

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXV CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

**IMPACTO DE UNA CALIBRACIÓN MULTI OBJETIVO EN LA INCERTEZA
PREDICTIVA DE UNA CUENCA PLUVIO-NIVAL**

RODRIGO MARINAO-RIVAS.¹
MAURICIO ZAMBRANO-BIGIARINI.^{2,3}

RESUMEN

En aplicaciones hidrológicas, existe una creciente necesidad de utilizar modelos lo suficientemente robustos para simular una variable de respuesta en particular. Ante esto, se hace necesario analizar la incerteza paramétrica y predictiva derivada del proceso de calibración, considerando la simulación adecuada de distintas componentes de la respuesta hidrológica. En este trabajo, se aplicó el método de optimización multiobjetivo NMPSO para calibrar el modelo hidrológico Raven GR4J-CemaNeige en una cuenca pluvio-nival de la región de La Araucanía durante el periodo 1992-2013, utilizando dos funciones objetivo: i) la eficiencia modificada de Kling-Gupta (KGE') para capturar caudales medios y altos, y ii) la eficiencia de Nash-Sutcliffe con caudales invertidos (iNSE), focalizada en la reproducción de caudales bajos. Dentro del set de soluciones obtenidas con la calibración multiobjetivo, los resultados muestran que la elección de una solución con el mejor iNSE implica valores altos de las capacidades de almacenamiento de los estanques conceptuales del modelo, en contraste al uso de una solución con el mejor KGE', la cual implica valores bajos de dichas capacidades. En cuanto a la incerteza en la respuesta de caudales, la maximización de KGE' e iNSE lleva a obtener una simulación deficiente de los caudales bajos y altos, respectivamente. Finalmente, el uso de una solución de compromiso obtenida desde el frente óptimo de Pareto conduce a obtener una respuesta adecuada tanto de los caudales altos como de los caudales bajos, desempeño que se mantiene durante el periodo de verificación.

¹ Departamento de Obras Civiles, Universidad de La Frontera- r.marinao01@ufromail.cl

² Departamento de Obras Civiles, Universidad de La Frontera- mauricio.zambrano@ufrontera.cl

³ Centro de Ciencia del Clima y la Resiliencia, (CR)2, Universidad de Chile

1. INTRODUCCIÓN

En las últimas décadas, la descripción del balance hídrico en cuencas mediante el uso de modelos hidrológicos ha experimentado grandes avances, ya sea en cuanto a la disponibilidad de datos de entrada, así como en la capacidad computacional para la ejecución de cálculos propios de cada modelo hidrológico (Singh, 2018).

Muy ligado a los avances indicados anteriormente, uno de los aspectos que ha tenido grandes mejoras es el proceso de calibración de parámetros, con variados algoritmos de optimización de uso extendido en la actualidad (ver por ejemplo, Duan et al. (1992); Zambrano-Bigiarini & Rojas (2013); Yapo et al. (1998); Tolson & Shoemaker (2007)). La mayoría de estas técnicas se aplican con foco en medir el desempeño del modelo para simular alguna variable de salida que pueda ser contrastada con mediciones en terreno. Para cuantificar dicho desempeño, existe una amplia oferta de indicadores de bondad del ajuste como la bien conocida eficiencia de Nash-Sutcliffe (NSE; Nash & Sutcliffe, 1970) o la eficiencia de Kling-Gupta (KGE; Gupta et al., 2009).

Si bien indicadores como NSE y KGE prácticamente tienen un uso estandarizado en estudios de consultoría o investigación, es importante tener en cuenta que estos han sido formulados bajo ciertas consideraciones que en la práctica no suelen tenerse en cuenta, como es, por ejemplo, el sesgo de NSE en la simulación de caudales altos (Fowler et al., 2018), en desmedro de la simulación de caudales bajos. Actualmente, se hace necesario reforzar estas discusiones, dada la creciente necesidad modelos hidrológicos lo suficientemente robustos que puedan abordar una gestión integrada de recursos hídricos, donde es clave que, por ejemplo, los caudales bajos sean bien representados. Para lo anterior, es necesario la experimentación con metodologías que puedan cuantificar la incertezas en el uso de una u otra función, siendo idóneo el uso de técnicas de optimización multiobjetivo (Deb, 2011).

El propósito de este trabajo es evidenciar el impacto del uso de una calibración multiobjetivo de un modelo hidrológico de precipitación-escorrentía en una cuenca pluvio-nival del Sur de Chile, considerando la aplicación de una función objetivo de uso general (KGE') y otra enfocada en caudales bajos. Los resultados permitirán por un lado analizar la incerteza predictiva derivada de enfocar la calibración de caudales altos y caudales medios-bajos, así como también proponer una solución de compromiso que pueda balancear ambos aspectos de la simulación.

