en la sección 3.3. Este promedio ponderado por área permite representar de forma más precisa las condiciones climáticas de toda la cuenca, evitando la dependencia de una única estación meteorológica y reduciendo el sesgo por ubicación puntual. La precipitación se incorpora como variable de entrada debido a su rol como principal forzante en la generación de escorrentía, documentado ampliamente en estudios previos (Addor et al., 2018; De la Fuente et al., 2021; Kratzert et al., 2019; Martel et al., 2024). La temperatura, en cambio, influye de forma indirecta en procesos como la fusión de nieve y la evapotranspiración, afectando la estacionalidad de los caudales y modificando la altitud de la isoterma 0 °C, la cual determina si las precipitaciones se registran en forma de nieve o lluvia (Vásquez Yáñez, 2020; Nearing et al., 2021; Martel et al., 2024; Anderson & Radić, 2022).

La pendiente media se reconoce como un factor determinante del tiempo de concentración y de la respuesta rápida de las cuencas (Kratzert et al., 2019; De la Fuente et al., 2024). La cobertura forestal ajusta la intercepción y almacenamiento del agua, reduciendo la escorrentía superficial (Addor et al., 2018; Li et al., 2024). El índice de aridez, que caracteriza el balance hídrico de largo plazo, ha sido identificado como predictor clave del comportamiento hidrológico (De la Fuente, 2021; Martel et al., 2024). Por su parte, la estacionalidad de la precipitación permite caracterizar la variabilidad intra-anual del régimen de caudales (Kratzert et al., 2019; Nearing et al., 2021). Finalmente, la frecuencia de eventos extremos de precipitación, aunque menos estudiada, se considera relevante para capturar la ocurrencia de caudales extremos en un contexto climático de constante variación (Martel et al., 2024).

La incorporación de estas variables busca relacionar la respuesta del modelo con procesos hidrológicos conocidos de la cuenca, permitiendo interpretar de forma más clara los resultados obtenidos bajo los distintos escenarios de perturbación.

3.3. División temporal del análisis

No existe un consenso único en la literatura que establezca con precisión la longitud óptima de las fases de entrenamiento, validación y testeo al aplicar modelos LSTM en hidrología. Sin embargo, basándose en estudios clave que abordan esta problemática desde distintos contextos climáticos y metodológicos (Martel et al., 2024; Kratzert et al., 2018; De la Fuente et al., 2023), se adoptó una estrategia que busca equilibrar la capacidad de aprendizaje del modelo, la selección de hiperparámetros y la evaluación objetiva del desempeño. En este trabajo, de un total de 19 años de datos, se asignaron 13 años para entrenamiento ($\approx 68\%$), 3 años para validación ($\approx 16\%$) y 3 años para testeo ($\approx 16\%$), en concordancia con lo reportado en estudios previos (Martel et al., 2024; Kratzert et al., 2019).

Durante la fase de entrenamiento (1995–2008), el modelo ajusta sus pesos internos mediante el análisis de datos históricos de entrada, identificando relaciones no lineales entre las variables meteorológicas, fisiográficas y el caudal observado. Esta etapa cumple un rol análogo al proceso de calibración en modelos hidrológicos tradicionales y conforma la base para el aprendizaje del sistema (Martel et al., 2024; Kratzert et al., 2018).

La fase de validación (2008–2011) se destina exclusivamente a la selección de hiperparámetros y la aplicación de técnicas de detención temprana (early stopping), que permiten evitar el sobreajuste. A diferencia del entrenamiento, en esta etapa no se modifican los pesos del modelo, sino que se evalúa su rendimiento para definir el punto óptimo de detención (Ma et al., 2024; De la Fuente et al., 2023).

Finalmente, la fase de testeo (2011–2014) tiene como propósito estimar la capacidad del modelo para generalizar frente a condiciones no observadas previamente. Esta etapa se lleva a cabo sobre un conjunto independiente del entrenamiento y la validación, lo que garantiza una medición objetiva de su desempeño en escenarios distintos (Feng et al., 2020; Kratzert et al., 2019; Duethmann et al., 2020).

3.4. Estructura del modelo LSTM y configuración de entrada

El modelo utilizado en este estudio se basa en la arquitectura Long Short-Term Memory (LSTM), propuesta por Hochreiter y Schmidhuber (1997). Esta variante de las redes neuronales recurrentes (RNN) fue diseñada específicamente para superar el problema del desvanecimiento del gradiente, característico de las RNN clásicas. A través del uso de compuertas de entrada, olvido y salida, las LSTM permiten regular dinámicamente el flujo de información, lo que facilita conservar dependencias temporales de largo plazo. Esta capacidad resulta especialmente útil en modelación hidrológica, donde procesos como la acumulación y fusión de nieve, la retención de humedad en el suelo o la descarga subterránea de agua generan retardos que requieren una memoria extendida para ser representados adecuadamente (De la Fuente et al., 2023).

El comportamiento interno se formaliza mediante las siguientes ecuaciones:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$g_t = \tanh(W_{\tilde{c}} x_t + U_{\tilde{c}} h_{t-1} + b_{\tilde{c}}) \quad (3)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (4)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (5)$$

$$h_t = \tanh(c_t) \odot o_t \quad (6)$$

Donde:

- f_t es la compuerta de olvido, que decide qué parte de la memoria anterior debe ser mantenida.
- i_t es la compuerta de entrada, que controla qué nueva información se debe agregar al estado de la celda.
- g_t es la compuerta candidata, que genera una propuesta de información nueva para ser incorporada.
- c_t es el estado de la celda, que es actualizado utilizando la compuerta de olvido y la compuerta de entrada.
- o_t es la compuerta de salida, que regula cuánto del estado de la celda actual se debe transferir al estado oculto.

- h_t es el estado oculto, que se utiliza como salida de la celda. En la figura, los subíndices -1 y -2 indican el estado oculto en pasos de tiempo anteriores, representando la información que fluye desde instantes previos en la secuencia temporal.

La Figura 2 muestra la estructura funcional de una celda LSTM típica. En este esquema, las compuertas de entrada, olvido y salida controlan la evolución del estado interno de la celda (c_t) y del estado oculto (h_t), según lo definido por las ecuaciones 1 a 6. Estas operaciones no lineales permiten que el modelo retenga y actualice información relevante a lo largo del tiempo, sin necesidad de representar explícitamente los procesos físicos del sistema hidrológico.




Figura 2. Esquema funcional de una celda de memoria LSTM. Se representa el flujo de información a través de las compuertas de olvido (f_t), entrada (i_t) y salida (o_t), así como el cálculo del estado de la celda (c_t) y el estado oculto (h_t). Adaptado de Kratzert et al. (2018).

En este contexto, resulta necesario distinguir entre dos conceptos complementarios pero distintos: la memoria hidrológica de la cuenca y la memoria efectiva del modelo. La primera se refiere a una propiedad física del sistema hidrológico, determinada por factores como el régimen climático, la acumulación nival, el almacenamiento subterráneo y la topografía, que condicionan la influencia de las condiciones pasadas sobre los caudales actuales (Alvarez-Garretón et al., 2021; De Lavenne et al., 2022). Su duración varía considerablemente entre cuencas. Por otro lado, la memoria efectiva del modelo corresponde a la cantidad de información histórica que una red LSTM puede utilizar para mejorar sus predicciones. Se trata de una propiedad emergente de la arquitectura, que no refleja necesariamente la duración real de la memoria hidrológica de cada cuenca (Hashemi et al., 2022).

El modelo fue implementado utilizando la librería *NeuralHydrology*, una herramienta de código abierto desarrollada para investigación en aprendizaje profundo aplicado a hidrología (Kratzert et al., 2022). Se empleó la arquitectura *lstm*, optimizada para GPU, que implementa celdas LSTM adaptadas a la predicción hidrológica a partir de series temporales meteorológicas y atributos de cuenca. La configuración se definió mediante un proceso de búsqueda en malla (*grid search* con refinamiento), evaluando distintas combinaciones de hiperparámetros como la tasa de aprendizaje, tamaño de lote, número de unidades ocultas y longitud de secuencia, entre otros. En este estudio se utilizó una única capa LSTM, el optimizador Adam y una función de pérdida basada en el Nash-Sutcliffe Efficiency (NSE). El desempeño del modelo se evaluó mediante la métrica Kling-Gupta Efficiency (KGE), la cual se descompone en tres componentes: correlación de Pearson (r), razón de variabilidad (α) y razón de sesgo (β).

Uno de los hiperparámetros centrales derivados de la búsqueda en malla realizado fue la longitud de entrada (*sequence length*), establecida en 365 días. Esta decisión metodológica tiene como objetivo capturar influencias climáticas persistentes, como las

que ocurren en cuencas con procesos lentos o acumulativos, por ejemplo, en zonas áridas. Además, se respalda la elección de este valor porque representa un año hidrológico completo, lo que permite mantener consistencia entre las cuencas y facilitar comparaciones (Kratzert et al., 2018; Gauch et al., 2021).

Es importante destacar que esta longitud no corresponde a la duración real de la memoria hidrológica, sino a la cantidad de información pasada que el modelo es capaz de utilizar. En otras palabras, representa la memoria operativa del modelo. Aunque existen diferencias entre cuencas respecto a cuánto influye el pasado en los caudales actuales, actualmente no hay una metodología validada que permita ajustar este parámetro de forma óptima para cada cuenca en particular (De la Fuente, 2021; Hashemi et al., 2022).

Los resultados alcanzados con esta configuración, junto con los valores obtenidos para los hiperparámetros seleccionados y el análisis de su desempeño predictivo, se presentan en la **Sección 4.1**.

3.5. Análisis de sensibilidad

El análisis de sensibilidad (AS) en modelos hidrológicos basados en aprendizaje automático busca evaluar cómo cambian las predicciones del modelo al modificar sus variables de entrada. Esta herramienta es especialmente útil para interpretar modelos complejos tipo caja negra, como las redes LSTM (Pianosi et al., 2016; Jiang et al., 2022). En este estudio, el AS se aplica para analizar la respuesta del modelo ante eventos extremos, mediante la perturbación sistemática de variables de entrada relevantes desde el punto de vista hidrológico.

3.5.1. Fundamento y aplicación del análisis de sensibilidad

El análisis de sensibilidad, entendido como la evaluación del cambio en la salida de un modelo ante variaciones controladas en sus entradas, se puede expresar matemáticamente como la derivada parcial de una función respuesta Z respecto a sus entradas o parámetros Q (Gupta & Razavi, 2017):

$$\frac{\partial Z}{\partial Q} = \left\{ \frac{\partial Z}{\partial q_1}, \frac{\partial Z}{\partial q_2}, \dots, \frac{\partial Z}{\partial q_p} \right\} \quad (7)$$

Esta formulación describe una sensibilidad local, ya que evalúa el cambio en la salida del modelo en un punto específico del espacio de entrada, manteniendo las demás variables constantes. En el caso de modelos LSTM aplicados a hidrología, este enfoque permite examinar si el modelo ha aprendido relaciones coherentes con la física hidrológica entre las variables forzantes y el caudal simulado (Jiang et al., 2022).

La Figura 3 ilustra gráficamente el principio del método OAT (One-At-a-Time). En el esquema bidimensional (izquierda), el punto rojo representa el valor nominal del sistema, mientras que los puntos verdes indican perturbaciones aplicadas una a una sobre cada variable. En la representación tridimensional (derecha), este concepto se extiende a un espacio de entradas con mayor dimensionalidad, como el que se trabaja en redes neuronales profundas. Esta visualización permite comprender cómo las perturbaciones univariadas recorren el espacio de entrada en distintas direcciones, y cómo se espera que el modelo reaccione ante estos cambios controlados.




Figura 3. Representación esquemática del método OAT en sistemas bidimensionales y tridimensionales. El punto rojo representa el valor nominal del parámetro, y las perturbaciones se muestran como puntos distribuidos a lo largo de los ejes correspondientes. Adaptado de HWRS 428/528, 2019 en Gupta y Razavi (2017).

Dentro de los enfoques posibles, los métodos de sensibilidad se clasifican en **locales** y **globales**. Los métodos locales, como **One-At-a-Time (OAT)**, perturban una variable a la vez, lo que permite atribuir directamente los cambios en la salida a la entrada modificada. En cambio, los métodos globales, como Sobol o Morris, exploran el espacio completo de entradas y consideran interacciones, pero requieren cientos o miles de simulaciones, lo que los hace poco viables en estudios exploratorios o con recursos computacionales acotados (Gupta & Razavi, 2017).

En este trabajo se utilizó una versión extendida del método OAT, complementada con combinaciones binarias entre variables implementadas mediante un script desarrollado en Python específicamente para este estudio, siguiendo el enfoque descrito en estudios previos (Martel et al., 2024; Jiang et al., 2022). Se aplicaron perturbaciones independientes sobre la precipitación, la temperatura y la cobertura forestal, y además se consideraron combinaciones de dos variables a la vez para capturar posibles efectos sinérgicos o compensatorios. En el caso de precipitación y temperatura, se analizaron cuatro escenarios: aumento simultáneo de ambas (+/+), aumento de precipitación y disminución de temperatura (+/-), disminución simultánea (-/-), y combinación inversa (-/+). Para las combinaciones entre precipitación y cobertura forestal, se incluyeron escenarios sincronizados (+/+ y -/-) y opuestos (+/- y -/+). Este diseño permite representar situaciones realistas desde el punto de vista físico, como el ascenso de la isoterma 0 °C que convierte nieve en lluvia, o la amortiguación de caudales extremos debido a la presencia de cobertura vegetal.

