

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXVI CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

HACIA MEJORES PRONÓSTICOS ESTACIONALES EN CUENCAS DE MONTAÑA: IMPACTO DE LA FUNCIÓN OBJETIVO EN LA CALIBRACIÓN DE MODELOS HIDROLÓGICOS

DIEGO ARAYA REYDET¹
PABLO MENDOZA²
EDUARDO MUÑOZ-CASTRO³
JAMES MCPHEE⁴

RESUMEN

Los métodos dinámicos son ampliamente utilizados para generar pronósticos estacionales de caudal, y se apoyan en modelos hidrológicos que requieren de la calibración de sus parámetros. En este trabajo, se investiga cómo la elección de la función objetivo utilizada para la calibración afecta la calidad de los pronósticos estacionales (primavera-verano) generados con el método de predicción de caudales por conjuntos (ESP, por sus siglas en inglés). Además, se exploran conexiones entre el desempeño del pronóstico y la consistencia hidrológica de las simulaciones para cada conjunto de parámetros. Con este fin, se calibraron tres modelos hidrológicos conceptuales (GR4J, TUW y Sacramento) utilizando 12 funciones objetivo diferentes, dentro de las cuales se incluyen métricas estacionales enfocadas en los errores durante el período de deshielo. Con ello, se generaron pronósticos en retrospectiva para cinco tiempos de inicialización durante un período de 33 años en 22 cuencas de alta montaña ubicadas en Los Andes Semiáridos (28°-37°S). Los resultados muestran que la elección de la función objetivo se vuelve relevante a medida que comienza la temporada de invierno (acumulación de nieve a comienzos de julio). La comparación de los pronósticos obtenidos a partir de diferentes métricas de calibración muestra que la consistencia hidrológica no garantiza pronósticos satisfactorios con el método ESP, y que los pronósticos satisfactorios con ESP no están necesariamente asociados a simulaciones de modelos hidrológicamente consistentes. Entre las opciones exploradas en este estudio, una función objetivo que combina la Eficiencia de Kling-Gupta (KGE) y la Eficiencia de Nash-Sutcliffe (NSE) con caudales en el espacio logarítmico ofrece el mejor compromiso entre simulaciones hidrológicamente consistentes y un rendimiento aceptable en el pronóstico.

¹ Ingeniero Civil, Advanced Mining Technology Center, U. de Chile - email: diego.araya.r@uchile.cl

² Profesor Asociado, Departamento de Ingeniería Civil, U. de Chile – email: pamendoz@uchile.cl

³ Ingeniero Civil, MSc., Departamento de Ingeniería Civil, U. de Chile – email: eduardo.munoz@uchile.cl

⁴ Profesor Titular, Departamento de Ingeniería Civil, U. de Chile – email: jmcphée@uchile.cl

1. INTRODUCCIÓN

Los pronósticos estacionales de caudal contribuyen a mejorar la gestión y planificación a largo plazo de los recursos hídricos, incluyendo el suministro de agua para consumo humano, riego, generación de energía hidroeléctrica, industria y operaciones mineras. Por lo tanto, mejorar la calidad de estos productos es un desafío continuo para la comunidad hidrológica, especialmente en regiones donde se espera que el riesgo y la gravedad de las sequías aumenten bajo los escenarios de cambio climático (Cook et al., 2022).

En la mayoría de los casos, la generación de pronósticos de caudal involucra el uso de modelos hidrológicos, los cuales son alimentados con distintas variables meteorológicas (como precipitación, temperatura del aire, entre otros). Existe una gran cantidad de modelos hidrológicos para diversos propósitos (e.g., pronósticos estacionales, planificación de riego, control de inundaciones), los cuales suelen requerir de la especificación de sus parámetros (e.g., calibración) para simular adecuadamente variables de interés (e.g., Fowler et al., 2018; Muñoz-Castro et al., 2023).

En cuanto a la calibración de modelos hidrológicos y, en particular, de modelos para generar pronósticos estacionales de caudales, la eficiencia de Nash-Sutcliffe (NSE; Nash y Sutcliffe, 1970) es una opción común en estrategias con un objetivo único (Sabzipour et al., 2021). Otra opción popular es la eficiencia de Kling-Gupta (KGE; Gupta et al., 2009), que se ha aplicado a caudales transformados (e.g., Harrigan et al., 2018).

A pesar de que la elección de la métrica de calibración es un tema importante en la literatura hidrológica, en el caso particular de los pronósticos estacionales su estudio ha sido limitado. Por lo tanto, el objetivo de este trabajo es evaluar los pronósticos estacionales de caudal generados con el método *Ensemble Streamflow Prediction* (ESP; Day, 1985) utilizando tres modelos hidrológicos calibrados con 12 métricas que pertenecen a diferentes familias de funciones objetivo.

2. ZONA DE ESTUDIO Y DATOS

La zona de estudio abarca 22 cuencas ubicadas en el centro de Chile (28°-37°S, 70°-71°O), área donde se concentra más del 60% de la población del país y, por lo tanto, muchas actividades socioeconómicas que dependen de la disponibilidad de agua. Las cuencas seleccionadas están incluidas en el conjunto de datos de CAMELS-CL (Alvarez-Garreton et al., 2018) y presentan un régimen hidrológico de influencia nival y cercano al natural (i.e., bajo índice de intervención humana y sin grandes extracciones de agua).