2. ZONA DE ESTUDIO Y DATOS

Subcuenca Río Trancura antes de Llafenco

La subcuenca del Río Trancura antes de Llafenco (ver **Figura 1**) se ubica en la Región de La Araucanía, siendo tributaria de la Cuenca del Río Tolstén. Esta subcuenca tiene un régimen hidrológico pluvio-nival (DGA, 2004), y su elevación varía entre los 353 y los 3740 m s.n.m. La delimitación considerada en este trabajo se define a partir de la estación Río Trancura antes de Llafenco (RTL) (código BNA 9414001). De acuerdo a los datos de Zhao et al. (2016), la cobertura de suelo de la subcuenca RTL se compone principalmente de bosques nativos, con presencia de coberturas de roca/nieve en las zonas más altas, y pastizales en las

llanuras de inundación, con lo que la intervención antrópica puede ser despreciable en la modelación. La clasificación climática de Köppen-Geiger caracteriza esta zona con climas templados sin estaciones secas en las zona baja, y con veranos secos en las partes más elevadas (Beck et al., 2018). A partir de la información de CR2MET v2 (Boisier et al., 2018) para el periodo 1980-2020, se tiene que esta cuenca presenta precipitaciones durante todo el año, alcanzando las cantidades máximas entre mayo y agosto con valores que oscilan entre 380 y 480 mm/mes, derivando en un caudal medio anual de 106.8 m³/s según la estación fluviométrica. La temperatura media oscila entre 3 °C (invierno) y 14 °C (verano).

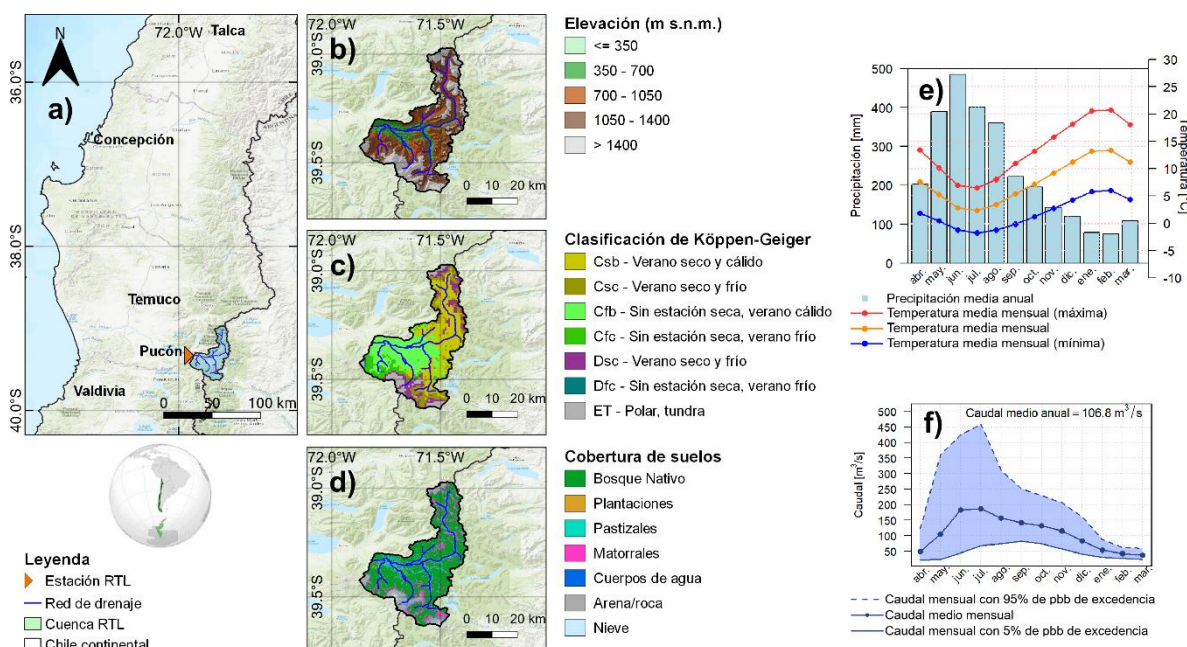


Figura 1. Cuenca Río Trancura antes de Llafenco (RTL).

Datos hidrometeorológicos

Para este trabajo, se utilizaron series temporales derivadas de datos espacialmente distribuidos de precipitación y temperaturas extremas del aire (máxima y mínima) de los productos grillados CR2MET v2 (Boisier et al., 2018), cuyas cuadrículas tienen resolución espacial de ~5 km, abarcando el periodo 1979 – 2020. También fueron requeridas series temporales de evapotranspiración potencial, calculadas con la fórmula de Hargreaves-Samani (Hargreaves & Samani, 1985), utilizando las series de temperatura de CR2MET v2. Tomando ventaja de la distribución espacial de los productos CR2MET v2, se extrajeron series temporales considerando la discretización de la cuenca RTL en tres bandas de elevación igualmente separadas en altura, entre la elevación máxima (3740 m s.n.m.) y mínima de la cuenca (353 m s.n.m.).

3. MODELO GR4J-CEMANEIGE EN RAVEN Y PARÁMETROS

La modelación hidrológica de la cuenca RTL se desarrolló en Raven (Craig et al., 2020), una plataforma de modelado hidrológico flexible para el desarrollo de modelos hidrológicos que pueden escalar en complejidad. La estructura y organización de Raven se ha formalizado

para manipular diferentes aspectos de modelado, como, por ejemplo, acomodar una amplia gama de estructuras de modelos, representaciones de procesos y enfoques de discretización espacial, con la posibilidad de emular modelos de uso extendido, como HBV (Bergström & Forsman, 1973) o GR4J (Perrin et al., 2003). Como este trabajo no está enfocado en explorar las capacidades de Raven, se ha limitado su uso a emular un modelo con la estructura de GR4J, considerando una discretización que llega solamente hasta las bandas de elevación de la cuenca trabajada.