Las perturbaciones aplicadas fueron coherentes con las escalas propias de cada variable. La precipitación se modificó en términos relativos ($\pm 5\%$, $\pm 10\%$, $\pm 20\%$), mientras que la temperatura se ajustó mediante incrementos absolutos de $\pm 1\text{ }^{\circ}\text{C}$, $\pm 2\text{ }^{\circ}\text{C}$ y $\pm 4\text{ }^{\circ}\text{C}$, es decir, aumentos o disminuciones fijas expresadas directamente en grados Celsius, sin depender del valor original. En el caso de la cobertura forestal, se aplicó un único cambio de $\pm 5\%$, valor considerado conservador por mantenerse dentro del rango observado durante el entrenamiento del modelo, evitar extrapolaciones fuera del espacio de aprendizaje y representar escenarios razonables de deforestación o reforestación a escala local.

Estos rangos fueron definidos considerando estudios previos en hidrología de montaña y proyecciones recientes de cambio climático para Chile. En el caso de la precipitación, las variaciones utilizadas coinciden con las exploradas por Martel et al. (2024) y Patterson et al. (2022), quienes analizaron escenarios de déficit y exceso hídrico en cuencas de montaña o clima mediterráneo. Para la temperatura, los valores seleccionados se alinean con los escenarios de calentamiento global proyectados para Chile durante el siglo XXI. Según la Dirección Meteorológica de Chile (2024), el año 2023 registró una temperatura media nacional de 13,5 °C, lo que representa un alza de +1,09 °C respecto del promedio histórico, además de un aumento sostenido en la frecuencia de eventos cálidos. Esto respalda el uso de rangos superiores a +2 °C como parte del análisis de sensibilidad. En el caso de la cobertura forestal, al tratarse de una variable estática, el rango de $\pm 5\%$ se define como un cambio realista y moderado, consistente con estudios recientes sobre el rol de la vegetación en la regulación del caudal (Li et al., 2024; Hall et al., 2024). Finalmente, la implementación de combinaciones binarias entre variables sigue un enfoque ya probado en estudios como los de Martel et al. (2024) y Jiang et al. (2022), permitiendo explorar efectos compuestos que no podrían detectarse mediante análisis univariados.

Para facilitar la comparación entre cuencas, se emplea como métrica la elasticidad hidrológica, definida como:

$$\varepsilon = \frac{\Delta Q/Q}{\Delta X/X} \quad (8)$$

donde $\Delta Q/Q$ representa el cambio relativo en el caudal máximo, y $\Delta X/X$ el cambio relativo en la variable de entrada. Esta métrica ha sido utilizada en estudios previos como una herramienta para entender la respuesta de sistemas hidrológicos ante forzantes climáticas (Rasouli et al., 2014, 2015; Chandel & Ghosh, 2021), y se adapta bien a contextos de análisis exploratorio con modelos complejos.

Una vez calculadas las elasticidades evento por evento, se organizó la información por cuenca y tipo de perturbación realizada. En el caso de la precipitación, se promedió la elasticidad resultante de los seis escenarios (+5 %, −5 %, +10 %, −10 %, +20 %, −20 %), excluyendo aquellos eventos en que la precipitación fue nula. Para la temperatura, se utilizaron los seis casos simétricos (± 1 °C, ± 2 °C, ± 4 °C). Para la cobertura forestal, se consideraron únicamente los dos escenarios de $\pm 5\%$. En todos los casos, los resultados se presentaron mediante gráficos tipo boxplot, utilizando la mediana y el rango intercuartílico como estadísticas de resumen, con el fin de representar tanto la dirección como la dispersión de las respuestas obtenidas.

Además de las perturbaciones individuales, se construyeron gráficos que resumen el efecto de las combinaciones de variables. En cada caso, primero se promediaron las elasticidades obtenidas por evento a partir de las combinaciones definidas, y luego se calculó la mediana y el rango intercuartílico de esos promedios para cada cuenca. Para el caso de precipitación y temperatura, se consideraron tres combinaciones por escenario: (+5 % / +1 °C, +10 % / +2 °C, +20 % / +4 °C) para el escenario (+/+) y (+5 % / −1 °C, +10 % / −2 °C, +20 % / −4 °C) para el escenario (+/−). En el caso de la cobertura forestal, se trabajó con una precipitación fija de +5 % y se analizaron escenarios sincronizados (prcp+5 % con lc_forest+5 %, y prcp−5 % con lc_forest−5 %) y opuestos (prcp+5 % con

lc_forest-5 %, y prcp-5 % con lc_forest+5 %). En estos últimos, los valores negativos fueron multiplicados por -1 antes de calcular el promedio, de modo que ambos escenarios aportaran en la misma dirección de interpretación.

Estos análisis permiten interpretar la magnitud y el sentido de la respuesta del modelo LSTM ante perturbaciones controladas. Una elasticidad mayor a uno indica una respuesta amplificada (elástica), mientras que valores menores a uno reflejan una respuesta amortiguada (inelástica). Una elasticidad negativa implica una relación inversa, como ocurre cuando la cobertura forestal reduce la magnitud del caudal máximo. Esta clasificación permite identificar cuencas más o menos sensibles frente a distintos tipos de cambio forzado, lo que aporta evidencia útil para evaluar su vulnerabilidad y capacidad de regulación hidrológica.

Finalmente, se incorporaron ajustes complementarios para mantener la coherencia interna del sistema. Al aumentar la precipitación, el índice de aridez fue ajustado dividiéndolo por el mismo factor relativo. En el caso de la temperatura, su aumento está asociado a un incremento en la evapotranspiración potencial (PET), lo cual también afecta el índice de aridez según su formulación clásica:

$$Aridez = \frac{PET}{Precipitación} \quad (9)$$

En el dataset CAMELS-CL, la PET fue estimada utilizando la fórmula de Hargreaves y Samani (1985), que se basa en la temperatura media diaria, la amplitud térmica diaria y la radiación extraterrestre. Esta dependencia refuerza la necesidad de considerar efectos indirectos al aplicar perturbaciones térmicas, ya que la PET no es una variable independiente, sino una función climática derivada que interviene directamente en otros índices hidrológicos relevantes.

En conjunto, el diseño adoptado busca equilibrar realismo físico, claridad interpretativa y viabilidad computacional. Si bien no se capturan todas las posibles interacciones entre variables, esta aproximación permite obtener un primer panorama estructurado y reproducible sobre cómo responde el modelo LSTM a cambios específicos en sus entradas. Los resultados obtenidos se presentan y analizan en la **sección 4**.

3.5.2. Índices de elasticidad utilizados

A fin de comparar de manera consistente la respuesta del modelo LSTM ante perturbaciones en sus entradas, se emplearon índices de elasticidad (cambios relativos) en lugar de sensibilidades (cambios absolutos). Como discuten Saltelli et al. (2004), cuando las variables poseen unidades y escalas distintas (mm de precipitación, °C de temperatura o % de cobertura forestal), es preferible utilizar métricas adimensionales que permitan comparar el efecto de cada variable en una misma escala. Además, su formulación es coherente con el enfoque local tipo One-At-a-Time (OAT), pues mide el efecto de modificar una entrada manteniendo constantes las demás, lo que resulta útil para estudios exploratorios y de priorización de factores (Saltelli et al., 2004). En lo que sigue, todos los caudales corresponden a simulaciones del modelo; se denota Q_{base} al caudal del escenario sin perturbaciones y $Q_{ajustado,X}$ al caudal cuando la variable $X \in \{P, T, B\}$ es perturbada.

En términos formales, para cada variable X la elasticidad se define como la razón entre el cambio relativo del caudal y el cambio relativo de dicha entrada,

$$E_X = \frac{\% \Delta Q}{\% \Delta X}, \quad (10a)$$

donde el cambio relativo del caudal se evalúa como

$$\% \Delta Q = \frac{Q_{ajustado,X} - Q_{base}}{Q_{base}}, \quad (10b)$$

Aplicando (10a)–(10b) a cada forzante se obtienen las expresiones implementadas en el estudio:

$$E_P = \frac{\frac{Q_{ajustado,P} - Q_{base}}{Q_{base}}}{\Delta P / P}, \quad (10)$$

$$E_T = \frac{\frac{Q_{ajustado,T} - Q_{base}}{Q_{base}}}{\Delta T / T}, \quad (11)$$

$$E_B = \frac{\frac{Q_{ajustado,B} - Q_{base}}{Q_{base}}}{\Delta B / B} = \frac{Q_{ajustado,B} - Q_{base}}{Q_{base} \cdot 0.05}, \quad (12)$$

considerando $\Delta B / B = 0.05$ ($\pm 5\%$) como perturbación fija por cuenca.

Para evaluar interacciones entre variables, se define una elasticidad combinada que compara el cambio relativo del caudal cuando dos entradas varían simultáneamente con un promedio ponderado de sus cambios relativos:

$$E_{X,Y} = \frac{\% \Delta Q_{X,Y}}{(w_X \cdot \% \Delta X + w_Y \cdot \% \Delta Y)} \quad (13a)$$

con pesos derivados de las elasticidades individuales,

$$w_X = \frac{|E_X|}{|E_X| + |E_Y|}, \quad w_Y = \frac{|E_Y|}{|E_X| + |E_Y|} \quad (13b)$$

donde $|\cdot|$ denota valor absoluto para evitar cancelaciones por signo. La implementación concreta para los pares analizados fue

$$E_{P,T} = \frac{\frac{(Q_{ajustado,P,T} - Q_{base})}{Q_{base}}}{w_P \cdot (\Delta P / P) + w_T \cdot (\Delta T / T)} \quad (13)$$

$$E_{P,B} = \frac{\frac{(Q_{ajustado,P,B} - Q_{base})}{Q_{base}}}{w_P \cdot (\Delta P / P) + w_B \cdot 0.05} \quad (14)$$

Estas métricas combinadas permiten detectar si los efectos conjuntos son sinérgicos (se potencian), compensatorios (se atenúan) o evidencian respuestas no lineales. En términos operativos, $E > 1$ indica que el caudal cambia, en porcentaje, más que la(s) entrada(s) considerada(s); por ejemplo, $E = 2$ sugiere $\sim 2\%$ de cambio en Q ante 1% de cambio en la(s) entrada(s).

- Q_{base} : caudal simulado en el escenario base (sin perturbación).
- $Q_{ajustado,X}$: caudal simulado con la variable $X \in \{P, T, B\}$ perturbada; $Q_{ajustado_{P,T}}$ y $Q_{ajustado_{P,B}}$ para perturbaciones combinadas.
- $\% \Delta Q$: cambio relativo de caudal.
- $\Delta P/P \in \{0.05, 0.10, 0.20\}$; $\Delta B/B = 0.05$
- $\Delta T/T$: Es un valor escalar utilizado para obtener la variación porcentual de T , calculado con base en los rangos de modificación térmica utilizados (± 1 °C, ± 2 °C, ± 4 °C).
- E_P, E_T, E_B : elasticidades individuales; $E_{P,T}, E_{P,B}$: elasticidades combinadas.
- w_X, w_Y : pesos relativos derivados de las elasticidades individuales $|E_X|$.

Por último, para garantizar consistencia entre todas las cuencas y tipos de perturbación, se adoptó un criterio unificado para reportar resultados: se utilizan la mediana (Q2) y el rango intercuartílico (Q1–Q3) como estadísticas de resumen, donde Q1 corresponde al primer cuartil (percentil 25) y Q3 al tercer cuartil (percentil 75; IQR=Q3-Q1). Esta elección permite describir adecuadamente la distribución central de las respuestas, sin que los valores extremos distorsionen el análisis. El uso de la mediana facilita comparar el comportamiento típico del modelo en cada cuenca, mientras que el rango intercuartílico permite evaluar la dispersión de las respuestas sin necesidad de asumir simetría o normalidad.

3.5.3. Criterios de selección de cuencas

Para asegurar que el análisis de sensibilidad entregara resultados interpretables y comparables, se definieron criterios claros para la selección de las cuencas. El primer criterio fue que el modelo alcanzara un valor de Kling-Gupta Efficiency (KGE; Gupta et al., 2009) igual o superior a 0,6 durante el periodo de validación. Esta métrica combina correlación, sesgo y variabilidad, y se utiliza para evaluar la concordancia entre los caudales simulados y observados. Establecer un umbral mínimo de desempeño ha sido recomendado en otros estudios, ya que permite centrar el análisis en resultados confiables y no en variaciones atribuibles al azar (Addor et al., 2018).

El segundo criterio fue que cada cuenca registrara al menos ocho eventos extremos, definidos como caudales asociados a un periodo de retorno de 10 años (TR = 10 años). Este umbral garantiza que exista suficiente información para evaluar la respuesta del modelo en condiciones de caudales elevados. Al seleccionar únicamente cuencas con este tipo de eventos, se evita incluir casos donde los datos no representen adecuadamente este comportamiento hidrológico (Frame et al., 2022).

La aplicación conjunta de ambos criterios—desempeño del modelo y presencia de eventos extremos—permite seleccionar un subconjunto de cuencas donde el modelo LSTM muestra capacidad de generalización, y que además presentan las condiciones hidrológicas relevantes para el análisis. La lista de cuencas seleccionadas y sus respectivos valores se presenta en los anexos de este documento (**Tabla A.6**).

Finalmente, con el fin de interpretar los resultados del análisis de sensibilidad desde una perspectiva física coherente, se realizó una clasificación hidrológica de las cuencas

seleccionadas. Esta clasificación se basa en indicadores como la fracción de nieve, la estacionalidad de la precipitación, la altitud media y el mes del caudal máximo, siguiendo el enfoque de Báez-Villanueva et al. (2023) y complementado con cálculos propios cuando fue necesario. Este paso metodológico permite agrupar las cuencas según su régimen dominante —pluvial, nival o mixto—, lo cual será clave para analizar si su respuesta ante perturbaciones se relaciona con su comportamiento hidrológico base.

