

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXV CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

**PRONÓSTICOS DE CAUDAL DE DESHIELO DE RANGO MEDIO EN LA
CUENCA ALTA DEL RÍO MAULE**

DIEGO HERNÁNDEZ N.¹
FRANCISCO JARA A.²
MARÍA IGNACIA ORELL F.³
PABLO MENDOZA Z.⁴
JAMES MCPHEE T.⁵

RESUMEN

La escasez de datos disponibles oportunamente en zonas cordilleranas es un problema recurrente que dificulta el desarrollo de sistemas operacionales hidrometeorológicos. En este trabajo, se aplica una metodología dependiente de productos grillados y reanálisis locales y globales, para obtener pronósticos de caudales de deshielo de rango medio (1-7 días). El sistema piloto se implementa en cuatro cuencas cordilleranas del río Maule. Este sistema se basa en (i) un set retrospectivo de series de precipitación y temperatura con enfoque de conjuntos, (ii) un modelo hidrológico precipitación-escorrentía acoplado a un módulo de nieves, a escala de cuenca y de paso de tiempo diario, (iii) series meteorológicas pronosticadas pre-procesadas, y (iv) un procedimiento de pre-selección de miembros del conjunto basado en observaciones de caudal de la semana precedente. El modelo hidrológico se calibra para el periodo 1998-2011 y se valida durante 2012-2018. La validación del modelo entrega un ajuste en torno a 0.7 y 0.6 para las métricas split-KGE y split-NSE, respectivamente, y sesgos volumétricos promedio entre -1 y 11% para los meses de octubre a marzo. El resultado final del sistema corresponde a pronósticos de volumen semanal de caudales, los cuales alcanzan sesgo promedio entre 0 y -5 %. De esta manera, la disponibilidad de productos locales y globales permite desarrollar un enfoque con resultados satisfactorios para fines operacionales, obteniendo sesgos relativamente pequeños, incluso durante condiciones de megasequía. Finalmente, el trabajo futuro está orientado a mejorar la calidad de la forzante meteorológica y a implementar técnicas de post-procesamiento de caudales.

¹ Ingeniero Civil, Advanced Mining Technology Center, U. de Chile – email: diego.hernandez.n@uchile.cl

² Ingeniero Civil, Centro Avanzado para Tecnologías del Agua, U. de Chile – email: francisco.jara@uchile.cl

³ Ingeniera en Recs. Nat. Renov., MSc. Advanced Mining Technology Center, U. de Chile – email: maria.orell@uchile.cl

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

⁵ Profesor Titular, Departamento de Ingeniería Civil, U. de Chile – email: jmcphee@uchile.cl

1. INTRODUCCIÓN

En Chile central, la nieve acumulada estacionalmente en la cordillera de los Andes constituye la principal fuente de agua. La disponibilidad de este recurso para la temporada estival depende de las condiciones hidrometeorológicas y de su gestión. En este contexto, el manejo de los recursos hídricos se hace cada vez más relevante tanto a nivel local como nacional, y es de suma importancia establecer escenarios y pronósticos de las situaciones futuras (Cornwell et al., 2016).

La agricultura en la zona centro-sur de Chile presenta requerimientos de riego en primavera y verano, que se satisfacen en gran parte con caudales de deshielo. Los pronósticos de caudales constituyen un insumo para la gestión hídrica, y podrían ayudar a los agricultores a tomar decisiones más informadas y así reducir los riesgos en la producción. Según Orell (2020), en las cuencas del río Maule y Longaví, las utilidades esperadas de los agricultores son mayores al decidir usar un modelo de pronóstico de caudales de deshielo, frente a la decisión de no utilizarlo. El costo de oportunidad es del orden de los miles de millones de pesos, y constituye un desafío para la investigación, desarrollo y actualización de los modelos.

Los pronósticos de caudales de deshielo requieren de modelos específicos y disponibilidad de datos meteorológicos (Cornwell et al., 2016). Sin embargo, la escasez de datos en zonas cordilleranas es un problema recurrente que dificulta el desarrollo de sistemas operacionales. El propósito de esta investigación es desarrollar un enfoque que dependa de productos locales y globales actualizados, obteniendo pronósticos de volúmenes semanales de deshielo que informen a los usuarios en la toma de decisiones.

2. ÁREA DE ESTUDIO Y DATOS DISPONIBLES

La gran cuenca del río Maule se encuentra en la Región del Maule, es la cuarta más extensa de Chile (superficie aproximada de 20,300 km²) y tiene una fuerte componente nival. El río Melado es tributario del río Maule a 75 km de su origen, presenta cumbres por sobre los