Los datos utilizados corresponden a series de tiempo diarias a escala de cuenca de precipitación, temperatura media del aire y evapotranspiración potencial (ETP) obtenidas de la base de datos CAMELS-CL, la cual además contiene información de caudales medios diarios medidos por la Dirección General de Aguas (DGA). Los datos de precipitación y temperatura provienen del producto grillado CR2MET versión 2.0 (Boisier et al., 2018) que abarca el periodo histórico de 1979 a 2020. La ETP se calcula con la fórmula propuesta por Hargreaves y Samani (1985) utilizando la temperatura promedio de la cuenca obtenida de CR2MET.

La Figura 1 muestra un conjunto de atributos para las cuencas de estudio, cuyas elevaciones y áreas promedio oscilan entre 1605 y 4275 m.s.n.m. y 81 a 4839 km², respectivamente. Se observa un marcado gradiente hidroclicmático, con valores de índice de aridez que van desde 0,5 a 7,0 (de sur a norte), y valores de precipitación y escorrentía media anual que siguen la relación inversa. No hay patrones claros en la fracción de precipitación que cae como nieve.

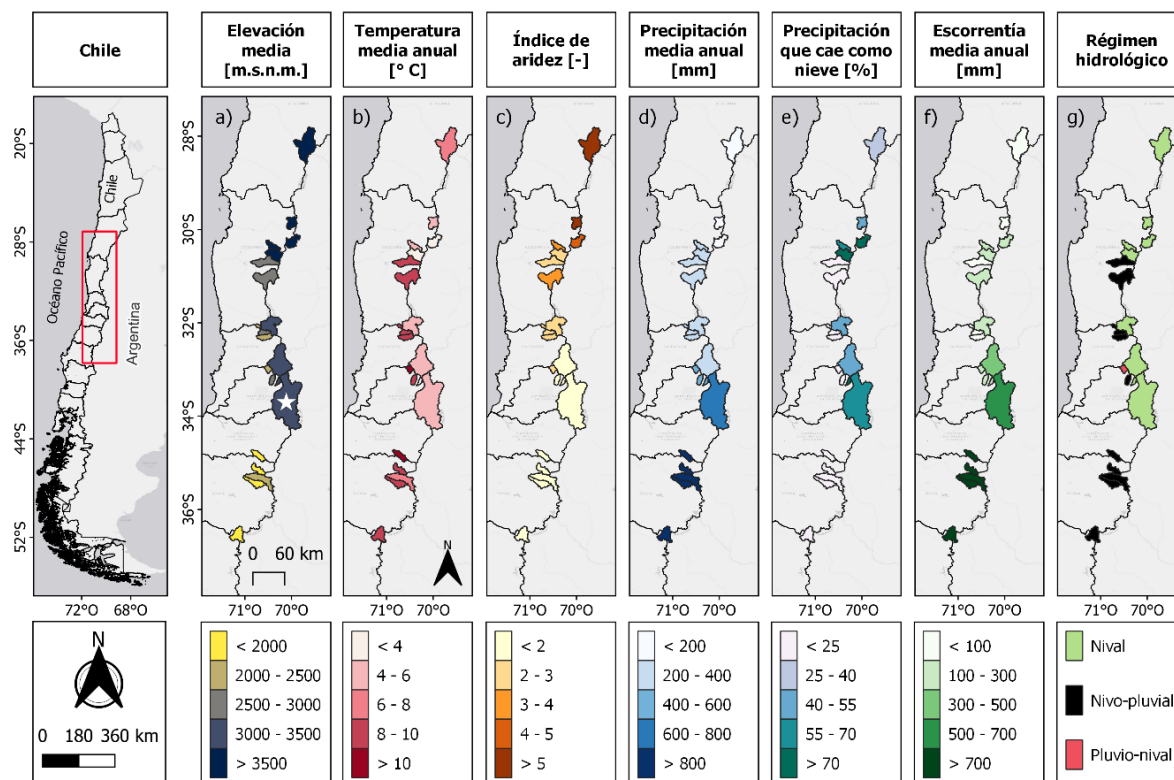


Figura 1: Ubicación y variabilidad espacial de las características de la cuenca en el área de estudio. Los atributos hidroclicmáticos se calculan entre abril/1987 - mayo/2020. La estrella blanca denota la cuenca del río Maipo en el Manzano.

3. METODOLOGÍA

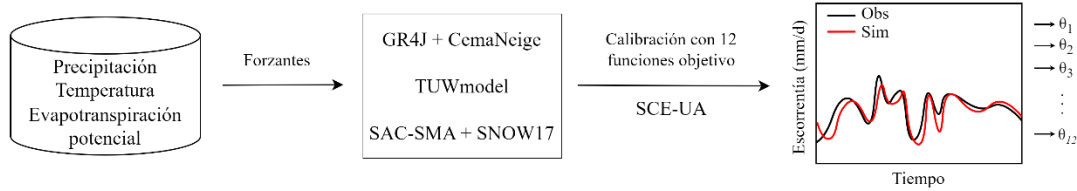
El esquema de trabajo se muestra en la Figura 2, y consta de tres pasos: (a) calibración de los parámetros de tres modelos hidrológicos (GR4J, TUV y SAC-SMA) en las 22 cuencas de la zona de estudio utilizando 12 funciones objetivo; (b) generación y evaluación del desempeño de pronósticos retrospectivos de caudal estacional (sep-mar) con el método ESP para 33 años hidrológicos (abril/1987 - marzo/2020) y cinco tiempos de inicialización; (c) evaluación de la consistencia hidrológica, mediante cinco índices hidrológicos que cuantifican el comportamiento del caudal simulado, del subconjunto de funciones objetivo con mejor desempeño en los pronósticos.