3.4. Evaluación del Desempeño

Para evaluar qué tan bien el modelo reproduce los caudales observados, se utilizó la métrica Kling–Gupta Efficiency (KGE), propuesta como una alternativa al tradicional coeficiente de eficiencia de Nash–Sutcliffe (NSE). La KGE busca superar algunas limitaciones del NSE, especialmente su sensibilidad al sesgo y su tendencia a subestimar la variabilidad del caudal en ciertos casos (Gupta et al., 2009). A diferencia del NSE, cuya interpretación puede ser ambigua al combinar distintos tipos de error en una única cifra, la KGE descompone el error total en tres componentes: correlación lineal (r), sesgo medio (β) y dispersión relativa (α).

La fórmula general de la KGE se expresa como:

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (12)$$

donde:

- r : coeficiente de correlación de Pearson entre los caudales observados y simulados, que captura la sincronía entre ambos.
- $\alpha = \frac{\sigma_s}{\sigma_o}$: Representa la relación entre las desviaciones estándar de las predicciones (σ_s) y las observaciones (σ_o), evaluando la similitud en la variabilidad.
- $\beta = \frac{\mu_s}{\mu_o}$: razón entre los valores medios simulados (μ_s) y los observados (μ_o), que representa el sesgo sistemático del modelo.

Un valor de KGE igual a 1 indica un ajuste perfecto, es decir, que el modelo reproduce bien la forma, la variabilidad y la magnitud del caudal observado. Esto hace que la KGE sea una herramienta útil para interpretar el rendimiento del modelo de forma más detallada, ya que permite analizar por separado aspectos como la correlación, la variabilidad y el sesgo, lo cual es clave para identificar en qué parte específica el modelo puede estar fallando.

4 Resultados y discusión

4.1 Desempeño general del modelo LSTM

Esta sección muestra cómo se comportó el modelo LSTM al intentar predecir el caudal máximo diario en las cuencas seleccionadas. Primero, se presenta una mirada general a los resultados obtenidos en todas las cuencas (Sección 4.1.1). Luego, se compara su desempeño en distintos tipos de climas, desde zonas húmedas del sur hasta regiones áridas del norte (Sección 4.1.2). Por último, se analiza con mayor detalle el caso del río Lircay (Sección 4.1.3), una cuenca que llamó la atención por presentar un cambio brusco en su comportamiento durante el periodo de testeo. La idea de esta sección no es solo mostrar cifras, sino también entender por qué el modelo funciona mejor en algunos contextos que en otros.

4.1.1. Evaluación cuantitativa general

La Figura 4 presenta las funciones de distribución acumulada (CDF) de las métricas de desempeño del modelo LSTM durante el periodo de testeo. En cada gráfico, la abscisa corresponde al valor de la métrica (KGE, r , α y β) y la ordenada al porcentaje acumulado

de cuencas que alcanza o supera dicho valor. Además, la leyenda incluye la mediana y el rango intercuartílico (Q1–Q3), mientras que las líneas verticales segmentadas marcan la posición de la mediana en cada distribución, lo que facilita la interpretación visual de la tendencia central y la dispersión entre cuencas.

En el panel izquierdo, correspondiente al KGE, se observa una mediana de 0.555 [0.448 – 0.774], inferior a la obtenida en el periodo de validación (0.643 [0.584 – 0.732]). En este caso, 8 de las 13 cuencas ($\approx 62\%$) alcanzaron valores iguales o superiores a 0.5, lo que evidencia un ajuste global aceptable del modelo en gran parte de los casos. Si bien este valor puede considerarse moderado, estudios comparativos recientes han demostrado que métricas de este orden no son inusuales en cuencas de alta complejidad hidroclicmática. Por ejemplo, Frame et al. (2021, 2022) reportaron que LSTM logra desempeños similares o superiores a modelos físico-conceptuales como SAC-SMA o VIC, incluso cuando estos últimos se calibran cuidadosamente. De hecho, en cuencas áridas o nivales, los valores de NSE/KGE rara vez superan 0.6 (Nauditt et al., 2017; Parra et al., 2019), lo que sitúa nuestros resultados dentro de lo esperado para este tipo de contextos.

El panel central muestra la distribución del coeficiente de correlación de Pearson (r), asociado a la sincronía temporal entre los caudales observados y simulados. La mediana alcanzó 0.716 [0.557 – 0.822], lo que indica que el modelo logra capturar parcialmente los patrones temporales. Si bien existen casos con menor ajuste, la mayoría de las cuencas se ubica por sobre 0.55, lo que evidencia una capacidad aceptable de representación temporal en el conjunto global.

El panel derecho presenta los componentes de la métrica KGE: α (relación entre desviaciones estándar) y β (relación entre promedios), ambos en escala logarítmica. Para el periodo de testing, se obtuvo una mediana de α igual a 0.902 [0.829 – 1.094], lo que sugiere que el modelo logró reproducir de forma razonable la variabilidad del caudal máximo diario. En contraste, los valores de β muestran mayor dispersión, con una mediana de 0.999 [0.942 – 1.299]. Aunque en la mayoría de las cuencas el sesgo de volumen se mantuvo cercano a 1, en algunos casos se superaron valores de 1.5, reflejando una sobreestimación importante del volumen acumulado. Este sesgo puede estar asociado a que el modelo fue entrenado en un periodo relativamente más húmedo, lo que genera dificultades para ajustarse a escenarios más secos. Resultados similares han sido descritos en estudios internacionales, donde tanto LSTM como modelos físico-conceptuales presentan degradación en escenarios más secos o extremos, con sobreestimación de volúmenes y reducción en la eficiencia (Frame et al., 2022). Esta heterogeneidad en el desempeño del modelo será analizado con mayor detalle en la siguiente sección, al comparar el desempeño del modelo en contextos hidroclicmáticos contrastantes.

No obstante, estos resultados deben interpretarse considerando una limitación metodológica clave: todas las variables de entrada, incluida la precipitación diaria —que constituye el predictor más relevante para la estimación de caudales—, fueron procesadas a resolución diaria, mientras que la variable objetivo corresponde específicamente al caudal máximo diario. Esta diferencia es fundamental, pues los máximos suelen concentrarse en ventanas horarias mucho más cortas, lo que implica que la agregación diaria puede suavizar los picos de escorrentía y reducir la capacidad del modelo para capturar con precisión la magnitud real de los eventos extremos (Baste et al., 2025). En consecuencia, el modelo tiende a reproducir patrones generales del régimen de caudal,

pero muestra discrepancias importantes durante crecidas intensas, dado que los picos están subrepresentados en la serie de entrada. La resolución diaria no solo atenúa los máximos, sino que también podría explicar la sobreestimación del volumen acumulado ($\beta > 1.5$) y la baja sincronía temporal de los eventos. Aunque el modelo logró representar de manera aceptable la variabilidad general ($\alpha \approx 0.9$), su desempeño quedó condicionado por esta limitación estructural. De cara a futuras investigaciones, una alternativa es utilizar datos subdiarios recientes, lo que permitiría una mejor representación de los caudales máximos y su coherencia con los forzantes meteorológicos que los originan (Frame et al., 2022; Zhang et al., 2024; Baste et al., 2025; Gauch et al., 2021; Acuña Espinoza et al., 2025).

En síntesis, aunque el desempeño global del LSTM pueda considerarse moderado en comparación con métricas ideales, se encuentra dentro de lo reportado tanto en Chile como en estudios internacionales con modelos físico-conceptuales y LSTM. Lo más relevante es que, más allá de las métricas, el enfoque propuesto permite avanzar en la interpretación del modelo y en la comprensión de su respuesta en contextos hidroclimáticos contrastantes, aportando un valor adicional frente a metodologías tradicionales.




Figura 4. 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: α y β en escala logarítmica (variabilidad y volumen de escorrentía). En cada gráfico, la leyenda muestra la mediana del desempeño acompañada de su rango intercuartílico (Q1–Q3), lo que resume la tendencia central y la variabilidad típica entre cuencas. Las líneas verticales segmentadas marcan la posición de la mediana dentro de la distribución acumulada, facilitando la comparación visual entre métricas.

4.1.2. Desempeño del modelo en contextos hidroclimáticos contrastantes

Para complementar los resultados generales mostrados anteriormente, esta sección presenta dos ejemplos concretos que ayudan a visualizar cómo varía el desempeño del modelo según el tipo de cuenca. Se eligieron dos casos con condiciones muy distintas: una cuenca del sur húmedo y otra del norte árido, ambas durante el periodo de testeo.

La Figura 5 muestra los resultados obtenidos para el Río Ibáñez, una cuenca con régimen nivo-pluvial ubicada en la Patagonia norte. Esta zona recibe una cantidad importante de precipitaciones a lo largo del año y también presenta acumulación de nieve en invierno. En este caso, el modelo logró ajustarse bien a los datos observados, tanto en la forma

como en la magnitud de los eventos, con una mediana de KGE de 0.85, lo que indica un desempeño muy alto.

En contraste, la Figura 6 muestra lo ocurrido en la cuenca del **Río Huasco**, ubicada en una región árida del norte. Aquí el modelo presentó grandes dificultades para representar adecuadamente los caudales, alcanzando una mediana de KGE de -0.94 . Esta diferencia refleja lo complejo que resulta modelar zonas con baja disponibilidad hídrica, alta variabilidad y escasa información climática.




Figura 5. 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 6. Ajuste entre caudales observados y simulados por el modelo LSTM en la cuenca del Río Huasco (período de testeo), representativa de una región árida.

Este contraste es coherente con lo reportado en la literatura internacional: los modelos, ya sean físico-conceptuales o de ML, tienden a degradar su desempeño en regiones áridas o de montaña debido a la escasez y calidad de los datos meteorológicos disponibles (Clark et al., 2015; Nauditt et al., 2017). En el caso de Chile, De la Fuente et al. (2023) encontraron que el desempeño del LSTM para caudales medios diarios fue mayor en zonas del centro-sur ($KGE \approx 0.70$) y disminuyó significativamente en el norte, con valores negativos en cuencas áridas. Este mismo patrón se observó en el presente estudio (con caudales máximos diarios), donde las cuencas ubicadas al norte de la latitud 32° S mostraron valores por debajo de 0.45, destacando Huasco y Elqui con desempeños negativos.

Una de las razones más relevantes que explica esta baja precisión en cuencas áridas es la falta de buenos datos de entrada. Los registros meteorológicos en estas zonas suelen ser escasos o tener baja resolución espacial y temporal. Además, los productos satelitales tienden a subestimar las lluvias en climas secos, lo que introduce errores desde el comienzo (Zambrano-Bigiarini et al., 2017, De la Fuente, 2021). También existen vacíos en variables importantes del conjunto de datos, como la profundidad del suelo o su capacidad de almacenamiento, que son clave para simular caudales en condiciones áridas (De la Fuente et al., 2023).

Aunque las redes LSTM tienen la capacidad de capturar patrones complejos, su desempeño depende directamente de la información que reciben. Como mencionan De la Fuente (2021) y De la Fuente et al. (2023), estos modelos no pueden aprender relaciones que no están presentes en los datos. Por eso, la falta de información o su baja calidad puede limitar fuertemente los resultados. Además, el concepto de memoria hidrológica de las cuencas, asociada a procesos de almacenamiento y persistencia de largo plazo (dinámica tipo Hurst–Kolmogorov), no siempre se refleja plenamente en la memoria efectiva impuesta al LSTM (ventanas de 365 días en este estudio). Ajustar la duración de la memoria por cuenca podría mejorar resultados en contextos áridos, aunque con el riesgo de sobreajuste (Hashemi et al., 2022; Gauch et al., 2021).

En resumen, estos dos ejemplos muestran con claridad cómo el desempeño del modelo está estrechamente ligado a las características hidroclimáticas de cada cuenca. Mientras en zonas húmedas, como **Ibáñez**, el modelo logra ajustarse bien, en regiones áridas, como **Huasco**, su rendimiento disminuye. Esto refuerza la necesidad de seguir investigando en tres líneas principales: (i) adaptar la duración de la memoria del modelo según el comportamiento hidrológico de cada cuenca, (ii) mejorar la calidad de los datos climáticos en regiones con menor cobertura, y (iii) explorar nuevos enfoques que permitan representar mejor distintas escalas temporales sin aumentar excesivamente la complejidad del modelo.

4.1.3. Caso especial: cuenca del río Lircay

Dentro del grupo de cuencas estudiadas, el caso del **río Lircay** llama especialmente la atención por el fuerte cambio en el desempeño del modelo entre la etapa de validación y la etapa de testeo. Mientras que en la validación el modelo tuvo un desempeño aceptable ($KGE = 0.64$), en el periodo de testeo este valor cayó bruscamente a 0.18. Esta diferencia no solo es importante por lo grande del cambio, sino también porque el **Lircay** fue una de las seis cuencas seleccionadas para el análisis de sensibilidad. Por lo tanto, entender qué pasó es clave para interpretar bien los resultados.

Al revisar los datos, se encontró un tramo muy extraño entre septiembre de 2011 y agosto de 2012, donde el caudal fue anormalmente alto, incluso en pleno verano. Durante esos meses, los caudales llegaron a valores cercanos a 50 m³/s, lo que no es común para esta cuenca. Por ejemplo, en enero de 2012 el caudal promedio superó los 61 m³/s, cuando lo habitual es que no pase de 8 m³/s. Para verificar esto, se compararon los caudales mensuales de ese tramo con los valores históricos anteriores al año 2011.

Tal como se muestra en la Figura 7, durante los meses de verano del periodo anómalo los caudales fueron hasta diez veces mayores que lo que normalmente ocurre. Esto sugiere que hubo algún cambio importante en la cuenca, pero también podría deberse a un posible error en los datos. Por eso, antes de sacar conclusiones, se consideraron varias posibilidades para explicar este comportamiento tan inusual.

En primer lugar, se revisó si existían antecedentes de obras humanas que pudieran haber influido en el caudal, como embalses, canales o desvíos. Sin embargo, no se encontró nada que estuviera funcionando en ese periodo. El embalse proyectado para esa zona todavía estaba en evaluación en 2014, y no se encontraron registros de trasvases ni de operaciones especiales (DGA, 2016).