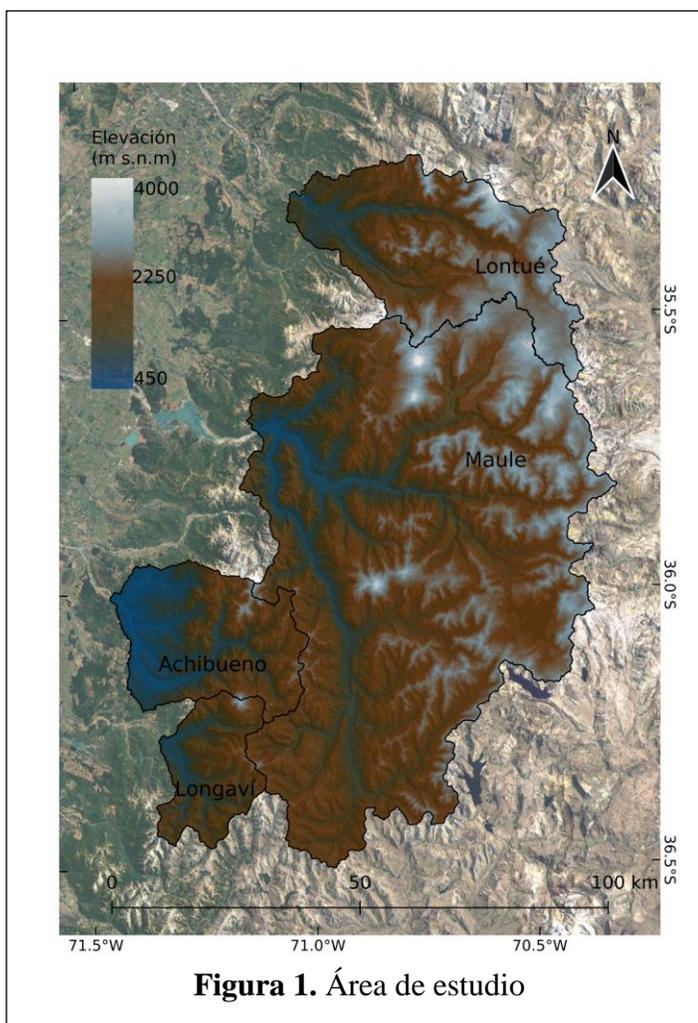


Figura 1. Área de estudio

2,500 m.s.n.m., separándolo de las cuencas de los ríos Longaví, Achibueno y Ancoa, subtributarios del Maule. Por otro lado, el río Lontué nace a 50 km al oriente de la ciudad de Curicó, con una longitud de 126 km y una hoya hidrográfica de 2,510 km². En su llegada al valle central, las cuencas de los ríos Maule y Lontué son de régimen principalmente nival, mientras que las cuencas de los ríos Longaví y Achibueno tienen un régimen pluvio-nival. La Figura 1 muestra la ubicación de las cuencas de estudio, y sus principales características fisiográficas se muestran en la Tabla 1.

Tabla 1. Principales características fisiográficas de las cuencas de estudio.

Cuenca	Área (km²)	Pendiente media (%)	Elevación promedio* (m.s.n.m.)	Elevación máxima* (m.s.n.m.)
Achibueno	890	23	1,220	3,180
Longaví	470	24	1,390	3,200
Lontué	1,370	20	2,180	4,060
Maule	5,470	21	2,190	3,950

*En base al Modelo Digital de Elevación Global Aster GDem (<https://doi.org/10.5067/ASTER/ASTGTM.003>).

Las series de caudal se obtienen desde el registro DGA para las cuencas de Achibueno en La Recova, Longaví en El Castillo y Lontué (unión de Palos antes de junta con Colorado y Colorado antes de junta con Palos). Por otro lado, las series de Maule en Armerillo se obtienen naturalizadas desde la Junta de Vigilancia, de 1998 al presente. La meteorología usada como referencia corresponde a CR2MET, producto grillado de resolución horizontal 0.5 x 0.5° (<https://www.cr2.cl/datos-productos-grillados/>), del cual se utiliza una versión modificada por subcaptación o subestimación desarrollada en el contexto de la Actualización del Balance Hídrico Nacional (DGA, 2019). Dado que CR2MET no dispone de datos en el presente, se utiliza el reanálisis ERA5 (Hersbach et al., 2020), de resolución 0.25 x 0.25°. Las series meteorológicas pronosticadas se obtienen del producto GEFS (Hamill et al., 2013). Como datos auxiliares para la calibración del modelo se utiliza un reanálisis local de nieve equivalente en agua (Cortés & Margulis, 2017), el producto de evaporación GLEAM (Martens et al., 2017) y el producto satelital de humedad de suelo ESA-CCI (Gruber et al., 2019).

3. METODOLOGÍA

3.1 Esquema general de la metodología de pronóstico

El esquema de trabajo se resume en la Figura 2, mientras que el detalle de los procedimientos se muestra en las secciones siguientes (3.2-3.5). El algoritmo de pronóstico implementado se fundamenta en el uso de productos meteorológicos de disponibilidad global, como son el reanálisis ERA5 y el pronóstico meteorológico GEFS, combinados con un modelo

hidrológico conceptual que incorpora la componente de acumulación y derretimiento nival. Para mejorar la representación del clima y meteorología local, los productos globales se pre-corrigen a partir del producto grillado CR2MET, que a su vez se basa en observaciones de estaciones meteorológicas. La incertidumbre inherente a las condiciones meteorológicas se aborda mediante un esquema de conjuntos, que se implementa mediante analógicos climáticos en el caso de la forzante histórica.