GR4J es un modelo diario parsimonioso con cuatro parámetros libres (Perrin et al., 2003): capacidad máxima del estanque de producción ($X1$, en mm), coeficiente de intercambio de agua subterránea ($X2$, en mm), capacidad máxima del estanque de enrutamiento ($X3$, en mm), y tiempo base del hidrograma unitario UH1 ($X4$, en d). A este modelo suele acoplarse un módulo de nieve denominado CemaNeige (Valéry, 2010), el cual tiene dos parámetros libres: coeficiente de ponderación para el estado térmico de la capa de nieve ($CemaNeige_X1$), y el coeficiente de fusión grado-día ($CemaNeige_X2$, en $mm/°C/d$).

En Raven, es posible hacer simulaciones exactas de GR4J (Craig et al., 2020) siguiendo la misma nomenclatura de parámetros; sin embargo, el módulo CemaNeige se basa en una emulación algo más indirecta, donde los parámetros libres que se indican en el Manual de Raven y el código fuente tienen una denominación distinta. Como símil de $CemaNeige_X1$, se indica al valor medio anual de la lámina de agua equivalente del manto de nieve (avg_ann_snow , en mm). Por otro lado, como símil de $CemaNeige_X2$, se indica al coeficiente de transferencia de calor aire/nieve de la rutina de evolución de la temperatura de la nieve ($airsnow_coeff$, en $mm/°C/d$).

Si bien inicialmente se consideraron los rangos de parámetros indicados por Perrin et al. (2003) para la calibración de GR4J (**Tabla 1**), estos, junto a los rangos de parámetros del pseudo-CemaNeige en Raven, han sido modificados en base a varias calibraciones preliminares realizadas. Estos cambios en los rangos consistieron principalmente en aumentar las capacidades máximas de los estanques de producción y de enrutamiento ($X1$ y $X3$), con el fin de lograr extender la respuesta lenta, o sea, los caudales bajos.

Tabla 1. Set de parámetros del modelo GR4J-CemaNeige emulado en Raven y rangos considerados para la calibración.

		Parámetro	Rango	Unidad de medida
GR4J- CemaNeige en Raven	GR4J	$X1$	0 – 2.5	m
		$X2$	-10 – 10	mm
		$X3$	10 - 1000	mm
		$X4$	0 – 6	d
	Pseudo- CemaNeige	avg_ann_snow	0 – 100	mm
		$airsnow_coeff$	0 – 5	$mm/°C/d$

4. CALIBRACIÓN MULTI OBJETIVO

Enfoque de optimización multiobjetivo y frente óptimo de Pareto

Los problemas de optimización multiobjetivo (*multiobjective optimization problems*, MOP) se caracterizan porque no buscan alcanzar una única solución que optimice simultáneamente todos los objetivos. En lugar de lo anterior, se supone que la mejora en un objetivo sólo puede obtenerse deteriorando uno o más de los restantes, lo cual lleva a considerar muchas posibles soluciones (Gunantara, 2018; Yapó et al., 1998). En base a lo anterior, se pone en contexto el concepto de no-dominancia de un set de soluciones, en el cual ninguna solución debiese estar totalmente superada por otra solución dentro del set (Farina & Amato, 2002). El límite definido por todas las soluciones no-dominadas suele estar representado por un frente óptimo de Pareto (*Pareto Optimal Front*, POF), donde puede explorarse el compromiso entre los objetivos del problema (Gunantara, 2018). Para ilustrar lo anterior, la **Figura 2** muestra un conjunto de soluciones para un problema de optimización con dos objetivos en maximización, diferenciando soluciones dominadas (no óptimas) de las no-dominadas (frente óptimo de Pareto). En la figura se agrega la ubicación de un “punto Ideal”, que se obtiene a través de la intersección del valor máximo (o mínimo) de una función objetivo y el valor máximo (o mínimo) de otra función objetivo (Gunantara, 2018).

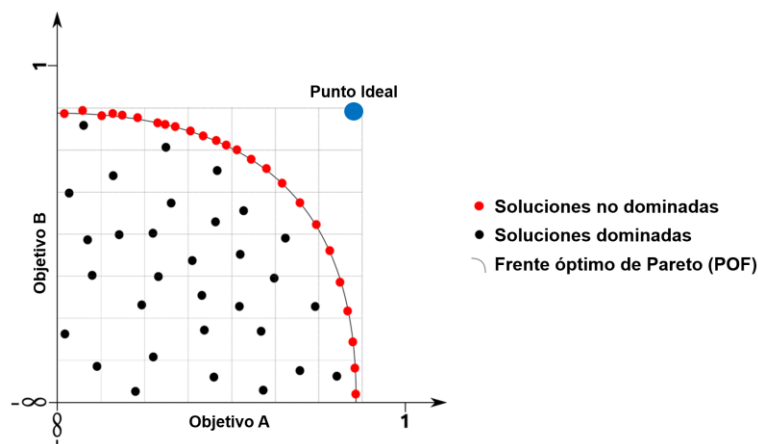


Figura 2. Representación de soluciones de un problema MOP con dos objetivos, A y B.