Ante la falta de intervenciones conocidas, se evaluó otra posibilidad: que el aumento del caudal estuviera relacionado con los efectos del terremoto del 27F (2010). Algunos estudios, como el de Mohr et al. (2012), mostraron que, en varias cuencas entre Concepción y Los Ángeles, los caudales aumentaron después del sismo, debido a un posible ascenso del nivel freático por el reajuste de sedimentos en el subsuelo. Otros trabajos, como los de Pritchard et al. (2013) y LeFevre (2014), informaron que volcanes cercanos al Lircay —como Calabozos y Cerro Azul— sufrieron hundimientos después del terremoto, lo que podría haber liberado agua subterránea acumulada. Como el Lircay está en una zona montañosa de origen volcánico y dentro del área más afectada por el sismo, es razonable pensar que algo similar pudo haber pasado, aunque no se puede afirmar con certeza.

Desde el punto de vista del modelo, evaluar su desempeño usando este tramo anómalo puede ser injusto. Aunque el modelo no se entrenó con esos datos, se le pide que reproduzca un comportamiento totalmente fuera de lo común, que no aparece en el resto del historial. Si el fenómeno no forma parte del patrón normal de la cuenca y no tiene registros similares en otros años, no se puede esperar que el modelo lo prediga bien.

Por eso, se decidió excluir el tramo entre septiembre de 2011 y agosto de 2012 del análisis. Al hacer esto, el desempeño del modelo mejoró: el KGE subió de 0.18 a 0.46, y también mejoraron otros indicadores como β (relacionado con el volumen, de 0.43 a 0.73) y α (relacionado con la variabilidad, de 0.52 a 0.63). En las demás cuencas, el desempeño se mantuvo casi igual. La única diferencia fue un pequeño aumento en el coeficiente de correlación (Pearson-r), cuya mediana subió de 0.659 a 0.716, lo que se debe principalmente al recorte aplicado en Lircay.

En resumen, el bajo resultado que tuvo el modelo en esta cuenca parece estar asociado a un fenómeno excepcional que no se repitió en otros años. Aunque no se puede descartar que se trate de un error de medición, se optó por tratar este tramo como un caso especial y eliminarlo del análisis. Esta decisión fue tomada de forma explícita y cuidadosa, para evitar que un evento tan raro distorsione el análisis general.




Figura 7. Comparación entre el caudal máximo medio mensual del río Lircay en su periodo histórico (hasta marzo de 2011) y durante el tramo anómalo (septiembre 2011 – agosto 2012). Se observa un aumento sostenido y fuera de temporada, especialmente en verano, lo que confirma un comportamiento inusual respecto al régimen estacional típico.

4.2. Análisis de sensibilidad ante perturbaciones

4.2.1. Clasificación hidrológica de las cuencas para análisis de sensibilidad

Esta sección presenta los resultados del análisis de sensibilidad aplicado al modelo LSTM entrenado, con el objetivo de evaluar cómo reacciona ante escenarios de cambio climático o alteraciones en el uso del suelo. Las perturbaciones aplicadas consideraron cambios controlados en tres variables que influyen directamente en la generación de escorrentía: **precipitación, temperatura y cobertura forestal**. Estas variables fueron seleccionadas por su rol hidrológico directo y por la claridad con la que pueden interpretarse sus efectos en el caudal máximo diario.

Para interpretar mejor las respuestas obtenidas, se organizó a las cuencas en grupos con características similares, siguiendo una clasificación hidrológica estructural basada en variables climáticas y topográficas. Esta agrupación permitió observar si ciertos tipos de cuencas (por ejemplo, aquellas dominadas por nieve versus lluvia) tienden a responder de forma distinta ante las mismas perturbaciones.

El esquema de clasificación se basó en el enfoque de Báez-Villanueva et al. (2023), que define regímenes hidrológicos para un conjunto de cuencas chilenas usando datos como la fracción de nieve, la estacionalidad de la lluvia, la altitud media y el mes del año en que ocurre el mayor caudal.

Como algunas cuencas analizadas no estaban incluidas en ese estudio (como el Río Ñuble en La Punilla y el Río Ibáñez en Desembocadura), se hizo una clasificación complementaria basada en su ubicación y un análisis propio de indicadores como el índice

de nivalidad, la fracción de nieve, la altitud y la estacionalidad. El Río Ibáñez, por ejemplo, se clasificó como nivo-pluvial porque está entre cuencas con ese tipo de régimen y tiene una fracción de nieve alta. El Río Ñuble fue clasificado como pluvio-nival, en línea con otras cuencas vecinas como el Río Chillán o el Río Sauces.

La Tabla 4 muestra esta clasificación, que fue clave para interpretar los resultados del análisis de sensibilidad. La columna “Índice de Nivalidad” (sin unidad) se calculó como la relación entre el caudal promedio durante los meses de deshielo (de octubre a enero) y el caudal promedio anual. La idea detrás de este índice es simple: ver qué tan importante es el deshielo en la generación del caudal. En muchas cuencas de montaña en Chile, sobre todo en la zona central y sur, la nieve acumulada en invierno se empieza a derretir en primavera, y eso se refleja claramente en los caudales. Por eso, se eligieron esos meses como una buena aproximación del periodo de fusión nival. Sabemos que esto puede variar un poco según la latitud o la altitud —en algunos casos el deshielo puede empezar antes o durar más—, pero en general, esta ventana entre octubre y enero permite capturar bien el pulso del deshielo en la mayoría de las cuencas andinas. Además, este enfoque está en línea con clasificaciones previas hechas para las cuencas chilenas (como las de Báez-Villanueva et al., 2020). La “Fracción de Nieve” es una variable del dataset CAMELS-CL (frac_snow_cr2met_1979_2010), también sin unidad, y representa el porcentaje promedio de cobertura nival. La “Estacionalidad de la Precipitación” viene del mismo dataset (p_seasonality_cr2met_1979_2010) y describe cómo se distribuye la lluvia a lo largo del año.

Tabla 4. Clasificación revisada de las cuencas analizadas para el Análisis de Sensibilidad (AS) (Basado en fracción de nieve, estacionalidad, altitud, mes de peak de caudal y validado con clasificación de Báez-Villanueva et al., 2023)

Nombre de la Cuenca	Mes Máx Caudal	Índice Nivalidad	Fracción de nieve	Elevación máxima	Estacional. de la Precip.	Clasificación de la cuenca
Río Lircay En Puente Las Rastras	6	0.42	0.00	2441	-1.1	Pluvio-nival
Río Ñuble En La Punilla	7	0.34	0.19	3189	-1.0	Pluvio-nival
Río Cautín En Rari-Ruca	7	0.77	0.03	3090	-0.8	Pluvio-nival
Río Liquiñe En Liquiñe	6	0.86	0.04	2319	-0.7	Pluvio-nival
Río Ibáñez En Desembocadura	12	1.12	0.16	2593	-0.2	Nivo-Pluvial
Río Las Chinas En Cerro Guido	2	0.75	0.10	1627	0.3	Nivo-Pluvial

Esta clasificación sirvió como marco para interpretar los resultados del análisis de sensibilidad. Por ejemplo, se espera que las cuencas con mayor componente nival tuvieran una respuesta más marcada ante los cambios en temperatura, debido a su influencia sobre el derretimiento de nieve y la elevación de la isoterma 0 °C. Por otro lado, las cuencas más pluviales debieran mostrar mayor sensibilidad ante perturbaciones en la precipitación. Esta distinción se analiza en detalle en las siguientes secciones, donde se presentan los resultados obtenidos para cada tipo de variable modificada.

4.2.2. Resultados de perturbaciones individuales

En esta sección se presentan los resultados del análisis de sensibilidad, comenzando por los efectos de perturbar individualmente las tres variables clave: precipitación, temperatura y cobertura forestal. Luego, se exploran escenarios combinados y, finalmente, se ofrece una síntesis que ayude a interpretar el comportamiento general del modelo ante condiciones cambiantes.

a. Elasticidad frente a la precipitación

La Figura 8 muestra cómo cambia el caudal máximo diario cuando varía la precipitación. En todas las cuencas se observan elasticidades positivas, lo que quiere decir que, al aumentar la lluvia, el caudal máximo también crece en la misma dirección. Este comportamiento está en línea con lo reportado en otros trabajos, donde la precipitación aparece como el principal factor que impulsa la escorrentía (Addor et al., 2018; De la Fuente et al., 2021).

Para contar con un punto de referencia práctico, en la Figura 8 se incluyen dos estimaciones empíricas comúnmente utilizadas en Chile (Dirección General de Aguas [DGA], 2005). La línea punteada negra corresponde al valor promedio obtenido con el Método DGA-AC para crecidas pluviales, mientras que la línea discontinua roja representa el Método de Verni y King modificado, calibrado para cuencas chilenas. La idea de incluirlos no es comparar metodologías, sino ofrecer un marco de referencia conocido que ayude a comprobar si las respuestas del modelo LSTM se encuentran dentro de rangos razonables y reconocidos por la comunidad ingenieril.

Un punto que llama la atención es que la mayoría de las cuencas presentan elasticidades iguales o incluso superiores a las que entregan los métodos empíricos. Esto sugiere que el modelo LSTM no solo reproduce comportamientos hidrológicos esperados, sino que también distingue las particularidades de cada cuenca, reflejando diferencias reales en su respuesta ante la lluvia. Este enfoque coincide con lo planteado por Anderson et al. (2024), quienes destacan que las curvas de elasticidad permiten entender cómo cambia la sensibilidad del caudal a lo largo de toda la gama de flujos. Según estos autores, las cuencas con una reacción más rápida y menor almacenamiento tienden a mostrar elasticidades mayores, mientras que las que tienen un control nival o una capacidad de retención más alta muestran respuestas más moderadas.

Las cuencas del Lircay, Ñuble, Cautín y Liquiñe son un ejemplo de esto: presentan elasticidades medianas mayores a 1, lo que significa que el caudal máximo crece más proporcionalmente que ante aumentos en la lluvia. Estas cuencas, de régimen pluvio-nival, tienen poca capacidad de almacenamiento y reaccionan casi de inmediato a los eventos de precipitación (Báez-Villanueva et al., 2024; Medina et al., 2022). Esto coincide con estudios que muestran que las cuencas con menor “memoria hidrológica” tienden a responder con mayor fuerza frente a los cambios en la precipitación (Martel et al., 2024). En este sentido, el LSTM logra captar bien este tipo de comportamiento rápido, donde la lluvia tiene un efecto directo sobre el caudal.

Por otro lado, el Río Ibáñez muestra una elasticidad menor, de 0.84 [0.43 – 0.95], lo que refleja una respuesta más amortiguada. Esto se debe, en parte, a que gran parte de la cuenca está sobre la isoterma 0 °C (1140–2400 m en Patagonia), por lo que buena parte

de la precipitación cae como nieve y se libera más tarde con el deshielo. Este almacenamiento temporal reduce la reacción inmediata del caudal frente a la lluvia, tal como se ha documentado en sistemas nivosos (Báez-Villanueva et al., 2024; Medina et al., 2022).

El río Las Chinas presenta un comportamiento distinto y particularmente interesante. Su sensibilidad promedio es alta (1.43 [0.36–2.53]), pero con una dispersión amplia entre eventos. Esta variabilidad se explica por varios factores: una precipitación media anual muy baja (1.3 mm/día), una cobertura forestal reducida (6.5 %) y una fuerte estacionalidad de las lluvias, a lo que se suma su baja elevación máxima (1627 m), que limita el desarrollo del gradiente altitudinal de precipitaciones. Como resultado, la escorrentía tiende a generarse de forma casi simultánea en toda la cuenca, haciendo que la respuesta hidrológica dependa en gran medida del estado del suelo: cuando está seco, buena parte de la lluvia se infiltra, pero si se encuentra saturado, el exceso fluye rápidamente como escorrentía superficial. Además, como señalan Rojas y Minder (2024), en las zonas australes donde la sombra de lluvia varía de un evento a otro, pueden alternarse tormentas con poca precipitación efectiva y otras en que se produce un “derrame” de humedad hacia el lado seco de los Andes. En este contexto, pequeños cambios en la temperatura o en la altura de la isoterma 0 °C pueden definir si la lluvia logra alcanzar la cuenca y generar escorrentía o si se pierde antes de hacerlo, lo que podría explicar la alta dispersión observada en las elasticidades del río Las Chinas.

Por último, vale la pena recordar que la posición de la isoterma 0 °C, analizada con más detalle en la siguiente sección, también influye en la sensibilidad de las cuencas. En eventos más cálidos, esta isoterma sube y la nieve que normalmente se acumularía cae como lluvia, aumentando el escurrimiento directo y con ello la elasticidad del caudal máximo (Dirección Meteorológica de Chile, 2020; Anderson & Radić, 2022; Escanilla-Minchel et al., 2020).

En resumen, los resultados reflejan la diversidad climática e hidrológica de las cuencas analizadas. Las cuencas del centro-sur responden con fuerza ante los aumentos de lluvia, mientras que las patagónicas lo hacen de forma más moderada o variable, dependiendo de su altitud y del efecto de la sombra pluviométrica. Como advierten Anderson et al. (2024) y Rojas y Minder (2024), las diferencias en la altura de la isoterma, el gradiente orográfico de la precipitación y las condiciones atmosféricas regionales podrían explicar buena parte de la heterogeneidad observada.