3.1. Modelación hidrológica y estrategia de calibración


Se utilizaron tres modelos hidrológicos conceptuales: (i) GR4J (Perrin et al., 2003) combinado con el módulo de nieve CemaNeige (Valéry et al., 2014b); (ii) TUV (Parajka et

al., 2007), que sigue la estructura de HBV (Bergström, 1976); y (iii) Sacramento *Soil Moisture Accounting* (SAC-SMA; Burnash et al., 1973) combinado con SNOW-17 (Anderson, 1973) y un esquema de rastreo (Lohmann et al., 1996).

(a) Configuración y calibración de los modelos hidrológicos



(b) Ensemble streamflow prediction (ESP)



(c) Determinación de funciones objetivo (FOs) robustas




Figura 2: Esquema de la metodología del trabajo.

El modelo GR4J cuenta con dos reservorios y cuatro parámetros para representar los procesos de evapotranspiración, humedad del suelo y rastreo de caudal. Está acoplado con el módulo CemaNeige (2 parámetros) que descompone la precipitación en líquida y sólida, y simula la nieve en múltiples bandas de elevación usando un esquema de derretimiento grado-día.

El modelo TUW consta de 4 rutinas: nieve (5 parámetros), donde se calcula la acumulación y derretimiento de nieve usando un esquema grado-día; humedad del suelo (3 parámetros) donde se calcula la evapotranspiración, humedad del suelo y escorrentía; respuesta (5 parámetros) con reservorios que generan escurrimiento superficial, intermedio y flujo base; y rastreo (2 parámetros) que distribuye el caudal usando una función triangular.

El modelo SAC-SMA (16 parámetros) divide la cuenca en una zona superior que simula procesos hidrológicos que ocurren en la zona radicular, superficie y atmósfera, produciendo escurrimiento superficial y directo; y una zona inferior, donde ocurre la percolación y se produce el caudal base. SAC-SMA está acoplado con el modelo conceptual de acumulación y ablación de nieve SNOW-17 (10 parámetros), que simula la acumulación y el derretimiento

de la nieve utilizando un balance energético simplificado; y con un esquema independiente de rastreo (2 parámetros), basado en la ecuación de Saint-Venant linealizada.

Todos los modelos requieren series de tiempo diarias de precipitación a escala de cuenca (P, mm), ETP (mm) y temperatura media del aire (T, °C). Se utilizaron 10 bandas de elevación para distribuir las forzantes meteorológicas con la elevación en CemaNeige, mientras que los modelos TUW y SNOW-17 se implementaron en su versión concentrada. El uso de tres modelos busca examinar en qué medida los resultados y conclusiones dependen del modelo.

Se utilizó el algoritmo de optimización global *Shuffled Complex Evolution* (SCE-UA; Duan et al., 1992) para encontrar el conjunto de parámetros óptimo con cada función objetivo. Se escogió el período abril/1994 a marzo/2013 para efectuar la calibración, considerando abril/1987 a marzo/1994 para el calentamiento del modelo (es decir, generar condiciones iniciales estables). Para cada modelo y cuenca, se realizaron 12 calibraciones utilizando las funciones objetivo de la Tabla 1. Las ocho primeras métricas (grupos 1-4) representan distintas funciones objetivo ampliamente utilizadas. Las últimas cuatro métricas de calibración están enfocadas en mejorar las simulaciones de caudales estacional. La evaluación de los modelos se realizó para el periodo de abril/1987 a marzo/1994, y el periodo de megasequía (Garreaud et al., 2019) de abril/2013 a marzo/2020, utilizando los periodos de abril/1979 a marzo/1987 y abril/2005 a marzo/2013 como calentamiento, respectivamente.

Tabla 1: Funciones objetivo utilizadas para la calibración de los modelos. El texto en negrita indica la notación utilizada en este trabajo.

Grupos de funciones objetivo	Funciones objetivo utilizadas	Descripción y características
1. Mínimos cuadrados clásico	NSE (Nash & Sutcliffe, 1970).	Variante normalizada del error cuadrático medio (MSE). Minimiza la relación entre la varianza de los caudales simulados y de los caudales observados. Es una de las métricas más utilizadas en modelación.
2. Variantes de mínimos cuadrados	KGE (Gupta et al., 2009); KGE' (Kling et al., 2012); ModKGE (Mizukami et al., 2019); KGE'' (Tang et al., 2021)	Se enfoca en optimizar tres aspectos de la serie de tiempo de caudales: variabilidad, sesgo y correlación. Al igual que la anterior, es ampliamente utilizada en modelación.
3. Funciones metaobjetivo basadas en el tiempo	Split KGE (Fowler et al., 2018). Se calcula un KGE (Gupta et al., 2009) por cada año y, luego, se promedian.	Considera diferentes subperíodos del período de calibración, en los cuales se calcula un valor de la métrica y luego se combinan en una única función metaobjetivo (por ejemplo, el promedio). Reduce la variabilidad año a año del desempeño del modelo.
4. Funciones metaobjetivo con transformación	KGE(Q)+KGE(1/Q) KGE(Q)+NSE(log(Q))	Combinación lineal de métricas de desempeño que pueden considerar transformaciones (e.g., utilizando el inverso del caudal o el logaritmo). Permite tener en cuenta simultáneamente caudales altos y bajos.
5. Funciones objetivo estacionales	RMSE Estacional (Sep-Mar) (VE-Sep); RMSE Estacional (Oct-Mar) (VE-Oct); KGE Estacional (Sep-Mar) (KGEV-Sep); KGE Estacional (Oct-Mar) (KGEV-Oct).	Los valores diarios se suman para generar una serie de tiempo anual con volúmenes de escorrentía estacionales. Luego, se minimiza la suma de los cuadrados para todos los pasos de tiempo dentro del período de calibración. Se enfoca exclusivamente en mejorar la modelación en el periodo de interés.