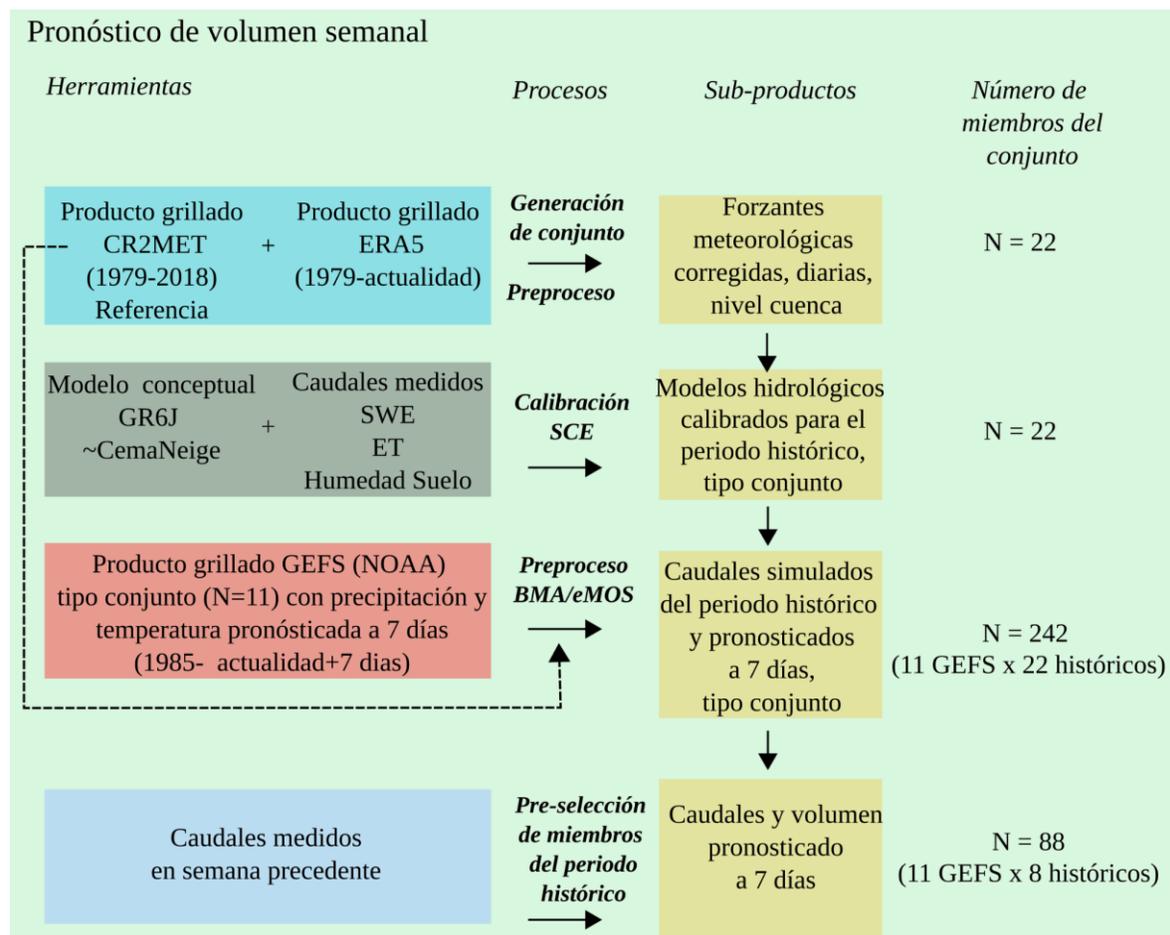


Figura 2. Esquema metodología de modelamiento

3.2 Generación de meteorología histórica tipo conjuntos

Para incorporar un enfoque probabilístico en los pronósticos de caudal, se construye la forzante meteorológica por conjuntos (*ensembles*). Esta técnica se apoya en que el estado real de la atmósfera pudiese ser distinto al señalado por las observaciones, y por tanto, resulta conveniente proponer más de un único valor de las variables por cada paso de tiempo. Para las series de ERA5 a escala de cuenca, se genera un conjunto de tamaño N según una metodología adaptada de Schefzik (2015, 2016), basada en análogos o días similares, y posterior aplicación de “Schaake Shuffle” (Clark et al., 2004) como proceso complementario que busca otorgar realismo físico a los miembros del conjunto (Vrac and Friederichs, 2015).

Al corregir la precipitación o temperatura de cierto día t de la serie ERA5, se buscan N días “similares” al día t en el registro histórico de ERA5. Como criterio de similitud, se compara la raíz del error cuadrático medio (RMSE, por sus siglas en inglés) entre la temperatura y precipitación del día t , versus la temperatura y precipitación de los días históricos. Luego, se escogen los N días similares al día t como aquellos con menor valor de RMSE. Finalmente, aplicando un procedimiento de ajuste de sesgo, cada día t de la serie de ERA5 se calibra con N días del registro histórico, generando valores corregidos por cada valor crudo de la serie de ERA5. Lo anterior permite disponer de N forzantes y , por lo tanto, N salidas del modelo hidrológico. En particular, se escoge $N=22$ según análisis exploratorios. El método de ajuste de sesgo aplicado corresponde a corrección delta por cuantiles (Cannon et al., 2015) para el caso de la temperatura. Por otro lado, primero la ocurrencia de la precipitación se corrige por regresión logística extendida heterocedástica (Messner et al.; 2013, 2014), y luego su magnitud es ajustada por corrección delta por cuantiles.

3.3 Modelación hidrológica

La modelación hidrológica emplea el modelo conceptual GR6J de paso de tiempo diario (Pushpalatha et al., 2011) definido por 6 parámetros, acoplado al módulo de nieves CemaNeige (Valéry et al., 2014) que incorpora otros 2 parámetros. Los modelos GR de escala de cuenca son forzados por temperatura media, precipitación y evapotranspiración potencial. La evapotranspiración potencial es obtenida mediante la fórmula de Oudin (Oudin et al., 2005) en función de la temperatura, y por lo tanto las forzantes meteorológicas se reducen a temperatura media y precipitación (se utilizan las series corregidas promedio del conjunto). El módulo CemaNeige discretiza la cuenca en bandas de elevación de igual área, parametrizando la precipitación y temperatura según gradientes altitudinales. En este trabajo se utilizan 100 bandas.

El registro fluviométrico (1998-2018) se divide en calibración (1998-2011) y validación (2012-2018). Lo anterior es conveniente para validar el modelo durante las condiciones de megasequía (Garreaud et al.; 2017, 2020). Las series de caudal simulado y observado se comparan según dos índices de eficiencia: *Nash-Sutcliffe Efficiency* (NSE) y *Kling-Gupta Efficiency* (KGE; Gupta et al., 2009). Los índices NSE y KGE dan cuenta de los sesgos relativos mediante una comparación gruesa entre las medias globales simulada y observada. Para dar un tratamiento estacional a los sesgos, se calcula el sesgo porcentual (pbias, por el inglés *percent bias*) para cada mes. Con lo anterior se busca incorporar la variabilidad intraanual a los criterios de calibración. La función objetivo a optimizar en la calibración utiliza métricas tipo “split”, que consiste en calcular índices para cada año hidrológico por separado, promediando luego todos los valores (Fowler et al., 2018). Lo anterior permite extraer la mayor cantidad de información de los años de calibración, lo que puede ser conveniente en regiones con gran variabilidad interanual. Como estrategia de calibración, se utiliza el algoritmo de búsqueda *Shuffled Complex Evolution* (Duan et al., 1992).