Figura 8. Distribución de la 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).

b. Elasticidad frente a la temperatura

Los resultados obtenidos al aplicar perturbaciones térmicas muestran que la respuesta de las cuencas al aumento de temperatura es diversa y depende de las características propias de cada una. A diferencia de lo que ocurre con la precipitación, donde el efecto sobre el caudal es más directo, el impacto de la temperatura se manifiesta a través de procesos distintos que pueden reforzar o debilitar la escorrentía. Por un lado, un aumento térmico puede elevar la isoterma $0\text{ }^{\circ}\text{C}$ y transformar parte de la nieve en lluvia, incrementando la cantidad de agua que fluye hacia los ríos (Schauwecker et al., 2022). Sin embargo, cuando la isoterma permanece la mayor parte del tiempo por encima de la altitud máxima de la cuenca, estos cambios no modifican la fase de la precipitación y el efecto sobre los caudales extremos tiende a ser leve. En estos casos, procesos más lentos, como la evapotranspiración, podrían reducir ligeramente la escorrentía, aunque no son la causa principal de las diferencias observadas en los caudales máximos (Escanilla-Minchel et al., 2020).

Entre las cuencas analizadas, las del Río Ñuble (2.40 [0.38–6.04]) y Río Las Chinas (–0.96 [–3.22–3.91]) destacan por su gran variabilidad. En ambos casos, la altitud máxima coincide con el rango donde suele ubicarse la isoterma $0\text{ }^{\circ}\text{C}$ (2100–3600 m en Ñuble y 1140–2300 m en Las Chinas; ver Tabla A.7). Esto significa que pequeños cambios de temperatura pueden determinar si un mismo evento se presenta como lluvia o nieve. Además, cuando existe nieve acumulada y se registran precipitaciones líquidas, pueden producirse eventos de lluvia sobre nieve, en los cuales la lluvia acelera el derretimiento del manto y genera aumentos abruptos en los caudales (Musselman et al., 2018; Brandt et al., 2022). En Chile central se han documentado situaciones de este tipo, donde lluvias cálidas sobre un manto nival causaron crecidas rápidas en el río Maipo (Ocampo-Melgar et al., 2020). Este comportamiento es coherente con lo observado en Ñuble y Las Chinas, donde algunos eventos muestran aumentos notables en el caudal, mientras que otros apenas varían, evidenciando una respuesta muy dependiente de las condiciones térmicas y de la cantidad de nieve previa (Zarzycki et al., 2024).

En las cuencas del Río Cautín (1.21 [0.68–2.02]) y Río Ibáñez (1.26 [0.84–2.03]) la respuesta es diferente. Aunque también muestran una sensibilidad positiva al aumento de temperatura, los valores son más acotados y las bandas de variación son estrechas. En ambos casos, las cotas máximas se encuentran por encima del rango más común de la isoterma (2300–2900 m en Cautín y 1140–2400 m en Ibáñez), por lo que la mayor parte de la cuenca mantiene condiciones similares durante los eventos de lluvia. El aumentar la temperatura genera un leve incremento en la fracción líquida de la precipitación, pero sin provocar cambios abruptos ni aumentos desmedidos en el caudal. En consecuencia, los resultados reflejan una respuesta más estable y coherente con cuencas que conservan un comportamiento nival moderado, donde el deshielo contribuye, pero no domina completamente la generación de escorrentía durante crecidas.

Por otro lado, las cuencas del Río Lircay (–0.44 [–1.71–0.80]) y Río Liquiñe (0.82 [–0.47–2.12]) muestran elasticidades bajas y, en algunos casos, cercanas a cero. En ambas cuencas, la isoterma 0 °C se sitúa la mayor parte del año por encima de su altitud máxima, lo que significa que los eventos de nieve son escasos y que el régimen es principalmente pluvial. Bajo este contexto, los aumentos de temperatura de uno o varios grados no modifican de forma importante la cantidad de agua que llega a los ríos, pues la precipitación ya se presenta mayoritariamente en forma líquida. En el caso del Lircay, su alta cobertura vegetal también podría contribuir a una ligera disminución de la escorrentía al aumentar la evapotranspiración, aunque este efecto sería secundario. En ambos casos, la señal térmica resulta amortiguada debido a la ausencia de un componente nival que pueda responder a cambios de fase.

En conjunto, los resultados muestran que la elasticidad térmica depende de la relación entre la altitud máxima de la cuenca y el rango de variación de la isoterma 0 °C. Cuando ambas coinciden, como ocurre en Ñuble y Las Chinas, las pequeñas variaciones de temperatura pueden cambiar la fase de la precipitación y dar lugar a respuestas muy variables o incluso extremas. En cambio, cuando la isoterma se mantiene claramente por encima o por debajo de la cuenca, como en Cautín, Ibáñez, Lircay y Liquiñe, la respuesta tiende a estabilizarse. Además, se observa que si la cota máxima de la cuenca se encuentra por debajo del rango de la isoterma, las elasticidades se atenúan, mientras que si se ubica por encima, los valores tienden a ser mayores, aunque sin alcanzar los extremos de las cuencas mixtas. En definitiva, estos resultados refuerzan la importancia de analizar la posición dinámica de la isoterma 0 °C en relación con la topografía, ya que este factor explica gran parte de las diferencias en la sensibilidad térmica y su influencia en la generación de caudales máximos diarios (Musselman et al., 2018; Brandt et al., 2022; Ocampo-Melgar et al., 2020; Zarzycki et al., 2024).




Figura 9. Elasticidad del caudal máximo diario frente a perturbaciones en la temperatura.

c. Elasticidad frente a la cobertura forestal (LC_Forest)

Luego de analizar la influencia de la temperatura y la precipitación sobre el caudal máximo diario, se evaluó también el efecto de la cobertura forestal. Este aspecto resulta especialmente importante, ya que la vegetación cumple un papel fundamental en la regulación del ciclo hidrológico. A través de procesos como la interceptación de lluvias, la evapotranspiración y el almacenamiento superficial del agua, el bosque actúa como un modulador natural del flujo de escorrentía (Hall et al., 2024). Para evaluar este efecto, se aplicaron perturbaciones controladas del 5 % en la cobertura de bosque de cada cuenca, manteniendo constantes las demás condiciones del sistema.

Los resultados obtenidos (Figura 10) muestran una clara tendencia hacia valores de elasticidad negativos, lo que indica que un aumento en la cobertura forestal tiende a reducir el caudal máximo diario. En otras palabras, existe una relación inversa entre ambas variables, coherente con lo que ha documentado la literatura especializada.

Entre las cuencas más sensibles destacan Cautín ($-1.9 [(-2.1) - (-1.7)]$), Liquiñe ($-1.8 [(-2.3) - (-1.4)]$) y Lircay ($-1.2 [(-1.6) - (-0.6)]$). Estas tres presentan altos porcentajes de cobertura boscosa inicial (55.0 %, 75.8 % y 66.0 %, respectivamente), lo que refuerza la idea de que la vegetación actúa como un amortiguador natural frente a las crecidas. En un escenario de pérdida de bosque, estas cuencas podrían experimentar un aumento en los caudales máximos durante eventos lluviosos, debido a la menor capacidad del dosel para retener la lluvia y del suelo para infiltrar el agua (Li et al., 2024). Este comportamiento se alinea con lo observado en otras regiones templadas, donde la disminución de la cobertura forestal se asocia con una mayor escorrentía superficial y una respuesta hidrológica más rápida frente a las tormentas.

En contraste, las cuencas del Río Ñuble ($-0.6 [(-0.8) - (-0.5)]$) y del Río Ibáñez ($-0.3 [(-0.6) - (-0.2)]$) muestran respuestas más moderadas. En el caso de Ñuble, su baja cobertura inicial (13.6 %) limita la magnitud del cambio, ya que pequeñas variaciones porcentuales

en la vegetación tienen un efecto reducido sobre el balance hídrico. En Ibáñez, aunque la cobertura forestal alcanza un 24.2 %, su influencia queda atenuada por el predominio de un régimen nival y por las condiciones frías y abiertas de la estepa patagónica. En este contexto, la dinámica del caudal está más controlada por la acumulación y el derretimiento de la nieve que por la estructura del bosque.

Un caso particular es el del Río Las Chinas, que presenta una elasticidad prácticamente nula (0.0 [-0.0 – 0.1]). Este resultado concuerda con su muy baja cobertura forestal (6.5 %) y con las condiciones frías de su entorno, donde la vegetación desempeña un papel limitado en la regulación de la esorrentía (Bentley & Coomes, 2020). En ambientes de este tipo, dominados por suelos delgados y climas rigurosos, la respuesta hidrológica depende más de las condiciones meteorológicas y del almacenamiento nival que de la cobertura vegetal.

En conjunto, los resultados confirman que la sensibilidad del caudal máximo frente a la cobertura forestal no depende solo del porcentaje de vegetación presente, sino también de la interacción con otros factores estructurales del paisaje, como la altitud, la pendiente o el régimen nival. En cuencas húmedas con abundante vegetación, el bosque funciona como un regulador natural que atenúa las crecidas extremas, mientras que en regiones más frías o áridas, su influencia disminuye. Estos hallazgos subrayan la importancia de conservar, y cuando sea posible, restaurar la cobertura forestal, especialmente en cuencas con altos niveles de lluvia y vegetación, ya que representan una barrera efectiva frente a eventos hidrológicos extremos (Li et al., 2024; Bhattacharjee & Behera, 2018; Hall et al., 2024).




Figura 10. Distribución de la elasticidad del caudal frente a perturbaciones en la cobertura forestal (LC_Forest).

4.2.3. Resultados de perturbaciones combinadas

a. Interacción precipitación–temperatura

El efecto combinado de la precipitación y la temperatura sobre el caudal máximo diario ha sido poco estudiado, a pesar de que en la realidad ambos factores suelen actuar al mismo tiempo. La mayoría de las investigaciones los han analizado por separado, pero estudios recientes demuestran que su interacción puede generar respuestas no proporcionales e incluso contrarias a lo esperado (Patterson et al., 2022). En este estudio se analizaron perturbaciones simultáneas de precipitación y temperatura a través de tres escenarios: el primero corresponde al caso base, con variaciones únicamente en la precipitación; el segundo, al escenario combinado (+/+), que considera aumentos conjuntos de ambas variables; y el tercero, al escenario (+/-), en el cual la precipitación aumenta mientras la temperatura disminuye. Esta configuración permite distinguir no solo los efectos individuales de cada variable, sino también su interacción y la forma en que estos procesos se expresan en el comportamiento hidrológico de cada cuenca.

En las cuencas del Río Ñuble, Río Cautín, Río Liquiñe y Río Ibáñez (Figura 11) se observa un patrón similar. Cuando aumentan tanto la precipitación como la temperatura, la elasticidad también crece en comparación con el escenario donde solo varía la precipitación. En los gráficos, esto se refleja en que la línea roja, correspondiente al escenario combinado, se sitúa por encima de la azul. Este comportamiento puede explicarse por la acción conjunta de dos mecanismos. En primer lugar, el ascenso de la isoterma 0 °C transforma parte de la nieve en lluvia, lo que incrementa la fracción de escorrentía directa. En segundo lugar, el gradiente de precipitación con la altitud favorece que precipiten mayores volúmenes de agua en las zonas más altas, reforzando el efecto del calentamiento.

La combinación de ambos procesos da lugar a un aumento más pronunciado del caudal máximo cuando coinciden lluvias intensas y temperaturas elevadas. Este resultado coincide con lo reportado en zonas de montaña, donde la lluvia sobre nieve y la fusión acelerada del manto pueden generar crecidas extremas (Chandel & Ghosh, 2021; Patterson et al., 2022; Martel et al., 2024). Investigaciones recientes confirman este fenómeno: durante los eventos de lluvia sobre nieve (ROS), la precipitación líquida acelera el derretimiento del manto nival y aumenta de forma notable los caudales diarios, especialmente cuando existe un contenido de agua en nieve (SWE) elevado y un rápido ascenso térmico (Musselman et al., 2018; Brandt et al., 2022). En Chile central, Ocampo-Melgar et al. (2020) documentaron situaciones similares en la cuenca del río Maipo, donde la combinación de lluvias cálidas y nieve acumulada provocó aumentos abruptos en el caudal. Más recientemente, Zarzycki et al. (2024) mostraron que estos eventos, aunque poco frecuentes, representan una proporción importante de las crecidas extremas en regiones frías y de montaña a escala global.

Por el contrario, la cuenca del Río Lircay presenta un comportamiento prácticamente neutro. En este caso, las tres curvas —correspondientes a los escenarios de precipitación sola, (+/+) y (+/-)— se superponen en el mismo rango, lo que sugiere que la temperatura no altera de forma clara la respuesta del caudal. Esta ausencia de efecto se explica porque la altitud máxima de la cuenca (2400 m) se encuentra por debajo del rango medio en que fluctúa la isoterma 0 °C (2100–3600 m; Tabla A.7). Por ello, la fracción nival en juego es pequeña y la dinámica del Lircay se mantiene esencialmente pluvial, de modo que las variaciones térmicas, ya sean positivas o negativas, apenas influyen en la generación de crecidas.

La respuesta del Río Las Chinas es más compleja. Esta cuenca presenta una amplia banda de incertidumbre, con valores tanto positivos como negativos, lo que evidencia una alta variabilidad en su comportamiento. Una posible interpretación es que, en condiciones de temperaturas muy bajas, un incremento de uno o dos grados no basta para transformar la nieve en lluvia, por lo que el efecto sobre el caudal resulta limitado. Sin embargo, en algunos eventos se producen condiciones de lluvia sobre nieve, lo que provoca un derretimiento súbito del manto nival y un aumento considerable de la escorrentía. Esta alternancia entre eventos sin reacción aparente y otros con respuestas extremas explica la dispersión observada en los resultados. En consecuencia, el caso de Las Chinas representa un entorno donde la sensibilidad climática es difícil de anticipar y donde pequeñas variaciones térmicas pueden tener efectos muy distintos, abriendo una línea de investigación relevante para comprender las causas de esta incertidumbre.

El escenario (+/-), que combina un aumento de la precipitación con una disminución de la temperatura, muestra un patrón más consistente entre cuencas. En la mayoría de los casos, la elasticidad disminuye en comparación con el escenario base, lo que concuerda con el descenso de la isoterma 0 °C. Bajo estas condiciones, una mayor proporción de la precipitación se acumula en forma de nieve y no se convierte en escorrentía inmediata, lo que retrasa el aporte al caudal y atenúa los picos de crecida (Rajwa-Kuligiewicz & Bojarczuk, 2024).