Optimización multiobjetivo NMPSO

NMPSO (Lin et al., 2018) es un algoritmo de optimización multiobjetivo que combina la técnica de optimización por enjambre de partículas (*Particle Swarm Optimization*, PSO) (Kennedy & Eberhart, 1995) con el uso de operadores genéticos (Lin et al., 2015). Con esta técnica cada iteración determina un frente de Pareto, calculando para cada solución un indicador (*balanceable fitness estimation*, BFE) para clasificar las partículas en un *archivo externo* (A), con el fin de proporcionar una guía efectiva para el verdadero POF, mientras se mantiene la diversidad de partículas en un repositorio de capacidad limitada.

Similar al algoritmo canónico PSO de Kennedy & Eberhart (1995), NMPSO comienza con una inicialización aleatoria de las posiciones de las partículas dentro del espacio de parámetros. Después de la búsqueda PSO, las partículas no-dominadas en el enjambre se agregan a un repositorio A para realizar un seguimiento del POF a lo largo de las iteraciones. El método BFE se utiliza para seleccionar soluciones no-dominadas que se mantendrán en A , que se consideran buenos representantes de todo el POF. Posteriormente, NMPSO realiza

operaciones evolutivas en las soluciones no-dominadas en A , para permitir el intercambio beneficioso de información entre sus partículas. En particular, se utiliza el operador de cruce binario simulado (*Simulated Binary Crossover*, SBX) para permitir el intercambio de segmentos genéticos útiles, y la mutación basada en polinomios (*Polynomial-based Mutation*, PM) llevada a cabo para agregar una pequeña perturbación y mejorar la búsqueda local. Detalles específicos sobre el uso de BFE y las operaciones genéticas SBX y PM pueden consultarse en Lin et al. (2018) y Lin et al. (2015), respectivamente.

La implementación del algoritmo NMPSO fue realizada en el lenguaje y entorno de programación R (R Core Team, 2021), basado en el pseudocódigo ofrecido por los autores del algoritmo (Lin et al., 2018).

Configuración experimental

Selección de objetivos

Los objetivos usados son dos indicadores de bondad del ajuste, siendo la eficiencia modificada de Kling-Gupta (KGE'; Kling et al., 2012), y una versión modificada de la eficiencia de Nash-Sutcliffe (Nash & Sutcliffe, 1970) donde se usa el valor inverso de los caudales (iNSE; Le Moine, 2008).

El indicador de bondad del ajuste KGE (Gupta et al., 2009) es un índice que se compone de tres términos obtenidos al comparar caudales observados (O) y simulados (S): la correlación lineal r según (2), el sesgo sistemático según (3), y la variabilidad dada por el coeficiente entre la desviación estándar entre valores simulados y observados. Kling et al. (2012) introdujo una modificación para el cálculo de la componente de variabilidad, ocupando en lugar de la desviación estándar, el coeficiente de variabilidad según (4).

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

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

$$\beta = \frac{\mu_S}{\mu_O} \quad (3)$$

$$\gamma = \frac{CV_S}{CV_O} = \frac{\sigma_S/\mu_S}{\sigma_O/\mu_O} \quad (4)$$

El uso de KGE' (o KGE) no está enfocado en un tipo de respuesta en particular (caudales altos, medios o bajos) ya que en base a su formulación está en línea con el paradigma de utilizar múltiples objetivos (Pool et al., 2018), y así evitar un sobreajuste de los parámetros del modelo a un aspecto hidrológico particular.

El segundo objetivo considerado es el indicador de bondad del ajuste *iNSE*, que es una modificación del ampliamente conocido indicador NSE, donde, en lugar de usar directamente los caudales observados (*O*) y simulados (*S*), se usa el valor recíproco ($1/O$ y $1/S$, respectivamente). Su formulación es como sigue:

$$iNSE = 1 - \frac{\sum_{i=1}^n \left(\frac{1}{S_i + \varepsilon} - \frac{1}{O_i + \varepsilon} \right)^2}{\sum_{i=1}^n \left(\frac{1}{O_i + \varepsilon} - \frac{1}{O + \varepsilon} \right)^2} \quad (5)$$

En (5) se incluye un valor ε para prevenir valores infinitos al invertir caudales nulos. De acuerdo a Pushpalatha et al. (2012), para este valor se recomienda el uso de un 1% del caudal medio observado.

El uso de *iNSE* está particularmente enfocado en la respuesta de caudales bajos, y ha sido considerado en base a la recomendación de Pushpalatha et al. (2012).

El proceso de calibración considerado abarca desde ene-1992 hasta dic-2013, con un año de calentamiento del modelo (1991); mientras que la verificación se realizó en los periodos 1980-1991 y 2013-2020, con un año de calentamiento del modelo (1979). Lo anterior, se resumen en 22 años de calibración y 19 años de verificación.

Configuración de NMPSO

En este trabajo, la aplicación del algoritmo de optimización NMPSO consideró 500 iteraciones con las siguientes especificaciones: 10 partículas para la exploración PSO, un máximo de 100 partículas en el repositorio *A* de partículas no-dominadas (N_e) en cada iteración, y un máximo de 50 operaciones genéticas (con SBX y PM) permitidas en cada iteración. Estos valores, con excepción de la cantidad máxima de iteraciones, fueron convenidos a partir de un análisis enfocado en determinar una configuración óptima del algoritmo NMPSO (Marinao-Rivas & Zambrano-Bigiarini, 2021), donde se consideró la resolución de problemas de optimización multiobjetivo con Frentes Óptimos de Pareto conocidos (Deb et al., 2005). La guía para encontrar una configuración óptima apuntó a obtener frentes óptimos de Pareto robustos en la menor cantidad de evaluaciones de las funciones.