3.2. Generación de los pronósticos y su evaluación

Se generaron pronósticos retrospectivos de caudal para el período abril/1987 - marzo/2020 (Figura 2b), utilizando cinco tiempos de inicialización (del 1 de mayo al 1 de septiembre). Por lo tanto, para cada modelo, función objetivo, cuenca y tiempo de inicialización, se llevaron a cabo los siguientes pasos, correspondientes al método ESP:

1. Se ejecutó el modelo durante los ocho años hidrológicos anteriores al momento de inicialización t_i para obtener las condiciones hidrológicas iniciales.
2. Se utilizaron las condiciones obtenidas en el paso 1 para generar simulaciones del modelo hidrológico utilizando los datos meteorológicos observados de los 32 años hidrológicos restantes (es decir, no se utilizaron las forzantes del año a pronosticar), generando un conjunto de 32 trayectorias para el año n .
3. Se sumaron los volúmenes diarios de caudal dentro del período de interés (ventana estacional del 1 de septiembre al 31 de marzo), obteniéndose un conjunto de 32 pronósticos retrospectivos de caudal estacional para cada año.

Una vez que se completaron los pasos, se evaluaron diferentes atributos de calidad del pronóstico utilizando un conjunto de métricas determinísticas y probabilísticas (Tabla 2).

Tabla 2: Métricas de desempeño utilizadas para evaluar los pronósticos retrospectivos.

Nombre	Ecuación	Descripción
Coefficiente de determinación	$R^2 = \left(\frac{\sum_{i=1}^N (q_{m,i} - \bar{q}_m)(o_i - \bar{o})}{\sqrt{\sum_{i=1}^N (q_{m,i} - \bar{q}_m)^2} \cdot \sqrt{\sum_{i=1}^N (o_i - \bar{o})^2}} \right)^2$	Métrica determinística que varía entre [0,1] con un valor perfecto de 1. Mide la relación lineal entre el pronóstico y la observación.
Sesgo porcentual	$\%bias = \frac{\sum_{i=1}^N (q_{m,i} - o_i)}{\sum_{i=1}^N o_i} \cdot 100$	Métrica determinística que varía entre $(-\infty, \infty)$, con un valor perfecto de 0. Mide la diferencia entre la magnitud media de los pronósticos y las observaciones.
Raíz del error cuadrático medio normalizado	$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (q_{m,i} - o_i)^2}}{sd(o_i)} \cdot 100$	Métrica determinística que varía entre [0, ∞), con un valor perfecto de 0.
Puntuación de habilidad continua de probabilidad clasificada	$CRPSS = 1 - \frac{\overline{CRPS}_{fcst}}{\overline{CRPS}_{ref}}$ $CRPS = \frac{1}{N} \sum_{i=1}^N \int_{-\infty}^{\infty} [F(q) - F_o(q)]^2 dq$ $F_o(q) = \begin{cases} 0, & q < 0 \\ 1, & q > 0 \end{cases}$	Métrica probabilística que varía entre $(-\infty, 1]$, con un valor perfecto de 1. Mide la habilidad relativa del CRPS con respecto a un pronóstico de referencia (Hersbach, 2000). CRPS cuantifica la diferencia entre la función de distribución acumulada (CDF por sus siglas en inglés) del pronóstico (F) y de la observación (F_o).
Índice de confiabilidad α	$\alpha = 1 - 2 \left[\frac{1}{N} \sum_{i=1}^N P_i(o_i) - U(o_i) \right]$	Métrica probabilística que varía entre [0, 1]. Cuantifica la cercanía entre la CDF empírica de los valores p de la muestra con la CDF de una distribución uniforme. Un valor de 1 refleja una confiabilidad perfecta (Renard et al., 2010).

$q_{m,i}$: Mediana del conjunto de pronósticos para el año i

$\bar{q}_{m,i}$: Promedio de las medianas de los conjuntos

o_i : Observación del año i

\bar{o}_i : Promedio de las observaciones

$P_i(o_i)$: Probabilidad de no excedencia de o_i , usando el conjunto de pronósticos del año i

$U(o_i)$: Probabilidad de no excedencia de o_i , usando la distribución uniforme $U [0,1]$

3.3. Análisis de la consistencia hidrológica

De cada familia de funciones objetivo (Tabla 1), se seleccionó aquella que proporciona el mejor desempeño general en los pronósticos (cuantificado a través de la mediana de la muestra de cuencas) para todas las combinaciones de tiempo de inicialización, métrica de desempeño y modelo, y se evaluó su capacidad para proporcionar simulaciones de modelo hidrológicamente consistentes (Figura 2c) utilizando cinco índices hidrológicos: coeficiente de escorrentía anual (RR), que mide el balance general de la cuenca; (2) segmento de caudales altos de la CDF (FHV), mide la reacción de la cuenca a eventos de precipitación de grandes magnitudes; (3) segmento de caudales bajos de la CDF (FLV), mide los procesos lentos; (4) segmento medio de la CDF (FMS), mide la velocidad de respuesta de la cuenca a los eventos de precipitación; (5) mediana de la CDF (FMM), mide los caudales medianos de la cuenca.