En conjunto, los resultados muestran que las respuestas no son aleatorias, sino que reflejan patrones coherentes con el régimen hidroclimático de cada cuenca. En Ñuble, Cautín, Liquiñe e Ibáñez, la interacción entre temperatura y precipitación potencia la generación de caudales extremos, mientras que en Lircay la temperatura no ejerce un papel relevante y en Las Chinas la señal es más incierta. En definitiva, los hallazgos refuerzan la idea de que el ascenso de la isoterma 0 °C, la presencia de nieve previa y la intensidad de la lluvia son factores clave para entender cómo se originan las crecidas bajo escenarios donde ambas variables cambian simultáneamente (Musselman et al., 2018; Ocampo-Melgar et al., 2020; Brandt et al., 2022; Zarzycki et al., 2024).




Figura 11. Elasticidad del caudal máximo diario frente a perturbaciones combinadas de precipitación y temperatura para seis cuencas andinas. La línea azul muestra el caso base, con perturbaciones solo en precipitación. La línea roja representa el escenario de aumento simultáneo en precipitación y temperatura (+prep, +temp), mientras que la línea amarilla corresponde al caso donde aumenta la precipitación, pero

disminuye la temperatura (+prcp, -temp). En cada caso, la línea indica la mediana (Q2) de la elasticidad, y las bandas sombreadas representan el rango entre el primer y tercer cuartil (Q1–Q3), reflejando la variabilidad en la respuesta.

b. Interacción precipitación–cobertura forestal

El análisis de sensibilidad frente a perturbaciones combinadas en la precipitación (+5 %) y en la cobertura forestal permite comprender cómo interactúan los factores climáticos con las características estructurales del paisaje. Mientras la precipitación actúa como el principal detonante de la escorrentía (Addor et al., 2018; De la Fuente et al., 2021), el bosque influye en su regulación a través de mecanismos como la interceptación, la evapotranspiración, la infiltración y el almacenamiento subsuperficial del agua (Li et al., 2024). En la Figura 12 se presentan tres escenarios: en azul, los efectos de la precipitación por sí sola; en verde, los escenarios sincronizados, donde tanto la lluvia como la cobertura forestal aumentan o disminuyen al mismo tiempo; y en café, los escenarios opuestos, en los cuales una variable se incrementa mientras la otra disminuye.

En el primer grupo de cuencas, conformado por Lircay, Cautín y Liquiñe, se observa el patrón más claro. Cuando las perturbaciones son sincronizadas, la elasticidad disminuye hasta valores cercanos a cero o negativos, lo que indica que el bosque atenúa de manera efectiva los aumentos de precipitación. Esta capacidad de regulación se explica por la acción conjunta del dosel, las raíces y los suelos, que reducen la escorrentía al interceptar parte de la lluvia, retener agua y aumentar la evapotranspiración. Sin embargo, cuando la precipitación aumenta y la cobertura forestal disminuye, la respuesta se invierte: la elasticidad crece con fuerza y la línea café supera ampliamente a la azul. En este caso, la pérdida de vegetación elimina su efecto moderador y amplifica la respuesta del caudal, tal como lo señalan estudios que han advertido sobre los efectos de la deforestación en regiones de alta pluviosidad (Li et al., 2024).

Un segundo grupo lo conforman las cuencas de Ñuble e Ibáñez, donde la interacción entre lluvia y bosque es más tenue. En ambas, los escenarios sincronizados muestran una reducción más limitada de la elasticidad, lo que sugiere que la vegetación contribuye a la regulación, aunque de manera menos marcada que en el grupo anterior. Del mismo modo, en los escenarios opuestos, el aumento de la elasticidad es más moderado y no alcanza la magnitud observada en las cuencas más húmedas. Estas diferencias se explican por su menor cobertura forestal inicial y por condiciones estructurales que restringen la influencia del bosque, como el régimen nival dominante en Ibáñez y la escasa proporción de vegetación en Ñuble.

El Río Las Chinas constituye un caso particular dentro del conjunto. En esta cuenca, la influencia del bosque sobre la escorrentía es prácticamente nula, lo que se entiende considerando que solo un 6,5 % de su superficie está cubierta por vegetación arbórea. En un entorno tan frío y abierto, donde predominan los suelos delgados y las bajas temperaturas, otros factores como la altitud, la presencia de nieve y el régimen climático local determinan de forma mucho más directa el comportamiento del caudal máximo (Bentley & Coomes, 2020).

En general, los resultados demuestran que la interacción entre la precipitación y la cobertura forestal no sigue una relación lineal, sino que depende del contexto particular de cada cuenca. En Lircay, Cautín y Liquiñe, el bosque actúa como un verdadero amortiguador frente a los eventos de lluvia intensa, reduciendo los caudales extremos. No obstante, cuando se produce pérdida de vegetación, el sistema se vuelve más sensible y

los caudales aumentan de manera significativa. En Ñuble e Ibáñez, este efecto es más atenuado, y en Las Chinas prácticamente desaparece. Esta tendencia ha sido ampliamente descrita en la literatura, donde se indica que el papel regulador del bosque se intensifica por sobre ciertos umbrales de cobertura (30–70 %) y en cuencas de menor tamaño (Li et al., 2024). Además, factores como la pendiente, la edad del bosque o la estructura del suelo también influyen en la magnitud de la respuesta (Bentley & Coomes, 2020).

En síntesis, las cuencas con mayor cobertura forestal y regímenes húmedos presentan una capacidad superior para amortiguar las crecidas extremas, aunque al mismo tiempo se vuelven más vulnerables a la pérdida de vegetación. Estos resultados respaldan el uso de las elasticidades combinadas como una herramienta útil para evaluar la resiliencia hidrológica de los sistemas y ponen en evidencia la importancia de integrar la conservación forestal dentro de las estrategias de planificación hídrica adaptativa (Bhattacharjee & Behera, 2018; Hall et al., 2024).




Figura 12. Elasticidad del caudal máximo diario frente a perturbaciones combinadas de precipitación (+5%) y cobertura forestal (LC_Forest), expresadas como mediana (Q2) y rango intercuartílico (Q1–Q3). La línea azul representa el efecto de modificar únicamente la precipitación. La línea verde muestra los resultados bajo cambios sincronizados en ambas variables (aumento o disminución conjunta de precipitación y cobertura), mientras que la línea café corresponde a escenarios con perturbaciones en direcciones opuestas (por ejemplo, aumento de precipitación y disminución de cobertura, o viceversa). Las bandas sombreadas indican el rango entre el primer y tercer cuartil, reflejando la variabilidad en la respuesta.

4.2.4. Síntesis interpretativa del análisis de sensibilidad

El análisis de sensibilidad permitió comprender de forma cuantitativa cómo el modelo LSTM responde ante cambios controlados en precipitación, temperatura y cobertura forestal, así como las interacciones entre estas variables. El propósito fue identificar qué factores controlan la generación de caudales máximos diarios y evaluar cómo estas relaciones varían entre cuencas con distintos regímenes climáticos y características fisiográficas.

El enfoque consistió en aplicar perturbaciones porcentuales y analizar la respuesta del caudal máximo mediante elasticidades, lo que permitió distinguir no solo la dirección del cambio, sino también su magnitud y estabilidad. Este procedimiento otorgó una visión más transparente del comportamiento interno del modelo, abriendo parcialmente la “caja negra” del LSTM y revelando qué variables condicionan realmente su desempeño.

Los resultados muestran que la precipitación es el principal forzante de las crecidas, con respuestas más intensas en cuencas pluvio-nivales y más amortiguadas en regiones frías o con control nival. La temperatura, en cambio, produce respuestas heterogéneas: en zonas donde la isoterma 0 °C coincide con la altitud de la cuenca, pequeñas variaciones térmicas pueden cambiar la fase de la precipitación y amplificar el caudal, mientras que en sistemas pluviales o con poca nieve el efecto se atenúa. Por su parte, la cobertura forestal actúa como un regulador negativo, reduciendo los picos de caudal en cuencas húmedas y boscosas, aunque con menor incidencia en entornos con menor cobertura forestal o con un comportamiento más nival.

Las perturbaciones combinadas evidenciaron que los efectos no son lineales. La coincidencia de lluvias intensas y temperaturas altas amplifica las crecidas, mientras que la pérdida de vegetación agrava la respuesta hidrológica, especialmente en cuencas húmedas. En conjunto, estos resultados confirman que la sensibilidad hidrológica depende del equilibrio entre forzantes climáticos, topografía y vegetación, y que el LSTM logra reproducir esta complejidad con consistencia física.

Desde una perspectiva aplicada, esta metodología permite identificar zonas más vulnerables a eventos extremos, orientar prioridades de conservación forestal y ajustar diseños de infraestructura hidráulica considerando las condiciones locales de sensibilidad climática. En contextos de cambio climático, donde se prevé un aumento de la variabilidad hidrológica, este enfoque contribuye a fortalecer la resiliencia de los sistemas fluviales, apoyar la definición de caudales de diseño más robustos y guiar decisiones de adaptación basadas en evidencia. En definitiva, el análisis de sensibilidad no solo evalúa el desempeño del modelo, sino que transforma su capacidad predictiva en conocimiento útil para comprender, anticipar y gestionar los impactos del clima sobre los recursos hídricos.

5 Conclusiones

El presente trabajo tuvo como propósito evaluar la capacidad de una red Long Short-Term Memory (LSTM) para predecir el caudal máximo diario en un conjunto diverso de cuencas chilenas y, al mismo tiempo, avanzar en la comprensión de cómo este tipo de modelos representa los procesos hidrológicos. Más que buscar reemplazar los enfoques físico-conceptuales tradicionales, este estudio propuso una alternativa complementaria que combina la potencia predictiva del aprendizaje automático con la posibilidad de interpretar sus resultados a la luz de principios hidrológicos conocidos.

Los resultados confirman que el modelo LSTM reproduce con coherencia el comportamiento de cuencas con regímenes climáticos contrastantes, incluso bajo condiciones de datos limitados. Aunque el desempeño medio ($KGE \approx 0.56$ en el periodo de prueba) es moderado, este valor es coherente con la complejidad de la variable analizada —el caudal máximo diario— y con el uso de información a escala diaria. Más allá de la métrica, el análisis de sensibilidad permitió abrir parcialmente la “caja negra” del modelo, mostrando que las relaciones aprendidas siguen una lógica hidrológica consistente. La precipitación se confirmó como el principal forzante de las crecidas; la temperatura exhibió respuestas moduladas por la posición de la isoterma $0\text{ }^{\circ}\text{C}$, y la cobertura forestal actuó como un amortiguador natural frente a lluvias intensas. En conjunto, estos resultados demuestran que la estructura de memoria del LSTM es capaz de representar interacciones complejas entre forzantes climáticos y atributos del paisaje sin necesidad de imponer ecuaciones explícitas, aportando interpretabilidad al comportamiento interno del modelo.

Las perturbaciones combinadas mostraron que las respuestas no son proporcionales ni aditivas. En las cuencas con fracción nival significativa, el aumento simultáneo de lluvia y temperatura amplificó los caudales extremos, mientras que el enfriamiento térmico generó efectos opuestos al favorecer el almacenamiento nival. Por su parte, la pérdida de cobertura forestal amplificó los picos de escorrentía, mientras que su conservación los atenuó. En conjunto, estos resultados confirman que las crecidas extremas emergen de la interacción no lineal entre clima, topografía y vegetación.

El principal aporte de este estudio no radica en lograr la mayor precisión numérica, sino en mostrar que los modelos de aprendizaje profundo pueden ser interpretables y coherentes con la física hidrológica. El LSTM demostró una notable capacidad de generalización entre regiones diversas, lo que resulta especialmente valioso en zonas de cabecera y alta montaña, donde la escasa densidad de estaciones y la discontinuidad de datos limitan la aplicabilidad de modelos físico-conceptuales. Al entrenarse con un conjunto regionalizado de cuencas representativas de las seis macrozonas climáticas de Chile, el modelo aprovechó la diversidad espacial para compensar la falta de información temporal, demostrando que es posible extraer patrones hidrológicos realistas incluso en entornos con datos escasos. Más aún abre la oportunidad de contar con modelos más consistentes si más cuencas fueran usadas en el entrenamiento.

Desde una perspectiva práctica, los resultados ofrecen una herramienta útil para la gestión hídrica y la planificación de infraestructura. Las sensibilidades estimadas permiten identificar qué cuencas son más vulnerables ante cambios en la precipitación, temperatura

o cobertura forestal, información que puede integrarse en instrumentos nacionales como el Atlas de Riesgo Climático (ARClím, 2023) o la Estrategia Nacional de Recursos Hídricos (MOP, 2020). De esta manera, es posible priorizar medidas de adaptación, reforzar defensas fluviales o actualizar caudales de diseño en las cuencas más expuestas.

En términos científicos, este trabajo constituye la primera aplicación en Chile de un análisis de sensibilidad perturbacional sobre un modelo LSTM (de acuerdo a la revisión bibliográfica realizada), demostrando que la interpretabilidad de las redes neuronales es alcanzable mediante estrategias adecuadas. En términos ingenieriles, abre una vía para evaluar la resiliencia hidrológica bajo escenarios de cambio climático, integrando enfoques basados en datos y modelos físico-conceptuales dentro de un marco complementario. En conjunto, los resultados confirman que la sinergia entre ambos paradigmas —predictivo y explicativo— representa un camino prometedor para mejorar la comprensión y gestión del agua en un país caracterizado por su diversidad climática y su creciente vulnerabilidad frente a los extremos hidroclimáticos.