5. RESULTADOS

POF e incerteza en los parámetros

En la **Figura 3** se muestra el Frente de Pareto resultante de la calibración multiobjetivo para la cuenca RTL, aplicando NMPSO en el periodo 1992-2013. Si bien el algoritmo NMPSO se ejecutó con 500 iteraciones, el frente de Pareto desplegado no corresponde al obtenido en la última iteración, sino que es el resultado de haber repasado la dominancia de todas las partículas de todas las iteraciones, recaudando 943 soluciones en total. De estas, las más relevantes son las que maximizan cada objetivo y la solución de mejor compromiso, siendo

esta última la que tienen la menor distancia euclidiana al punto Ideal, cuyos resultados numéricos en particular se detallan en la **Tabla 2**.




Figura 3. Frente de Pareto del MOP derivado de la calibración de la cuenca RTL con dos objetivos. Se ubica el punto Ideal (punto azul) y la solución de mejor compromiso (punto rojo).

Tabla 2. Bondad del ajuste de la solución de mejor compromiso (MC) y las que maximizan cada objetivo.

Solución	Indicador		Parámetros					
	KGE'	iNSE	X1	X2	X3	X4	avg_ann_snow	airsnow_coeff
			[m]	[mm]	[mm]	[d]	[mm]	[mm/°C/d]
Mejor KGE'	<u>0.93</u>	0.61	1.40	4.6	301.4	1.19	78.5	0.0019
Mejor iNSE	0.73	<u>0.90</u>	2.50	4.0	437.3	0.85	42.2	0.0007
MC	0.88	<u>0.86</u>	1.93	5.0	301.7	1.00	26.7	0.0005




Figura 4. Ubicación de los parámetros de las soluciones de la **Tabla 2** en el set de todo el frente óptimo de Pareto.

En la **Tabla 2** y la **Figura 4**, se desglosan los resultados de cada parámetro. Para la capacidad máxima de almacenamiento de la capa de producción (X1) se obtiene el valor más bajo para el mejor KGE', el más alto para la solución con mejor iNSE, y un valor intermedio para la solución de mejor compromiso, siendo este último cercano a la mediana de todas las soluciones del POF. Lo anterior, es similar para la capacidad máxima del estanque de

enrutamiento (X3), con la salvedad de que para el mejor iNSE y el mejor KGE' los valores son prácticamente iguales. Para el coeficiente de intercambio de agua subterránea (X2), el valor más bajo se obtiene para el mejor iNSE, un valor relativamente alto para el mejor compromiso, y uno intermedio para el mejor KGE'. Para el tiempo base del hidrograma unitario UH1 (X4), se tiene una concentración de valores en torno a 1 d (un día) para todas las soluciones del POF con solución la de mejor compromiso en dicho valor, mientras que el mejor KGE' toma un valor más alto, y el mejor iNSE uno algo más bajo. El valor medio anual de la lámina de agua equivalente del manto de nieve (*avg_ann_snow*) toma un valor más alto para el mejor KGE', un valor intermedio para el mejor iNSE, y un valor más bajo y cercano a la mediana para la solución de mejor compromiso. Para el coeficiente de transferencia de calor aire/nieve (*airsnow_coeff*), existe una concordancia en 0 para prácticamente todas las soluciones del POF, por lo que su dispersión es despreciable en términos prácticos.

Incerteza en la respuesta de caudales de todas las soluciones del POF

Para el periodo de calibración, la incerteza en la reproducción de distintos rangos de caudales medios diarios se presenta de manera compacta a través de curvas de duración (Figura 5). En cada panel, se muestran tanto las curvas de las soluciones de interés indicadas anteriormente (maximización de cada objetivo y mejor compromiso), así como la banda de incerteza generada por las respuestas de caudales provenientes de las 943 soluciones del POF.

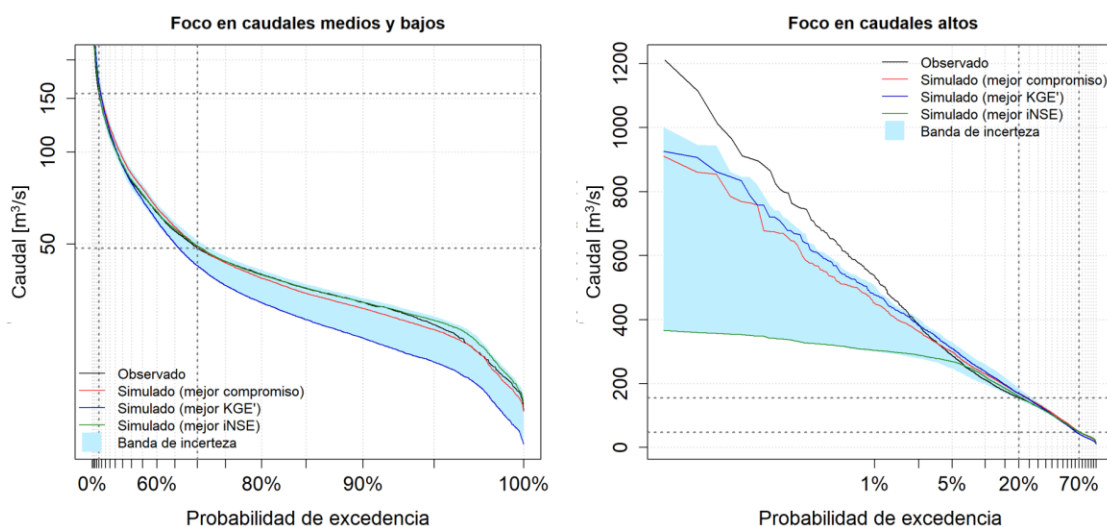


Figura 5. Curvas de duración de caudales enfocadas en caudales medios-bajos (izquierda) y caudales altos (derecha), para el periodo de calibración.