El uso de funciones multiobjetivo que consideren nieve acumulada (Riboust et al., 2019; Duethmann et al., 2020), evaporación (Dembélé et al., 2020) o humedad del suelo (Tong et al., 2020; López López et al., 2017) ha reportado una mejor representación de las variables internas de los modelos (i.e., realismo), aunque no necesariamente del caudal. Para evaluar el valor agregado, se calibra con y sin los términos asociados a nieves, evaporación y

humedad, donde los ponderadores son redistribuidos a los términos de caudal. Finalmente, la función objetivo se basa en las ponderaciones utilizadas en Duethmann et al. (2020), modificada según análisis exploratorios. Esta función se compone de un término de eficiencia y un término de sesgos mensuales, con igual peso: (I) Promedio de split-KGE de caudal, split-NSE de caudal en escala raíz cuadrada, split-NSE de caudal en escala logarítmica, split-NSE de caudal en escala inversa, split-NSE de equivalente en agua de nieves, split-KGE de evaporación, y split-KGE de humedad; (II) Para cada año, promedio de los valores absolutos de los sesgos porcentuales mensuales, luego los valores anuales son promediados.

3.4 Meteorología pronosticada pre-procesada

La meteorología pronosticada proviene del Global Ensemble Forecast System de segunda generación (GEFS; Hamill et al., 2013) con 11 miembros de conjunto. Posee una resolución de $0.5 \times 0.5^\circ$ y un registro diario desde 1985 hasta 2020.

Para el preprocesamiento se evaluaron dos metodologías: *Bayesian Model Averaging* (BMA; Raftery et al., 2005) y *Ensemble Model Output Statistics* (eMOS; Gneiting et al., 2005). Estas metodologías buscan remover errores sistemáticos y aumentar la consistencia estadística y confianza de los productos. Por un lado, BMA se basa en la utilización del teorema de Bayes, y pondera cada miembro de acuerdo a la probabilidad posterior dada una observación. Por otro lado, eMOS permite calibrar un conjunto a partir de regresiones lineales múltiples de las funciones de densidad de probabilidades, minimizando el índice *Continuous Ranked Probability Score* (CRPS; Hersbach et al., 2000). Para ambas metodologías se supuso una distribución Normal de la temperatura y Gamma truncada en cero para la precipitación.

El proceso de entrenamiento en el preprocesamiento se separa por cada cuenca, cada mes y cada tiempo de adelanto del pronóstico (1 a 7 días), en validación cruzada dejando un año fuera a la vez. La verificación mostró menores errores del pronóstico al aplicar eMOS, especialmente para la precipitación en invierno y primavera.

3.5 Pronóstico hidrológico y pre-selección de miembros del conjunto

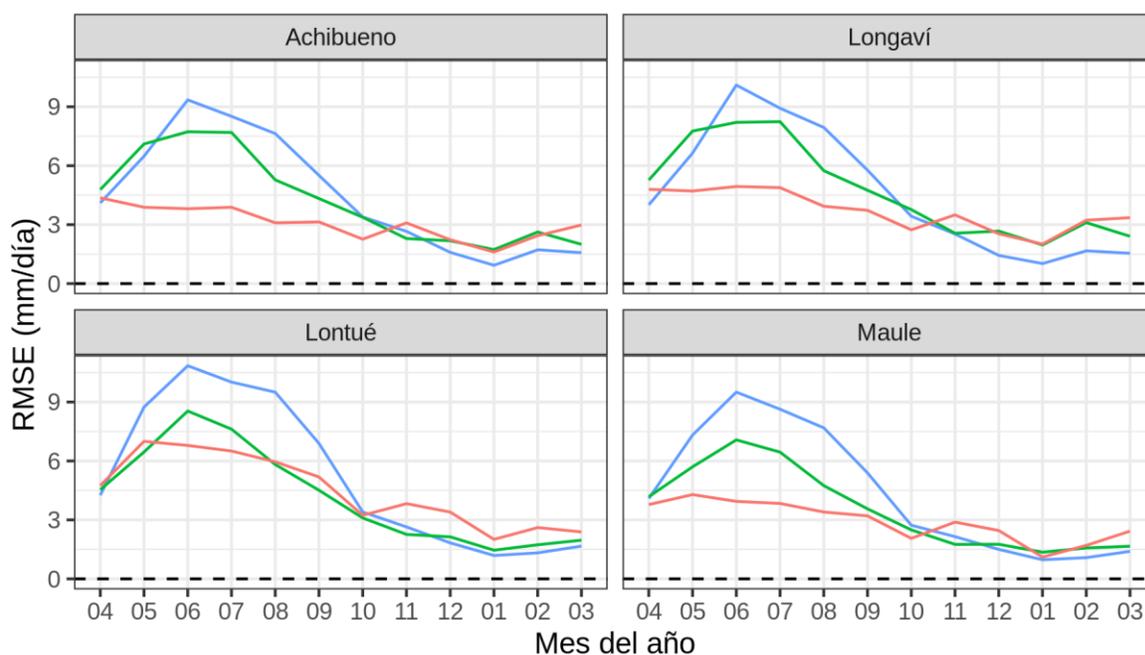
Los pronósticos de volúmenes semanales de caudal se obtienen forzando el modelo hidrológico con los pronósticos meteorológicos de 1 a 7 días concatenados, inicializado con cada una de las N condiciones iniciales simuladas según la meteorología histórica. Así, la dimensión del conjunto histórico se multiplica por la dimensión del conjunto pronosticado. Por otra parte, resulta conveniente pre-seleccionar solo aquellos miembros que representen más fielmente las condiciones hidrológicas observadas. Para este fin, en el día de emisión (día 0) se contrastan los caudales observados versus los simulados de los días -13 a -7, de acuerdo al error absoluto medio (MAE, por sus siglas en inglés). De las 22 simulaciones históricas se seleccionan solo aquellas ocho trayectorias con menor MAE. Los días más recientes (-6 a 0) son omitidos en el método por falta de disponibilidad en la situación operativa.