6 Referencias

- Acuña Espinoza, E., Kratzert, F., Klotz, D., Gauch, M., Álvarez Chaves, M., Loritz, R., & Ehret, U. (2025). Technical note: An approach for handling multiple temporal frequencies with different input dimensions using a single LSTM cell. *Hydrology and Earth System Sciences*, 29(7), 1749–1758. <https://doi.org/10.5194/hess-29-1749-2025>
- 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>
- Alvarez-Garreton, C., Boisier, J. P., Garreaud, R., Seibert, J., & Vis, M. (2021). Progressive water deficits during multiyear droughts in basins with long hydrological memory in Chile. *Hydrology and Earth System Sciences*, 25(1), 429–446. <https://doi.org/10.5194/hess-25-429-2021>
- 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, B. J., Brunner, M. I., Slater, L. J., & Dadson, S. J. (2024). *Elasticity curves describe streamflow sensitivity to precipitation across the entire flow distribution*. *Hydrology and Earth System Sciences*, 28(7), 1567–1583. <https://doi.org/10.5194/hess-28-1567-2024>
- 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>
- 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. (2024). On the timescale of drought indices for monitoring streamflow drought considering catchment hydrological regimes. *Hydrology and Earth System Sciences*, 28(4), 1415–1439. <https://doi.org/10.5194/hess-28-1415-2024>
- 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>
- Baste, S., Klotz, D., Acuña Espinoza, E., Bardossy, A., & Loritz, R. (2025). *Unveiling the limits of deep learning models in hydrological extrapolation tasks* [Preprint]. EGU sphere. <https://doi.org/10.5194/egusphere-2025-425>

- Bathurst, J., Birkinshaw, S., Johnson, H., Kenny, A., Napier, A., Raven, S., Robinson, J., & Stroud, R. (2018). Runoff, flood peaks and proportional response in a combined nested and paired forest plantation/peat grassland catchment. *Journal of Hydrology*, 564, 916–927. <https://doi.org/10.1016/j.jhydrol.2018.07.039>
- Bentley, L., & Coomes, D. A. (2020). Partial river flow recovery with forest age is rare in the decades following establishment. *Global Change Biology*, 26(3), 1458–1473. <https://doi.org/10.1111/gcb.14954>
- Bhattacharjee, K., & Behera, B. (2018). Does forest cover help prevent flood damage? Empirical evidence from India. *Global Environmental Change*, 53, 78–89. <https://doi.org/10.1016/j.gloenvcha.2018.09.004>
- Brandt, W. T., Haleakala, K., Hatchett, B. J., & Pan, M. (2022). *A review of the hydrologic response mechanisms during mountain rain-on-snow*. *Frontiers in Earth Science*, 10, 791760. <https://doi.org/10.3389/feart.2022.791760>
- Broderick, C., Murphy, C., Wilby, R. L., Matthews, T., Prudhomme, C., & Adamson, M. (2019). Using a scenario-neutral framework to avoid potential maladaptation to future flood risk. *Water Resources Research*, 55(2), 1079–1104. <https://doi.org/10.1029/2018WR023623>
- Brooks, P. D., Gelderloos, A., Wolf, M. A., Jamison, L. R., Strong, C., Solomon, D. K., Bowen, G. J., Burian, S., Tai, X., Arens, S., Briefer, L., Kirkham, T., & Stewart, J. (2021). Groundwater-mediated memory of past climate controls water yield in snowmelt-dominated catchments. *Water Resources Research*, 57(10), e2021WR030605. <https://doi.org/10.1029/2021WR030605>
- Chandel, V. S., & Ghosh, S. (2021). Components of Himalayan river flows in a changing climate. *Water Resources Research*, 57, e2020WR027589. <https://doi.org/10.1029/2020WR027589>
- Chen, X., Huang, J., Wang, S., Zhou, G., Gao, H., Liu, M., Yuan, Y., Zheng, L., Li, Q., & Qi, H. (2022). A new rainfall-runoff model using improved LSTM with attentive long and short lag-time. *Water*, 14(5), 697. <https://doi.org/10.3390/w14050697>
- Clark, M. P., Nijssen, B., Lundquist, J. D., Kavetski, D., Rupp, D. E., Woods, R. A., Freer, J. E., Gutmann, E. D., Wood, A. W., Gochis, D. J., Rasmussen, R. M., Tarboton, D. G., Mahat, V., Flerchinger, G. N., & Marks, D. G. (2015). A unified approach for process-based hydrologic modeling: 2. Model implementation and case studies. *Water Resources Research*, 51(4), 2515–2542. <https://doi.org/10.1002/2015WR017200>
- Cortés, G., Ragettli, S., & Ayala, Á. (2024). *Rain-on-snow events in the Chilean Andes: Spatiotemporal patterns, controls, and implications for hydrological extremes*. *Natural Hazards and Earth System Sciences*, 24(9), 3315–3333. <https://doi.org/10.5194/nhess-24-3315-2024>
- Coron, L., Andréassian, V., Perrin, C., Lerat, J., Vaze, J., Bourqui, M., & Hendrickx, F. (2012). *Crash testing hydrological models in contrasted climate conditions: An experiment on 216 Australian catchments*. *Water Resources Research*, 48(5), W05552. <https://doi.org/10.1029/2011WR011721>
- De Lavenne, A., Andréassian, V., Crochemore, L., Lindström, G., & Arheimer, B. (2022). Quantifying multi-year hydrological memory with Catchment Forgetting Curves.

Hydrology and Earth System Sciences, 26(10), 2715–2732. <https://doi.org/10.5194/hess-26-2715-2022>

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., Bennett, A., Gupta, H. V., & Condon, L. E. (2024, octubre). A HydroLSTM-based machine-learning approach to discovering regionalized representations of catchment dynamics [Preprint]. ESSOAr. <https://doi.org/10.22541/essoar.172801404.45473140/v1>

De la Fuente, L. A., Ehsani, M. R., Gupta, H. V., & Condon, L. E. (2024). Toward interpretable LSTM-based modeling of hydrological systems. *Hydrology and Earth System Sciences*, 28(4), 945–971. <https://doi.org/10.5194/hess-28-945-2024>

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. (2016). Actualización del informe de evaluación de los recursos hídricos superficiales de la cuenca del río Maule (Informe técnico S.D.T. N° 385). Ministerio de Obras Públicas, Departamento de Administración de Recursos Hídricos.

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>

Duethmann, D., Blöschl, G., & Parajka, J. (2020). Why does a conceptual hydrological model fail to correctly predict discharge changes in response to climate change? *Hydrology and Earth System Sciences*, 24(7), 3493–3511. <https://doi.org/10.5194/hess-24-3493-2020>

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>

Filoso, S., Bezerra, M. O., Weiss, K. C. B., & Palmer, M. A. (2017). Impacts of forest restoration on water yield: A systematic review. *PLOS ONE*, 12(8), e0183210. <https://doi.org/10.1371/journal.pone.0183210>

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->

Gauch, M., Kratzert, F., Klotz, D., Nearing, G., Lin, J., & Hochreiter, S. (2021). Rainfall–runoff prediction at multiple timescales with a single Long Short-Term Memory network. *Hydrology and Earth System Sciences*, 25(4), 2045–2062. <https://doi.org/10.5194/hess-25-2045-2021>

Gupta, H. V. (2019). L10A: Sensitivity & Perturbation Analysis. HWRS 428/528 – Systems Approach to Hydrological Modeling [Presentación de clase, Universidad de Arizona]. <https://www.hwr.arizona.edu>

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>

Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1–2), 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>

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>

Hashemi, R., Brigode, P., Garambois, P.-A., & Javelle, P. (2022). How can we benefit from regime information to make more effective use of long short-term memory (LSTM) runoff models? *Hydrology and Earth System Sciences*, 26(21), 5793–5816. <https://doi.org/10.5194/hess-26-5793-2022>

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>

Hurtado-Pidal, J., Aguayo, M., Link, O., Valencia, B. G., & Francés, F. (2025). Setting priorities for floods mitigation through forest restoration: The threshold elevation hypothesis. *Journal of Environmental Management*, 373, 123500. <https://doi.org/10.1016/j.jenvman.2024.123500>

Jiang, S., Bevacqua, E., & Zscheischler, J. (2022). River flooding mechanisms and their changes in Europe revealed by explainable machine learning. *Hydrology and Earth System Sciences*, 26(24), 6339–6359. <https://doi.org/10.5194/hess-26-6339-2022>

Kratzert, F., Gauch, M., Nearing, G., & Klotz, D. (2022). NeuralHydrology — A Python library for deep learning research in hydrology. *Journal of Open Source Software*, 7(71), 4050. <https://doi.org/10.21105/joss.04050>

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>

- Kratzert, F., Klotz, D., Shalev, G., Klambauer, G., Hochreiter, S., & Nearing, G. (2019). Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. *Hydrology and Earth System Sciences*, 23(12), 5089–5110. <https://doi.org/10.5194/hess-23-5089-2019>
- LeFevre, K. (2014). Shake, rattle, and sink. Sensing Our Planet: NASA Earth Science Research Features. NASA Earthdata. Recuperado de <http://earthdata.nasa.gov/sensing-our-planet/shake-rattle-and-sink>
- Li, K., Wang, G., Gao, J., Guo, L., Li, J., & Guan, M. (2024). The rainfall threshold of forest cover for regulating extreme floods in mountainous catchments. *Catena*, 236, 107707. <https://doi.org/10.1016/j.catena.2023.107707>
- Ma, K., Shen, C., Xu, Z., & He, D. (2024). Transfer learning framework for streamflow prediction in large-scale transboundary catchments: Sensitivity analysis and applicability in data-scarce basins. *Journal of Geographical Sciences*, 34(5), 963–984. <https://doi.org/10.1007/s11442-024-2235-x>
- 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* [preprint]. <https://doi.org/10.5194/egusphere-2024-2133>
- 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>
- Medina, Y., Muñoz, E., Clasing, R., & Arumí, J. L. (2022). Analysis of the relative importance of the main hydrological processes at different temporal scales in watersheds of South-Central Chile. *Water*, 14(5), 807. <https://doi.org/10.3390/w14050807>
- Merz, R., Parajka, J., & Blöschl, G. (2011). *Time stability of catchment model parameters: Implications for climate impact analyses*. *Water Resources Research*, 47(2), W02531. <https://doi.org/10.1029/2010WR009505>
- Ministerio del Medio Ambiente (MMA), Ministerio de Obras Públicas (MOP), y Fundación Chile. (2019). *Marco conceptual para la seguridad hídrica en Chile*. Santiago, Chile: Gobierno de Chile. <https://mma.gob.cl>
- Mohr, C. H., Montgomery, D. R., Huber, A., Bronstert, A., & Iroumé, A. (2012). Streamflow response in small upland catchments in the Chilean coastal range to the MW 8.8 Maule earthquake on 27 February 2010. *Journal of Geophysical Research: Earth Surface*, 117, F02032. <https://doi.org/10.1029/2011JF002138>
- Mohr, C. H., Montgomery, D. R., Huber, A., Bronstert, A., & Iroumé, A. (2012). Streamflow response in small upland catchments in the Chilean coastal range to the MW 8.8 Maule earthquake on 27 February 2010. *Journal of Geophysical Research: Earth Surface*, 117, F02032. <https://doi.org/10.1029/2011JF002138>
- Mkaya, D. M. (2013). Evaluation of the impact of land use change on catchment hydrology: The case of Wundanyi River Catchment in Taita Hills, Kenya (Tesis de maestría, Egerton University, Department of Agricultural Engineering).

- Musselman, K. N., Lehner, F., Ikeda, K., Clark, M. P., Prein, A. F., Liu, C., Barlage, M., & Rasmussen, R. (2018). *Projected increases and shifts in rain-on-snow flood risk over western North America*. *Nature Climate Change*, 8(9), 808–812. <https://doi.org/10.1038/s41558-018-0236-4>
- 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>
- Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., Prieto, C., & Gupta, H. V. (2021). What role does hydrological science play in the age of machine learning? *Water Resources Research*, 57, e2020WR028091. <https://doi.org/10.1029/2020WR028091>
- Ocampo Melgar, D., & Meza, F. J. (2020). *Exploring the fingerprints of past rain-on-snow events in a Central Andean mountain range basin using satellite imagery*. *Remote Sensing*, 12(24), 4173. <https://doi.org/10.3390/rs12244173>
- 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>
- Pianosi, F., Beven, K., Freer, J., Hall, J. W., Rougier, J., Stephenson, D. B., & Wagener, T. (2016). Sensitivity analysis of environmental models: A systematic review with practical workflow. *Environmental Modelling & Software*, 79, 214–232. <https://doi.org/10.1016/j.envsoft.2016.02.008>
- Qi, W., & Liu, J. (2019). Studies on changes in extreme flood peaks resulting from land-use changes need to consider roughness variations. *Hydrological Sciences Journal*, 64(16), 2015–2024. <https://doi.org/10.1080/02626667.2019.1669039>
- Ragettli, S., Immerzeel, W. W., & Pellicciotti, F. (2016). Contrasting climate change impact on river flows from high-altitude catchments in the Himalayan and Andes Mountains. *Proceedings of the National Academy of Sciences*, 113(33), 9222–9227. <https://doi.org/10.1073/pnas.1606526113>
- Rajwa-Kuligiewicz, A., & Bojarczuk, A. (2024). Evaluating the impact of climatic changes on streamflow in headwater mountain catchments with varying human pressure: An example from the Tatra Mountains (Western Carpathians). *Journal of Hydrology: Regional Studies*, 53, 101755. <https://doi.org/10.1016/j.ejrh.2024.101755>
- Rasouli, K., Pomeroy, J. W., Janowicz, J. R., Carey, S. K., & Williams, T. J. (2014). Hydrological sensitivity of a northern mountain basin to climate change. *Hydrological Processes*, 28(14), 4191–4208. <https://doi.org/10.1002/hyp.10244>
- Rojas, Y., & Minder, J. R. (2024). *Variability of the Southern Andes rain shadow*. *Atmospheric Research*, 308, 107509. <https://doi.org/10.1016/j.atmosres.2024.107509>