Para caudales medios-bajos (Figura 5, panel izquierdo) se destaca que la solución con mejor iNSE y la de mejor compromiso muestran una buena correspondencia con los caudales observados mientras que, por otro lado, la solución con mejor KGE' subestima a las observaciones. Para caudales altos (Figura 5, panel derecho), la solución con mejor KGE' y la de mejor compromiso muestran una reproducción adecuada respecto a los valores observados y, en el lado opuesto, la solución con mejor iNSE muestra una gran subestimación de los correspondientes valores observados. Estos resultados dejan en evidencia que la

solución de mejor compromiso lograr equilibrar la correcta representación de los caudales altos medios y bajos.

Incerteza en la respuesta de caudales en periodo de verificación

A partir de las 943 soluciones del POF obtenidas en la calibración, se pasa a determinar los resultados en periodo de verificación. La incerteza predictiva de caudales diarios para este caso se presenta en la **Figura 6**.

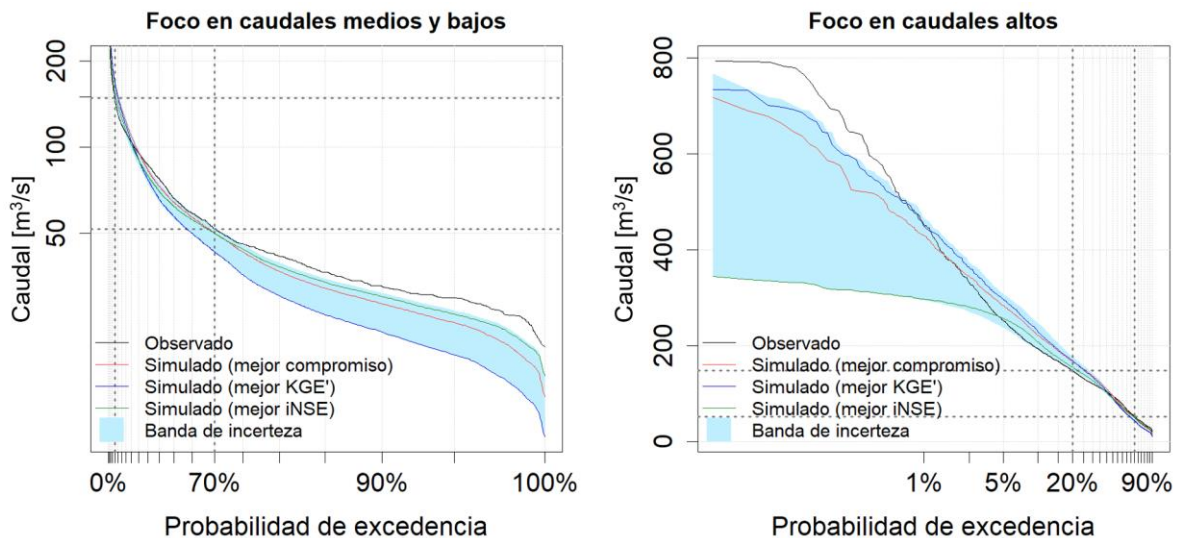


Figura 6. Curvas de duración de caudales enfocadas en caudales medios-bajos (izquierda) y caudales altos (derecha), para el periodo de verificación.

En este caso, para los caudales medios-bajos (**Figura 6**, panel izquierdo), la solución con mejor iNSE y la de mejor compromiso subestiman a los caudales observados (a diferencia de lo evidenciado en periodo de calibración), y la solución con mejor KGE' subestima aún más a las observaciones. Para caudales altos (**Figura 6**, panel derecho), al igual que en la calibración, la solución con mejor KGE' y la de mejor compromiso muestran una reproducción adecuada respecto a los valores observados y, por otro lado, la solución con mejor iNSE muestra una gran subestimación de los correspondientes valores observados.

Comparación de desempeños en periodo de verificación

En la **Tabla 3** se desglosan los desempeños de las soluciones de interés, tanto para periodo de calibración como de verificación. Para cualquiera de los tres casos, el KGE' no muestra importantes bajas en periodo de verificación, siendo la más grande aquella obtenida con la solución con mejor KGE', donde pasa de ser 0.93 a 0.86; en los otros dos casos (Mejor SC y Mejor iNSE) el KGE' aumenta en periodo de verificación. En cuanto a iNSE, éste presenta importantes bajas en todos los casos, siendo el menos severo aquel en el que se consideró la solución con mejor iNSE; el más severo aquel caso en el que se usó la solución de mejor KGE', y en un nivel intermedio, el uso de la solución de mejor compromiso.