El objetivo de este análisis es explorar hasta qué punto la calidad de los pronósticos de caudal estacional, logrados con una función objetivo específica de calibración, está relacionada con la capacidad del modelo para reproducir otros aspectos del comportamiento hidrológico observado.

4. RESULTADOS

4.2. Impacto de la elección de la función objetivo en el desempeño de los pronósticos

La Figura 3 muestra los resultados de CRPSS de los pronósticos para las 22 cuencas y todos los tiempos de inicialización, utilizando los tres modelos hidrológicos y los valores de parámetros obtenidos con 12 funciones objetivo. En general, las funciones objetivo estacionales (cajas de color celeste) proporcionan los valores medios más altos para 57 de las 75 combinaciones (3 modelos x 5 métricas de desempeño de la Tabla 2 x 5 tiempos de inicialización). Por otro lado, KGE(Q)+KGE(1/Q) y Split KGE generalmente producen las peores métricas de desempeño para todos los modelos hidrológicos.

Es importante señalar que algunas funciones objetivo, como las enfocadas en volumen estacional, generan un desempeño similar para todas las cuencas, mientras que otras, como KGE(Q)+KGE(1/Q), presentan una gran dispersión en los valores de desempeño. Es interesante notar que la dispersión entre cuencas aumenta con el tiempo de inicialización, siendo más pronunciada para los pronósticos emitidos el 1 de septiembre.

Para los pronósticos inicializados antes del 1 de julio, cuando la influencia de las condiciones iniciales es baja, la elección de la métrica de calibración es menos relevante (i.e., no hay diferencias significativas entre los conjuntos de funciones objetivo). En función de estos resultados y en análisis adicionales con el sesgo porcentual, el índice α , R^2 y NRMSE (no

mostradas), se selecciona la mejor función objetivo (representativa) de cada familia para análisis posteriores, que son: NSE, ModKGE, Split KGE, VE-Sep y KGE(Q)+NSE(log(Q)).

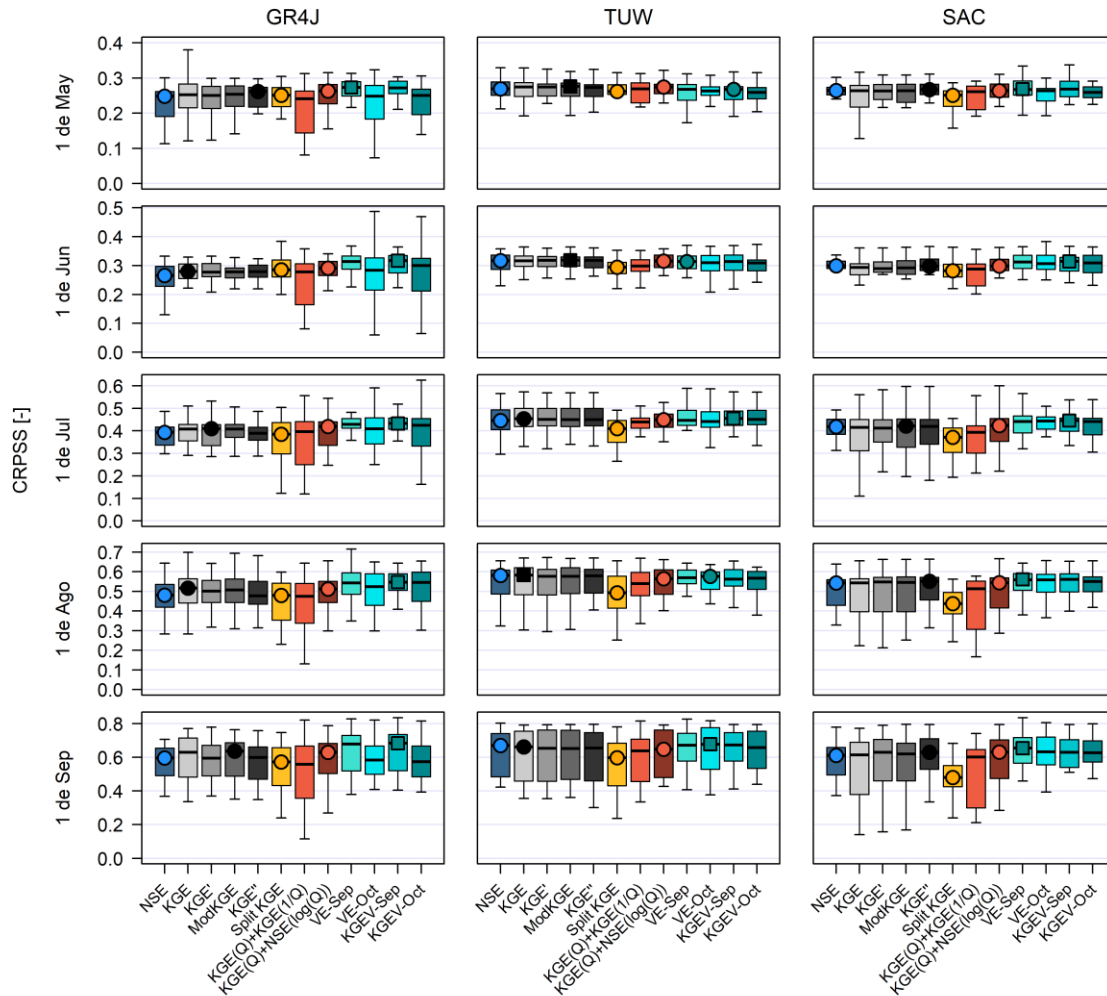


Figura 3: Comparación de CRPSS obtenidos con diferentes funciones objetivo. Cada panel contiene resultados para una combinación específica de tiempo de inicialización (filas) y modelo hidrológico (columnas), y cada diagrama de caja incluye los resultados de las 22 cuencas de estudio. El círculo indica la función objetivo que proporciona la mediana más alta dentro de cada familia de métricas de calibración (identificadas con diferentes colores), y el cuadrado indica la función objetivo que ofrece el mejor conjunto de valores métricos utilizando una combinación específica de tiempo de inicialización y modelo hidrológico.