- Schauwecker, S., Palma, G., MacDonell, S., Ayala, Á., & Viale, M. (2022). The snowline and 0°C isotherm altitudes during precipitation events in the dry subtropical Chilean Andes as seen by citizen science, surface stations, and ERA5 reanalysis data. *Frontiers in Earth Science*, 10, 875795. <https://doi.org/10.3389/feart.2022.875795>
- Scholbeck, C. A., Moosbauer, J., Casalicchio, G., Gupta, H. V., Bischl, B., & Heumann, C. (2024). Bridging the gap between machine learning and sensitivity analysis. *arXiv preprint arXiv:2312.13234v2*. <https://doi.org/10.48550/arXiv.2312.13234>
- 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>
- Sleziak, P., Holko, L., Danko, M., & Parajka, J. (2020). *Uncertainty in the number of calibration repetitions of a hydrologic model in varying climatic conditions*. *Water*, 12(9), 2362. <https://doi.org/10.3390/w12092362>
- Suazo Álvarez, M. J. (2023). *Reconstrucción de la altitud de la isoterma 0 °C en Patagonia Norte durante los últimos 900 años utilizando anillos de árboles* (Tesis de habilitación profesional, Universidad de Concepción, Facultad de Ciencias Físicas y Matemáticas). https://www.dgeo.udec.cl/wp-content/uploads/2023/04/MSUAZO_HP-1.pdf
- Vargas, X., Ricchetti, F., Jerez, C., & Mendoza, P. (2020). *Informe Proyecto ARCLim: Hidrología*. Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile; Centro de Ciencia del Clima y la Resiliencia (CR)²; Centro de Cambio Global UC; Ministerio del Medio Ambiente; Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH. Santiago, Chile. Disponible en www.cambioglobal.uc.cl
- Vásquez Yáñez, R. (2020). Climatología y tendencia de la altura de la isoterma cero. Dirección Meteorológica de Chile, Oficina Cambio Climático. <https://www.meteochile.gob.cl/>
- Wang, W., Gao, J., Liu, Z., & Li, C. (2023). A hybrid rainfall-runoff model: Integrating initial loss and LSTM for improved forecasting. *Frontiers in Environmental Science*, 11, Article 1261239. <https://doi.org/10.3389/fenvs.2023.1261239>
- Wi, S., & Steinschneider, S. (2022). Assessing the physical realism of deep learning hydrologic model projections under climate change. *Water Resources Research*, 58(9), e2022WR032123. <https://doi.org/10.1029/2022WR032123>
- Zhang, C., Zhou, Y., Lu, F., Liu, J., Zhang, J., Yin, Z., Ji, M., & Li, B. (2025). Assessing the performance and interpretability of the CNN-LSTM-Attention model for daily streamflow forecasting in typical basins of the eastern Qinghai-Tibet Plateau. *Scientific Reports*, 15, Article 82. <https://doi.org/10.1038/s41598-024-84810-5>
- Zhang, H., Fang, K., Feng, D., & Nearing, G. S. (2024). Deep learning for cross-region streamflow and flood forecasting at a global scale. *The Innovation*, 5(1), 100617. <https://doi.org/10.1016/j.xinn.2024.100617>

7 Anexos

- **Tabla A.1.**

Parámetros del modelo LSTM utilizado: arquitectura, entradas y criterios de entrenamiento.

Se detallan los principales hiperparámetros y componentes del modelo entrenado, incluyendo la arquitectura de la red, las variables de entrada utilizadas, los métodos de normalización, y los criterios aplicados en las etapas de entrenamiento, validación y prueba.

Componente	Configuración
Arquitectura base	LSTM (1 capa)
Tamaño de capa oculta	64 unidades
Secuencia de entrada	365 días
Variables dinámicas	Precipitación diaria, temperatura máxima y mínima
Variables estáticas	Pendiente media, cobertura forestal, índice de aridez, estacionalidad, frecuencia de eventos extremos
Normalización	Variables dinámicas normalizadas con estadísticas del conjunto de entrenamiento
Embedding estático/dinámico	Redes densas (3 capas: 30–20–64), activación tanh, sin dropout
Optimización	Optimizador Adam
Función de pérdida	Nash-Sutcliffe Efficiency (NSE)
Épocas de entrenamiento	45
Tasa de aprendizaje	1e-3 (ép. 0), 5e-4 (ép. 10), 1e-4 (ép. 20)
Tamaño del batch	256 muestras
Regularización	Dropout en salida LSTM: 0.2; gradiente clip: 1.0
Perturbación objetivo	Ruido normal con $\sigma = 0.005$
Período de entrenamiento	01/04/1995 – 31/03/2008
Período de validación	01/04/2008 – 31/03/2011
Período de testeo	01/04/2011 – 31/03/2014
Métricas de evaluación	NSE, KGE, α -NSE, β -NSE
Umbral de desempeño para AS	KGE > 0.6 en testing
Software	NeuralHydrology (PyTorch)

- **Tabla A.2.**

Elasticidad individual del caudal máximo diario frente a perturbaciones en variables climáticas y estructurales.

Se presentan los valores medianos y rangos intercuartílicos de elasticidad del caudal ante cambios en precipitación, temperatura y cobertura forestal para cada cuenca analizada, permitiendo evaluar su sensibilidad hidrológica frente a forzantes específicos.

Cuenca	Elasticidades medianas - Efectos individuales (Precipitación, Temperatura y Cob. De Bosque)					
	Elasticidad de prcp		Elasticidad de temp		Elasticidad de lc_forest	
	Q2	(Q3-Q1)	Q2	(Q3-Q1)	Q2	(Q3-Q1)
Rio Lircay En Puente Las Rastras	1.94	[2.32 - 1.37]	-0.44	[0.80 - (-1.71)]	0.150	[0.177-0.053]
Rio Ñuble En La Punilla	1.42	[1.95 - 1.05]	2.40	[6.04 - 0.38]	0.005	[0.015-0.001]
Rio Cautín En Rari-Ruca	1.49	[1.62 - 1.13]	1.21	[1.73 - 0.52]	0.058	[0.093-0.039]
Rio Liquiñe En Liquiñe	1.49	[1.68 - 1.37]	0.80	[2.17 - (-1.0)]	0.112	[0.212-0.063]
Rio Ibáñez En Desembocadura	0.84	[0.95 - 0.43]	1.26	[2.03 - 0.84]	-0.014	[-0.006-(-0.017)]
Rio Las Chinas En Cerro Guido	1.43	[2.53 - 0.36]	-0.96	[3.91 - (-3.22)]	0.000	[0.002-(-0.004)]

- **Tabla A.3.**

Elasticidad del caudal máximo diario frente a perturbaciones combinadas en precipitación y temperatura.

Se muestran las respuestas medianas del modelo LSTM bajo escenarios de perturbaciones simultáneas y opuestas entre variables climáticas, evaluando la no linealidad e interacción entre estos factores en distintas cuencas.

Cuenca	Elasticidad mediana - Efectos Sinérgicos (Precipitación - Temperatura)							
	Elast. Precipitación + Temperatura (+ +)		Elast. Precipitación + Temperatura (- -)		Elast. Precipitación + Temperatura (+ -)		Elast. Precipitación + Temperatura (- +)	
	Q2	(Q3-Q1)	Q2	(Q3-Q1)	Q2	(Q3-Q1)	Q2	(Q3-Q1)
Rio Lircay En Puente Las Rastras	1.5	[2.6 - 0.6]	-2.3	[-0.3 - -3.2]	1.7	[3.3 - -0.3]	-2.3	[-1.7 - -2.7]
Rio Ñuble En La Punilla	2.3	[9.1 - 1.0]	-4.4	[-2.6 - -5.8]	-2.4	[-0.3 - -3.7]	0.1	[3.3 - -1.3]
Rio Cautín En Rari-Ruca	2.0	[2.4 - 1.1]	-3.3	[-2.1 - -3.5]	-0.7	[-0.4 - -1.2]	-0.9	[-0.5 - -1.7]
Rio Liquiñe En Liquiñe	2.1	[3.5 - -0.1]	-2.8	[-1.5 - -3.5]	-1.2	[1.5 - -1.7]	-1.7	[-0.1 - -2.6]
Rio Ibáñez En Desembocadura	1.7	[2.6 - 1.5]	-2.6	[-1.4 - -3.5]	-1.2	[-0.0 - -1.9]	0.5	[1.3 - -0.2]
Rio Las Chinas En Cerro Guido	0.7	[5.8 - -3.4]	-3.4	[-0.4 - -4.9]	-1.4	[1.8 - -4.1]	-2.6	[1.5 - -5.7]

- **Tabla A.4.**

Elasticidad del caudal máximo diario frente a combinaciones de cambios en precipitación y cobertura forestal.

Se presentan los efectos sinérgicos u opuestos que surgen al modificar conjuntamente la precipitación y la cobertura forestal, destacando el rol de la vegetación en la amortiguación o amplificación del caudal máximo.

Cuenca	Elasticidad mediana - Efectos Sinérgicos (Precipitación - Cob. De Bosque)					
	precip (+5%)		Elasticidad de precip (+5%) + lc_forest (++) y (--)		Elasticidad de precip (+5%) + lc_forest (+-) y (-+)	
	Q2	(Q3-Q1)	Q2	(Q3-Q1)	Q2	(Q3-Q1)
Rio Lircay En Puente Las Rastras	2.0	[2.3 - 1.5]	0.4	[0.7 - 0.1]	3.3	[3.7 - 2.9]
Rio Ñuble En La Punilla	1.4	[1.8 - 1.1]	0.9	[1.0 - 0.7]	2.0	[2.5 - 1.6]
Rio Cautín En Rari-Ruca	1.4	[1.5 - 1.1]	-0.6	[-0.1 - -0.7]	3.2	[3.6 - 2.9]
Rio Liquiñe En Liquiñe	1.5	[1.7 - 1.4]	-0.3	[0.0 - -0.7]	3.0	[3.9 - 2.7]
Rio Ibáñez En Desembocadura	0.8	[0.9 - 0.5]	0.2	[0.4 - 0.2]	1.3	[1.5 - 0.7]
Rio Las Chinas En Cerro Guido	1.4	[2.6 - 0.4]	1.4	[2.6 - 0.4]	1.4	[2.6 - 0.3]

- **Tabla A.5.**

Distribución estadística del caudal máximo diario por cuenca y periodos de retorno.

Se indican los valores umbrales del caudal máximo para diferentes tiempos de retorno (2, 5 y 10 años), junto con la distribución estadística ajustada para cada cuenca, empleada como base para la identificación de eventos extremos.

Nombre de la Cuenca	Distribución Seleccionada	Umbrales del caudal [m ³ /s]		
		TR=2	TR=5	TR=10
Rio Loa Antes Represa Lequena	GEV (Distribución de valores extremos generalizados)	0.54	0.75	0.91
Rio Huasco En Santa Juana	GEV (Distribución de valores extremos generalizados)	3.86	6.96	9.69
Rio Elqui En Algarrobal	Distribución Log-Normal	7.14	13.22	18.24
Rio Hurtado En San Agustín	Distribución Normal	2.83	5.94	7.57
Rio Mapocho En Los Almendros	Distribución Pearson III	4.67	10.25	14.41
Rio Teno Después De Junta Con Claro	Distribución Pearson III	48.92	98.18	133.81
Rio Lircay En Puente Las Rastras	Distribución Log-Pearson III	9.09	27.57	50.24
Rio Ñuble En La Punilla	Distribución Pearson III	56.88	123.62	174.63
Rio Cautín En Rari-Ruca	Distribución Pearson III	75.12	134.51	176.72
Rio Liquiñe En Liquiñe	GEV (Distribución de valores extremos generalizados)	31.09	58.44	85.81
Rio Ibáñez En Desembocadura	Distribución Log-Normal	137.53	241.87	324.9
Rio Las Chinas En Cerro Guido	Distribución Log-Pearson III	6.46	15.74	25.62
Rio Grande En Tierra Del Fuego	Distribución Log-Pearson III	27.16	47.02	60.52

- **Tabla A.6.**

Evaluación del desempeño del modelo y frecuencia de eventos extremos por cuenca.

Se sintetiza el número de eventos asociados a un tiempo de retorno de 10 años y el valor del KGE alcanzado por el modelo en cada una de las seis cuencas utilizadas en el análisis de sensibilidad.

Código	Nombre de la Cuenca	Eventos (TR= 10)	KGE
7374001	Rio Lircay En Puente Las Rastras	18	0.64
8105001	Rio Ñuble En La Punilla	8	0.71
9123001	Rio Cautín En Rari-Ruca	14	0.84
10102001	Rio Liquiñe En Liquiñe	20	0.91
11505001	Rio Ibáñez En Desembocadura	23	0.73
12284006	Rio Las Chinas En Cerro Guido	33	0.62

- **Tabla A.7.**

Rangos aproximados de la isoterma 0 °C y cotas máximas de las cuencas analizadas.

Los rangos de la isoterma 0 °C se obtuvieron a partir de estudios previos (Schauwecker et al., 2022; Carrasco et al., 2005; Carrasco, Osorio, & Casassa, 2008; Suazo Álvarez, 2023; Dirección Meteorológica de Chile, 2020). Las cotas máximas corresponden a la base CAMELS-CL (Álvarez-Garretón et al., 2018).

Cuenca	Rango isoterma 0 °C (m s.n.m.)	Cota máxima (m s.n.m.)
Rio Lircay En Puente Las Rastras	~2100 – 3600	2441
Rio Ñuble En La Punilla	~2100 – 3600	3189
Rio Cautín En Rari-Ruca	~2300 – 2900	2642
Rio Liquiñe En Liquiñe	~2300 – 2800	2098
Rio Ibáñez En Desembocadura	~1140 – 2400	2593
Rio Las Chinas En Cerro Guido	~1140 – 2300	1627