Tabla 3. Comparación de desempeños en periodo de calibración y verificación.

Opción		Calibración	Verificación
Mejor SC	KGE'	<u>0.88</u>	0.89
	$iNSE$	<u>0.86</u>	0.66
Mejor KGE'	KGE'	<u>0.93</u>	0.86
	$iNSE$	0.61	-0.04
Mejor $iNSE$	KGE'	0.73	0.79
	$iNSE$	<u>0.90</u>	0.79

Hidrograma para un año específico en periodo de verificación

En la **Figura 7** se muestra el hidrograma de caudales diarios entre ene-2019 y dic-2019, el cual deja en evidencia, en forma de serie de tiempo, lo que implica adoptar una solución inclinada hacia un objetivo (mejor KGE' o mejor $iNSE'$) o la solución de mejor compromiso. En el caso de la solución con mejor KGE' , es notable la inclinación a representar los caudales peak observados y, por otro lado, subestimar los caudales en periodo de estiaje (feb-2019 a mar-2019). La solución con mejor $iNSE$, al contrario, tiende a presentar una mayor cercanía a los caudales bajos y, por otro lado, una gran subestimación de las caudales peak. Así, también se puede apreciar que la solución de mejor compromiso logra equilibrar la representación de caudales peak y caudales bajos, usualmente ubicándose en medio de las soluciones anteriores. Por último, indicar que la banda de incerteza envuelve a todas las soluciones del frente óptimo de Pareto, teniendo como límites (inferior y/o superior) usualmente a las simulaciones con soluciones que maximizan cada objetivo (mejor KGE' o mejor $iNSE'$).




Figura 7. Hidrograma para el año calendario 2019, incluido en el periodo de verificación. Se ubican los caudales observados, así como los simulados a partir de las soluciones del frente óptimo de Pareto.

6. CONCLUSIONES

En este trabajo, se aplicó un método de optimización multiobjetivo para la calibración del modelo hidrológico Raven GR4J-CemaNeige en una cuenca pluvio-nival del Sur de Chile,

considerando dos funciones objetivo: la eficiencia modificada de Kling-Gupta (KGE') y la eficiencia de Nash-Sutcliffe con caudales invertidos (iNSE). Este enfoque permitió obtener soluciones (i.e., conjuntos de parámetros) que cumplen la optimalidad de Pareto durante el proceso de calibración.

Al evaluar la incerteza paramétrica correspondiente a todas las soluciones del frente de Pareto, se observa una dispersión importante para cinco de los seis parámetros calibrados, siendo la excepción, el coeficiente de transferencia de calor aire/nieve. En particular, para la solución que maximiza iNSE se obtuvieron las más altas capacidades máximas de los estanques de producción y de enrutamiento, debido a la necesidad de almacenar más agua para una mejor representación de la respuesta lenta. Por otra parte, las soluciones que maximizan KGE' condujeron a capacidades de almacenamiento más bajas, lo que indica que esta función objetivo favorece principalmente a una respuesta más rápida (caudales altos). Finalmente, para la solución de mejor compromiso, se observa que la capacidad máxima del estanque de producción se ubica en un punto intermedio al valor de las soluciones anteriores, estando más cercano a la mediana de todos los valores del frente de Pareto; mientras que la capacidad máxima del estanque de producción toma casi el mismo valor que el de la solución con mejor KGE'.

Las curvas de duración de caudales medios diarios durante el periodo de calibración dejaron en evidencia que para caudales medios-bajos existe una importante incerteza en las simulaciones. En este caso, la solución con mejor KGE' es la que más subestimó los valores observados, mientras que el iNSE logró representar de mejor forma caudales de menor magnitud. Para los caudales altos sucede lo opuesto pues, en este caso, la solución con mejor iNSE es la que más subestimó los valores observados, y la solución con mejor KGE' logró ajustarse mejor. Lo más relevante en estos resultados es que la solución de compromiso logra un buen ajuste tanto para caudales medios-bajos como para caudales altos. Finalmente, al evaluar los resultados en periodo de verificación, la solución de compromiso logró mantener un adecuado desempeño de caudales medios-bajos y altos.

Considerando las desfavorables condiciones hídricas que han pasado a prevalecer a nivel nacional y la meta de implementar en el mediano plazo una gestión de los recursos hídricos en todos los niveles, es razonable pensar que la obtención de modelos hidrológicos robustos comenzará a tener un mayor protagonismo en la toma de decisiones. En particular, el uso de métodos que sean capaces de identificar soluciones que permitan compatibilizar múltiples objetivos que no pueden ser satisfechos simultáneamente.

AGRADECIMIENTOS

Este trabajo agradece a los proyectos ANID PCI NSFC 190018 (*Management of global change impacts on hydrological extremes by coupling remote sensing data and an interdisciplinary modelling approach*) y ANID Fondecyt 1212071 (*The catchment's memory: understanding how hydrological extremes are modulated by antecedent soil moisture conditions in a warmer climate*).