La Figura 4 ilustra la influencia del tiempo de inicialización en los atributos de calidad del pronóstico cuando se utiliza NSE como métrica de calibración y el modelo TUW. El CRPSS y R^2 (el índice α) mejoran (empeoran) a medida que las fechas de inicialización de los pronósticos se acercan al 1 de septiembre, con incrementos considerables en el desempeño para los pronósticos del 1 de julio en comparación con los del 1 de mayo y del 1 de junio. Este resultado ilustra que la información de la acumulación de nieve recolectada a fines del otoño y principios del invierno es crucial para maximizar la predictibilidad a partir de las condiciones hidrológicas iniciales en las cuencas andinas.

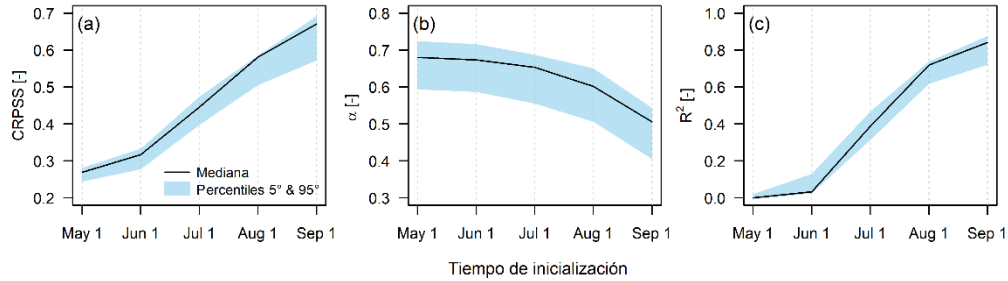


Figura 4: Impacto del tiempo de inicialización en las métricas de desempeño de los pronósticos para la función objetivo NSE y el modelo TUW. Las sombras representan los percentiles 5 y 95 de las 22 cuencas de estudio y la línea sólida es la mediana de cada métrica.

4.2. Calidad de los pronósticos estacionales y consistencia hidrológica

La Figura 5 muestra los sesgos en los índices hidrológicos obtenidos con las cinco métricas de calibración representativas para todas las cuencas y para el modelo TUW. Aunque no hay una única mejor función objetivo para los índices examinados, hay patrones interesantes que se repiten en los tres modelos:




Figura 5: Sesgo porcentual en los índices hidrológicos para el modelo TUW y las cinco funciones objetivo representativas, para el periodo de calibración (fila superior, abril/1994 – marzo/2013) y el periodo de evaluación (fila inferior, abril/1987 - marzo/1994 y abril/2013 - marzo/2020).

1. Las funciones objetivo que generan el peor balance hídrico general (RR) son Split KGE y VE-Sep para el período de calibración (fila superior). Sin embargo, durante el

- período de evaluación (fila inferior), Split KGE es una de las mejores, mientras que VE-Sep sigue siendo la peor.
2. ModKGE es la función objetivo que mejor representa los volúmenes de caudal altos (FHV) para el período de calibración, aunque es una de las peores, junto con VE-Sep, en el período de evaluación.
 3. ModKGE y VE-Sep son las funciones que peor representan los volúmenes de caudal bajos (FLV), mientras que KGE(Q)+NSE(log(Q)) y Split KGE lo hacen mejor.
 4. Split KGE es la función que mejor representa la velocidad respuesta de la cuenca (FMS), mientras que ModKGE y VE-Sep son las peores tanto para el período de calibración como para el de evaluación.
 5. KGE(Q)+NSE(log(Q)) y Split KGE son las funciones que mejor representan los caudales medios (FMM), mientras que VE-Sep es la peor.

La Figura 6 muestra las variaciones en CRPSS (Δ CRPSS) utilizando VE-Sep como referencia, para los pronósticos inicializados el 1 de septiembre. Se observa que Split KGE (una de las funciones objetivo con la mayor consistencia hidrológica) produce un rendimiento en pronóstico significativamente más bajo que la referencia (mediana de Δ CRPSS ~ -0.1 para GR4J y TUW y mediana de Δ CRPSS ~ -0.2 para SAC), mientras que ModKGE y KGE(Q)+NSE(log(Q)) producen medianas cercanas a Δ CRPSS ~ 0 para los tres modelos.