Para evaluar la mejora en propiedades probabilísticas (agudeza y/o calibración de las distribuciones) se utiliza el índice *Continuous Ranked Probability Skill Score* (CRPSS; Hersbach et al., 2000), cuyo rango abarca de $-\infty$ hasta 1 (0 es igual desempeño que cierta

referencia, y 1 es perfecto). Mediante análisis exploratorios, se obtuvo que pre-seleccionar los ocho de 22 miembros mejora en general las propiedades del pronóstico para los meses de octubre a marzo.

4. RESULTADOS

La Figura 3 muestra que el procedimiento de corrección de sesgo, para la precipitación histórica, funciona particularmente bien en los meses de invierno. La corrección tipo conjuntos muestra valor agregado por sobre una corrección más simple (de igual método, regresión logística y corrección delta por cuantiles, pero con un único valor de salida). Sin embargo, la corrección de sesgo no muestra beneficios durante primavera y verano, presumiblemente asociado al distinto régimen de precipitación en estas temporadas con tormentas más esporádicas.



Series — ERA5 — Corrección simple — Corrección conjuntos

Figura 3. Resultados de precipitación del producto meteorológico histórico. Los productos crudos (ERA5) y corregidos con y sin enfoque de conjuntos (“conjuntos” y “simple”, respectivamente) son comparados versus la referencia CR2MET.

Los resultados del modelo hidrológico muestran en general pocas diferencias entre la función objetivo multivariada y la basada sólo en caudal (Figura 4), por lo que en lo sucesivo se utilizan sólo los resultados de la función multivariada. Las curvas estacionales en calibración muestran observaciones más altas que en validación (validación corresponde a megasequía); además, las cuencas más nivales (Lontué y Maule) muestran una distribución bimodal en calibración y unimodal en validación (Figura 4). Los resultados de las métricas split-KGE y split-NSE son similares entre calibración y validación (Tabla 2), sin embargo, los sesgos en

general se desplazan desde negativos en calibración a positivos en validación (Tabla 2), posiblemente asociado al cambio en las condiciones climáticas.

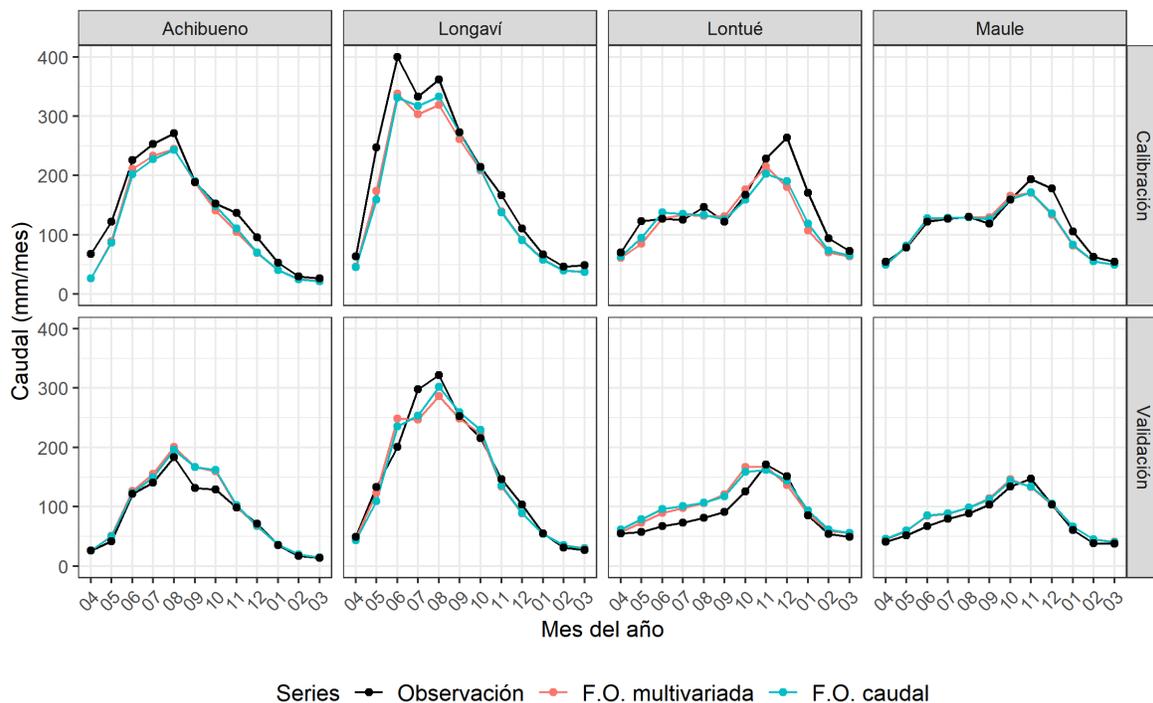


Figura 4. Ajuste estacional en calibración y validación del modelo hidrológico, utilizando dos funciones objetivo (F.O.).