REFERENCIAS

- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., & Wood, E. F. (2018). Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific Data* 2018 5:1, 5(1), 1–12.
- Bergström, S., & Forsman, A. (1973). Development of a conceptual deterministic rainfall-runoff model. *Hydrology Research*, 4(3), 147–170.
- Boisier, J. P., Alvarez-Garretón, C., Cepeda, J., Osses, A., Vásquez, N., & Rondanelli, R. (2018). CR2MET: A high-resolution precipitation and temperature dataset for hydroclimatic research in Chile. *EGUGA*, 20, 19739.
- Coello, C. A. C. (2003). Evolutionary Multi-Objective Optimization: A Critical Review. *Evolutionary Optimization*, 117–146.
- Craig, J. R., Brown, G., Chlumsky, R., Jenkinson, R. W., Jost, G., Lee, K., Mai, J., Serrer, M., Sgro, N., Shafii, M., Snowdon, A. P., & Tolson, B. A. (2020). Flexible watershed simulation with the Raven hydrological modelling framework. *Environmental Modelling & Software*, 129, 104728.
- Deb, K. (2011). Multi-objective Optimisation Using Evolutionary Algorithms: An Introduction. *Multi-Objective Evolutionary Optimisation for Product Design and Manufacturing*, 3–34.
- DGA. (2004). Cuenca del Río Toltén. <https://mma.gob.cl/wp-content/uploads/2017/12/Tolten.pdf>
- Duan, Q., Sorooshian, S., & Gupta, V. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, 28(4), 1015–1031.
- Farina, M., & Amato, P. (2002). On the optimal solution definition for many criteria optimization problems. *Annual Conference of the North American Fuzzy Information Processing Society - NAFIPS*, 2002, 233–238.
- Fowler, K., Peel, M., Western, A., & Zhang, L. (2018). Improved Rainfall-Runoff Calibration for Drying Climate: Choice of Objective Function. *Water Resources Research*, 54(5), 3392–3408.
- Gunantara, N. (2018). A review of multi-objective optimization: Methods and its applications. *Cogent Engineering*, 5(1), 1–16.
- 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.
- Hargreaves, G. H., & Samani, Z. A. (1985). Reference Crop Evapotranspiration from Temperature. *Applied Engineering in Agriculture*, 1(2), 96–99.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, 1942–1948.
- Kling, H., Fuchs, M., & Paulin, M. (2012). Runoff conditions in the upper Danube basin under an ensemble of climate change scenarios. *Journal of Hydrology*, 424–425, 264–277.
- Le Moine, N. (2008). Le bassin versant de surface vu par le souterrain: une voie d'amélioration des performances et du réalisme des modèles pluie-débit ? [Doctorat Géosciences et Ressources Naturelles].
- Lin, Q., Li, J., Du, Z., Chen, J., & Ming, Z. (2015). A novel multi-objective particle swarm optimization with multiple search strategies. *European Journal of Operational Research*, 247(3), 732–744.

- Lin, Q., Liu, S., Zhu, Q., Tang, C., Song, R., Chen, J., Coello, C. A. C., Wong, K.-C., & Zhang, J. (2018). Particle Swarm Optimization With a Balanceable Fitness Estimation for Many-Objective Optimization Problems. *IEEE Transactions on Evolutionary Computation*, 22(1), 32–46.
- Marinao-Rivas, R., & Zambrano-Bigiarini, M. (2021). Towards best default configuration settings for NMPSO in multi-objective optimisation. 2021 IEEE Latin American Conference on Computational Intelligence. (*Accepted*).
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I — A discussion of principles. *Journal of Hydrology*, 10(3), 282–290.
- Perrin, C., Michel, C., & Andréassian, V. (2003). Improvement of a parsimonious model for streamflow simulation. *Journal of Hydrology*, 279(1–4), 275–289.
- Pool, S., Vis, M., & Seibert, J. (2018). Evaluating model performance: towards a non-parametric variant of the Kling-Gupta efficiency, 63(13–14), 1941–1953.
- Pushpalatha, R., Perrin, C., Moine, N. Le, & Andréassian, V. (2012). A review of efficiency criteria suitable for evaluating low-flow simulations. *Journal of Hydrology*, 420–421, 171–182.
- R Core Team. (2021). R: A Language and Environment for Statistical Computing. <https://www.r-project.org/>
- Singh, V. P. (2018). Hydrologic modeling: progress and future directions. *Geoscience Letters*, 5, 15.
- Tolson, B. A., & Shoemaker, C. A. (2007). Dynamically dimensioned search algorithm for computationally efficient watershed model calibration. *Water Resources Research*, 43(1), 1413.
- Valéry, A. (2010). Modélisation précipitations débit sous influence nivale : Elaboration d'un module neige et évaluation sur 380 bassins versants [Doctorat Hydrobiologie, Institut des Sciences et Industries du Vivant et de l'Environnement AgroParisTech].
- Yapo, P. O., Gupta, H. V., & Sorooshian, S. (1998). Multi-objective global optimization for hydrologic models. *Journal of Hydrology*, 204(1–4), 83–97.
- Zambrano-Bigiarini, M., & Rojas, R. (2013). A model-independent Particle Swarm Optimisation software for model calibration. *Environmental Modelling & Software*, 43, 5–25.
- Zhao, Y., Feng, D., Yu, L., Wang, X., Chen, Y., Bai, Y., Hernández, H. J., Galleguillos, M., Estades, C., Biging, G. S., Radke, J. D., & Gong, P. (2016). Detailed dynamic land cover mapping of Chile: Accuracy improvement by integrating multi-temporal data. *Remote Sensing of Environment*, 183, 170–185.