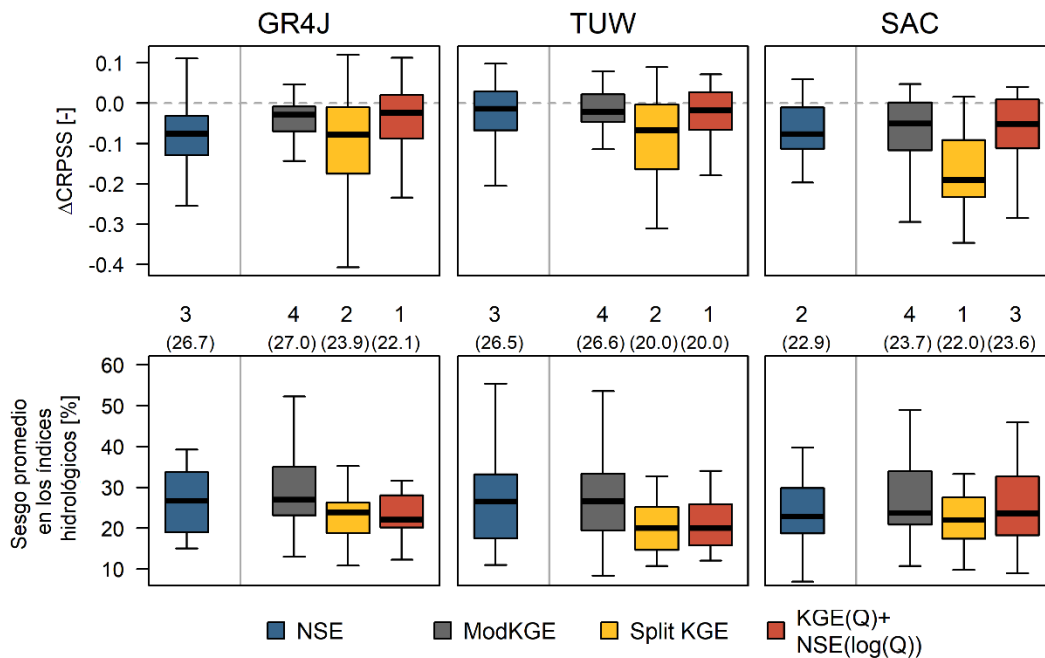


Figura 6: Variación en el CRPSS de los pronósticos al escoger una métrica con mayor consistencia hidrológica, con respecto a VE-Sep (mejor rendimiento en pronósticos).

Se observa que NSE produce un rendimiento más bajo que ModKGE y KGE(Q)+NSE(log(Q)) en términos de pronóstico, mientras que, en términos de consistencia hidrológica, más alto que ModKGE pero más bajo que KGE(Q)+NSE(log(Q)). Es interesante notar que KGE(Q)+NSE(log(Q)) ofrece un buen compromiso entre estas dos características. Los resultados revelan que existen compensaciones entre la calidad de los pronósticos y la consistencia hidrológica de las simulaciones del modelo. Aunque las métricas estacionales

produjeron buenos rendimientos en pronósticos, no garantizaron consistencia hidrológica. Las métricas meta-temporales (Split-KGE) o con transformaciones ($KGE(Q)+NSE(\log(Q))$) lograron mejor consistencia. Estos resultados resaltan el riesgo de configurar modelos para un propósito específico sin darle importancia a la representación de características que pueden ser útiles para otras aplicaciones operacionales.

5. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo, se obtuvieron importantes resultados utilizando el método ESP con tres modelos hidrológicos conceptuales y 12 funciones objetivos para generar pronósticos estacionales de caudal de primavera/verano en 22 cuencas en el centro de Chile, donde la nieve juega un papel clave en el ciclo hidrológico. Las principales conclusiones son:

1. La elección de la métrica de calibración produce diferencias significativas en la calidad del pronóstico (excepto R^2) para inicializaciones durante los meses de invierno. Este efecto disminuye considerablemente para los pronósticos inicializados durante la temporada de otoño (mayo y junio).
2. La comparación de pronósticos estacionales obtenidos a partir de diferentes familias de funciones objetivo reveló que la consistencia hidrológica no garantiza pronósticos satisfactorios de ESP estacionales (por ejemplo, Split KGE), y que los pronósticos satisfactorios de ESP no están necesariamente asociados a un conjunto de parámetros hidrológicamente consistentes (por ejemplo, VE-Sep).
3. Se identificó una función objetivo ($KGE(Q)+NSE(\log(Q))$) que proporciona un equilibrio razonable entre la consistencia hidrológica y el desempeño del pronóstico.

Los resultados presentados aquí, disponibles para su descarga en la base de datos Zenodo (Araya et al., 2023), resaltan la importancia de la calibración de modelos hidrológicos para generar pronósticos hidrológicos de calidad y obtener conclusiones sólidas sobre la predictibilidad hidrológica. Mejorar las estrategias de estimación de parámetros beneficiaría no sólo a los sistemas que dependen de métodos dinámicos, sino también a una variedad de enfoques híbridos diseñados para aprovechar la información de las salidas de los modelos hidrológicos. Este trabajo contribuye al esfuerzo continuo para mejorar la precisión y confiabilidad de los pronósticos de caudal en dominios influenciados por la nieve, con el fin de respaldar decisiones de gestión de recursos hídricos.

Dadas las fuertes relaciones entre la hidrología a escala de cuenca en este dominio y algunos patrones climáticos a gran escala, futuras investigaciones deberían explorar el potencial de técnicas de post-procesamiento que aprovechen la información climática para mejorar la calidad del pronóstico. También, los análisis de generación y evaluación de pronósticos presentados deberían extenderse a las estaciones de otoño e invierno, que son relevantes para el suministro de agua doméstica y otras aplicaciones.

AGRADECIMIENTOS

Pablo A. Mendoza recibió financiamiento del Proyecto Fondecyt 11200142. J. McPhee y P.A. Mendoza recibieron financiamiento del Proyecto CONICYT/PIA AFB180004.