Tabla 2. Índices de caudal simulado obtenidos en calibración y validación. Se muestran resultados solo para la función objetivo multivariada. O-M indica solo los meses de octubre a marzo.

Cuenca	Índice calibración (validación)			
	split-KGE	split-NSE	RMSE O-M (mm/día)	pbias O-M (%)
Achibueno	0.67 (0.68)	0.64 (0.49)	1.3 (1.0)	-15.9 (11.3)
Longaví	0.57 (0.64)	0.57 (0.58)	1.7 (1.3)	-12.1 (-1.0)
Lontué	0.60 (0.65)	0.55 (0.55)	1.9 (1.1)	-15.2 (4.4)
Maule	0.73 (0.75)	0.66 (0.67)	1.3 (0.8)	-10.2 (4.3)

Los volúmenes semanales pronosticados para Achibueno y Longaví muestran que los miembros del conjunto tienen menor dispersión entre sí, en términos relativos a la gran variabilidad observada para estas cuencas dada su respuesta rápida o pluvial (Figura 5). Los volúmenes semanales pronosticados para Achibueno y Longaví tienen un pulso concentrado en error cero, mientras que la escala del error es mayor en Longaví (Figura 6), dado que esta

cuenca presenta en general caudales específicos superiores. Por otro lado, las cuencas de Lontué y Maule muestran gran dispersión entre los miembros del conjunto. En este caso las series observadas tienen menor variabilidad (Figura 6) dado el efecto amortiguador de la nieve sobre la variabilidad de los caudales. La escala del error es mayor en Lontué que en Maule, y esta última cuenca presenta en general el mejor ajuste entre la observación y el pronóstico (Tabla 3).

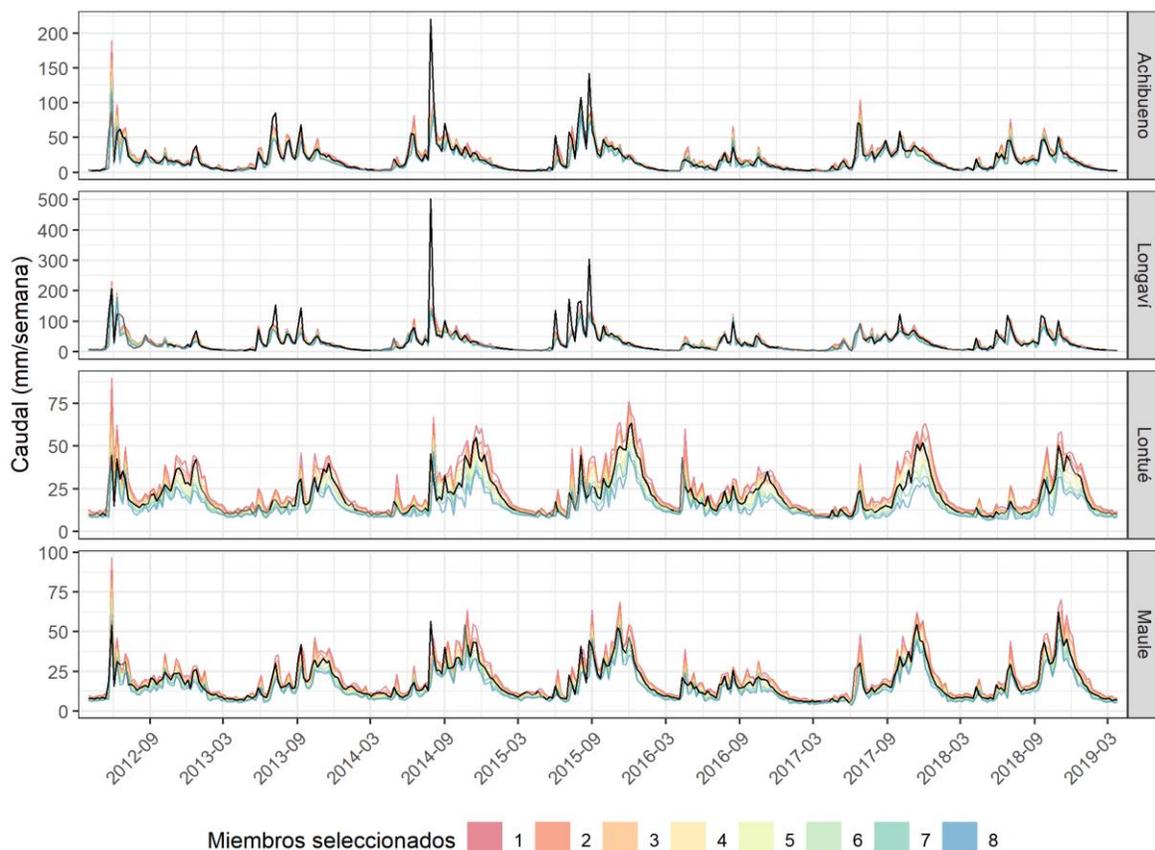


Figura 5. Hidrogramas de pronósticos de volúmenes semanales, en periodo de validación. Las líneas de color representan cada uno de los 8 miembros pre-seleccionados y la línea negra muestra el volumen observado.

Finalmente, los volúmenes semanales pronosticados muestran sesgos volumétricos promedio relativamente pequeños, de 0 a -5 %, y coeficientes de determinación altos, de 0.85 a 0.95 (Tabla 3). En cuanto al procedimiento de pre-selección de miembros, el valor de CRPSS es positivo en todos los casos (la selección mejora las propiedades probabilísticas del conjunto), con valores notables en Lontué y Maule, sugiriendo que la pre-selección es exitosa en corregir los conjuntos en las cuencas de régimen más nival.

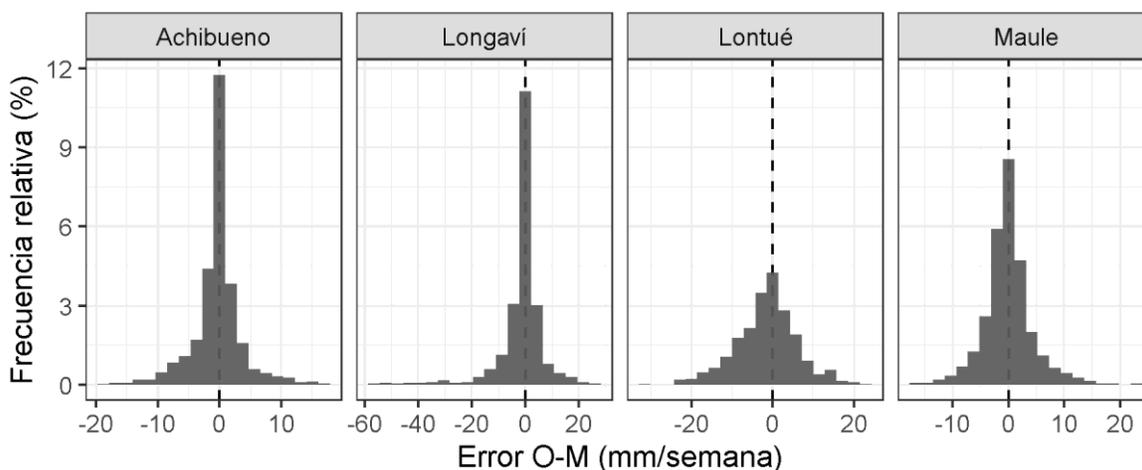


Figura 6. Histogramas de error (simulación menos observación) de pronósticos de volúmenes semanales, en periodo de validación. O-M corresponden a los meses de octubre a marzo.

Tabla 3. Validación de pronósticos semanales entre octubre y marzo (O-M). CRPSS se calcula tomando como referencia el conjunto sin pre-selección.

Cuenca	RMSE O-M (mm/semana)	pbias O-M (%)	R ² O-M	CRPSS O-M
Achibueno	3.5	-2.3	0.91	0.23
Longaví	8.3	-5.0	0.85	0.14
Lontué	2.5	-5.1	0.88	0.56
Maule	2.3	-0.3	0.95	0.49

5. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo demuestra que la combinación de productos meteorológicos de disponibilidad global (reanálisis y pronósticos meteorológicos), corregidos con base en observaciones locales y acoplados con un modelo hidrológico conceptual, son capaces de proveer predictibilidad de caudales de rango medio (escala semanal) en cuencas hidrográficas de montaña con componente nival de escorrentía. De esta manera, se alivian dos problemas acuciantes, como lo son la disponibilidad oportuna de datos observados en un contexto operacional, y la incertidumbre respecto al desempeño de modelos estadísticos en condiciones de variabilidad climática.

El trabajo futuro considera un mejoramiento en la calidad de la forzante meteorológica, debido a que el ajuste de la ocurrencia de precipitación y la aplicación de técnicas de reordenamiento como Schaake Shuffle podrían reducir el desempeño en aplicaciones hidrológicas (Van de Velde et al., 2020), así como se observa que la corrección de precipitación en primavera y verano no aporta beneficios claros en la metodología actual. Por

otro lado, en la calibración del modelo hidrológico se espera visitar la función objetivo ya que no se observa valor agregado en la incorporación del esquema multivariado. Finalmente, se considera explorar técnicas de posprocesamiento de caudales que permitan mejorar la calidad de la simulación.

AGRADECIMIENTOS

Este trabajo ha sido realizado con el aporte del proyecto CORFO 19BP-117327 y del proyecto ANID/PIA AFB180004. Además apreciamos la colaboración de las Juntas de Vigilancia del río Maule, Melado, Lontué, Achibueno, Ancoa y Longaví. Agradecemos el aporte de Tomás Gómez en el producto CR2MET corregido por subestimación, en el contexto del proyecto de Actualización del Balance Hídrico Nacional.

REFERENCIAS

- Cannon, A. J., Sobie, S. R., & Murdock, T. Q. (2015). Bias correction of GCM precipitation by quantile mapping: How well do methods preserve changes in quantiles and extremes?. *Journal of Climate*, 28(17), 6938-6959.
- Clark, M., Gangopadhyay, S., Hay, L., Rajagopalan, B., & Wilby, R. (2004). The Schaake shuffle: A method for reconstructing space-time variability in forecasted precipitation and temperature fields. *Journal of Hydrometeorology*, 5(1), 243-262.
- Cornwell, E., Molotch, N. P., and McPhee, J. (2016). Spatio-temporal variability of snow water equivalent in the extra-tropical Andes Cordillera from distributed energy balance modeling and remotely sensed snow cover. *Hydrology and Earth System Sciences*, 20(1), 411-430.
- Cortés, G., & Margulis, S. (2017). Impacts of El Niño and La Niña on interannual snow accumulation in the Andes: Results from a high-resolution 31 year reanalysis. *Geophysical Research Letters*, 44(13), 6859-6867.
- Dembélé, M., Ceperley, N., Zwart, S. J., Salvatore, E., Mariethoz, G., & Schaefli, B. (2020). Potential of satellite and reanalysis evaporation datasets for hydrological modelling under various model calibration strategies. *Advances in Water Resources*, 143, 103667.
- Dirección General de Aguas (2019). Aplicación de la metodología de actualización del balance hídrico nacional en las cuencas de la parte sur de la macrozona Austral e Isla de Pascua, SIT N° 444. Ministerio de Obras Públicas, Dirección General de Aguas, División de Estudios y Planificación, Santiago, Chile.
- Duan, Q., Sorooshian, S., & Gupta, V. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water resources research*, 28(4), 1015-1031.
- 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.
- 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.
- Gneiting, T., Raftery, A. E., Westveld, A. H., III, & Goldman, T. (2005). Calibrated Probabilistic Forecasting Using Ensemble Model Output Statistics and Minimum CRPS Estimation, *Monthly Weather Review*, 133(5), 1098-1118.
- Garreaud, R. D., Alvarez-Garreton, C., Barichivich, J., Boisier, J. P., Christie, D., Galleguillos, M., ... & Zambrano-Bigiarini, M. (2017). The 2010-2015 megadrought in central Chile: impacts on regional hydroclimate and vegetation. *Hydrology & Earth System Sciences*, 21(12).
- Garreaud, R. D., Boisier, J. P., Rondanelli, R., Montecinos, A., Sepúlveda, H. H., & Veloso-Aguila, D. (2020). The central Chile mega drought (2010–2018): a climate dynamics perspective. *International Journal of Climatology*, 40(1), 421-439.