REFERENCIAS

- Alvarez-Garreton, C., Mendoza, P. A., Pablo Boisier, J., Addor, N., Galleguillos, M., Zambrano-Bigiarini, M., Lara, A., ... y Ayala, A. (2018). The CAMELS-CL dataset: Catchment attributes and meteorology for large sample studies-Chile dataset, *Hydrol. Earth Syst. Sci.*, 22(11).
- Anderson, E. (1973). National Weather Service River Forecast system - snow accumulation and ablation model, NOAA Tech. Memo. NWS HYDRO-17, 217.
- Araya, Diego, Mendoza, Pablo A., McPhee, James, y Muñoz-Castro, Eduardo. (2023). A hydrological modeling dataset for ensemble streamflow forecasting in 22 snow-influenced basins in Central Chile. <https://doi.org/10.5281/zenodo.7853556>
- Bergström, S. (1976). Development and application of a conceptual runoff model for Scandinavian catchments, Report RHO 7, SMHI, Norrköping, Sweden.
- Boisier, J. P., Alvarez-Garretón, C., Cepeda, J., Osses, A., Vásquez, N. y Rondanelli, R. (2018) CR2MET: A high-resolution precipitation and temperature dataset for hydroclimatic research in Chile.
- Burnash, R., Ferral, R. y McGuire, R. (1973) A generalized streamflow simulation system - Conceptual modeling for digital computers, Sacramento, California.
- Cook, B. I., Smerdon, J. E., Cook, E. R., Williams, A. P., Anchukaitis, K. J., Mankin, ... y Wise, E. K. (2022). Megadroughts in the Common Era and the Anthropocene, *Nat. Rev. Earth Environ.*, 3(11), 741–757.
- Day, G. N. (1985). Extended Streamflow Forecasting Using NWSRFS, *J. Water Resour. Plan. Manag.*, 111(2).
- Duan, Q., Sorooshian, S. y Gupta, V. (1992). Effective and Efficient Global Optimization for Conceptual Rainfall-Runoff Models, *Water Resour. Res.*, 28(4), 1015–1031.
- Fowler, K., Peel, M., Western, A. y Zhang, L. (2018). Improved Rainfall-Runoff Calibration for Drying Climate: Choice of Objective Function, *Water Resour. Res.*, 54(5), 3392–3408.
- Garreaud, R. D., Boisier, J. P. P., Rondanelli, R., Montecinos, A., Sepúlveda, H. H. H. y Veloso-Aguila, D. (2019). The Central Chile Mega Drought (2010–2018): A climate dynamics perspective, *Int. J. Climatol.*
- Gupta, H. V., Kling, H., Yilmaz, K. K. y Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling, *J. Hydrol.*, 377(1–2).
- Hargreaves, G. H. y Samani, Z. A. (1985). Reference Crop Evapotranspiration from Temperature, *Appl. Eng. Agric.*, 1(2), 96–991985.
- Harrigan, S., Prudhomme, C., Parry, S., Smith, K. y Tanguy, M. (2018). Benchmarking ensemble streamflow prediction skill in the UK, *Hydrol. Earth Syst. Sci.*, 22(3), 2023–2039.
- Hersbach, H. (2000). Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems, *Weather Forecast.*, 15(5), 559–570.
- Lohmann, D., Nolte-Holube, R. y Raschke, E. (1996). A large scale horizontal routing model to be coupled to land surface parametrization schemes, *Tellus*, 48A(5), 708–721.
- Muñoz-Castro, E., Mendoza, P., Vásquez, N. y Vargas, X. (2023). Exploring parameter (dis)agreement due to calibration metric selection in conceptual rainfall–runoff models, *Hydrological Sciences Journal*.
- Mizukami, N., Rakovec, O., Newman, A. J., Clark, M. P., Wood, A. W., Gupta, H. V. y Kumar, R. (2019). On the choice of calibration metrics for “high-flow” estimation, *Hydrol. Earth Syst. Sci.*, 23(6), 2601–2614.
- Nash, J. y Sutcliffe, J. (1970). River flow forecasting through conceptual models part I - A discussion of principles, *J. Hydrol.*, 10(3), 282–290.
- Parajka, J., Merz, R. y Blöschl, G. (2007). Uncertainty and multiple objective calibration in regional water balance modelling: case study in 320 Austrian catchments, *Hydrol. Process.*, 21(4), 435–446.
- Perrin, C., Michel, C. y Andréassian, V. (2003). Improvement of a parsimonious model for streamflow simulation, *J. Hydrol.*, 279(1–4), 275–289.
- Renard, B., Kavetski, D., Kuczera, G., Thyer, M. y Franks, S. W. (2010). Understanding predictive uncertainty in hydrologic modeling: The challenge of identifying input and structural errors, *Water Resour. Res.*, 46(5).
- Sabzipour, B., Arsenault, R. y Brissette, F. (2021) Evaluation of the potential of using subsets of historical climatological data for ensemble streamflow prediction (ESP) forecasting, *J. Hydrol.*, 595, 125656.
- Taner, M. (2019). sacsmaR: SAC-SMA Hydrology Model, R Package version 0.0.1 [online] Available from: <https://github.com/tanerumit/sacsmaR>, 2019.
- Tang, G., Clark, M. P. y Papalexiou, S. M. (2021). SC-earth: A station-based serially complete earth dataset from 1950 to 2019, *J. Clim.*, 34(16), 6493–6511.
- Valéry, A., Andréassian, V. y Perrin, C. (2014). ‘As simple as possible but not simpler’: What is useful in a temperature-based snow-accounting routine? Part 2 – Sensitivity analysis of the Cemaneige snow accounting routine on 380 catchments, *J. Hydrol.*, 517(Supplement C), 1176–1187.