- Gruber, A., Scanlon, T., van der Schalie, R., Wagner, W., & Dorigo, W. (2019). Evolution of the ESA CCI Soil Moisture climate data records and their underlying merging methodology. *Earth System Science Data*, *11*(2), 717-739.
- 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.
- Hamill, T. M., Bates, G. T., Whitaker, J. S., Murray, D. R., Fiorino, M., Galarneau, T. J., Jr., Zhu, Y., & Lapenta, W. (2013). NOAA's Second-Generation Global Medium-Range Ensemble Reforecast Dataset, *Bulletin of the American Meteorological Society*, *94*(10), 1553-1565.
- Hersbach, H. (2000). Decomposition of the continuous ranked probability score for ensemble prediction systems. *Weather and Forecasting*, *15*(5), 559-570.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., ... & Simmons, A. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*.
- López López, P., Sutanudjaja, E. H., Schellekens, J., Sterk, G., & Bierkens, M. F. (2017). Calibration of a large-scale hydrological model using satellite-based soil moisture and evapotranspiration products. *Hydrology and Earth System Sciences*, *21*(6), 3125-3144.
- Martens, B., Miralles, D.G., Lievens, H., van der Schalie, R., de Jeu, R.A.M., Fernández-Prieto, D., Beck, H.E., Dorigo, W.A., and Verhoest, N.E.C.: GLEAM v3: satellite-based land evaporation and root-zone soil moisture, *Geoscientific Model Development*, *10*, 1903–1925, doi: 10.5194/gmd-10-1903-2017, 2017.
- Messner, J. W., Mayr, G. J., Zeileis, A., & Wilks, D. S. (2013). *Extending extended logistic regression to effectively utilize the ensemble spread* (No. 2013-21). Working Papers in Economics and Statistics.
- Messner, J. W., Mayr, G. J., Wilks, D. S., & Zeileis, A. (2014). Extending extended logistic regression: Extended versus separate versus ordered versus censored. *Monthly Weather Review*, *142*(8), 3003-3014.
- Orell, M.I. (2020). Utilidad de pronóstico de volúmenes de deshielo en la gestión de recursos hídricos del sector agrícola de los ríos Maule y Longaví, Chile. Tesis para optar al grado de Magíster en Ciencias de la Ingeniería, mención Recursos y Medio Ambiente Hídrico. Facultad de Ciencias Físicas y Matemáticas. Universidad de Chile.
- Oudin, L., Hervieu, F., Michel, C., Perrin, C., Andréassian, V., Anctil, F., & Loumagne, C. (2005). Which potential evapotranspiration input for a lumped rainfall–runoff model?: Part 2—Towards a simple and efficient potential evapotranspiration model for rainfall–runoff modelling. *Journal of hydrology*, *303*(1-4), 290-306.
- Pushpalatha, R., Perrin, C., Le Moine, N., Mathevet, T., & Andréassian, V. (2011). A downward structural sensitivity analysis of hydrological models to improve low-flow simulation. *Journal of hydrology*, *411*(1-2), 66-76.
- Raftery, A. E., Gneiting, T., Balabdaoui, F., & Polakowski, M. (2005). Using Bayesian Model Averaging to Calibrate Forecast Ensembles, *Monthly Weather Review*, *133*(5), 1155-1174.
- Riboust, P., Thirel, G., Le Moine, N., & Ribstein, P. (2019). Revisiting a simple degree-day model for integrating satellite data: implementation of SWE-SCA hystereses. *Journal of hydrology and hydromechanics*, *67*(1), 70-81.
- Schefzik, R. (2015). *Physically coherent probabilistic weather forecasts using multivariate discrete copula-based ensemble postprocessing methods* (Doctoral dissertation).
- Schefzik, R. (2016). A similarity-based implementation of the Schaake shuffle. *Monthly Weather Review*, *144*(5), 1909-1921.
- Tong, R., Parajka, J., Salentinig, A., Pfeil, I., Komma, J., Széles, B., ... & Blöschl, G. (2021). The value of ASCAT soil moisture and MODIS snow cover data for calibrating a conceptual hydrologic model. *Hydrology and Earth System Sciences*, *25*(3), 1389-1410.
- Valéry, A., Andréassian, V., & 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. *Journal of hydrology*, *517*, 1176-1187.
- Van de Velde, J., De Baets, B., Demuzere, M., & Verhoest, N. E. (2020). Comparison of occurrence-bias-adjusting methods for hydrological impact modelling. *Hydrology and Earth System Sciences Discussions*, 1-35.
- Vrac, M., & Friederichs, P. (2015). Multivariate—intervariable, spatial, and temporal—bias correction. *Journal of Climate*, *28*(1), 218-237.