

# **SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA**

## **XXVI CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA**

### **POTENCIAL DE LA ASIMILACIÓN DE DATOS DE CAUDAL Y EQUIVALENTE EN AGUA DE NIEVE PARA MEJORAR PRONÓSTICOS ESTACIONALES DE CAUDAL EN UNA CUENCA ANDINA**

**JERONIMO SOTA<sup>1,2</sup>**  
**PABLO MENDOZA<sup>3,4</sup>**  
**MIGUEL LAGOS<sup>3</sup>**  
**JAMES MCPHEE<sup>3,4</sup>**  
**DIEGO ARAYA<sup>1</sup>**  
**DIEGO PINTO<sup>1,2</sup>**

#### **RESUMEN**

Mejorar la estimación de condiciones hidrológicas iniciales (IHCs, por sus siglas en inglés) es crucial para reducir la incertidumbre de pronósticos estacionales de caudal. En este sentido, las técnicas de asimilación de datos (DA, por sus siglas en inglés) buscan combinar información de observaciones inciertas con información proveniente de modelos imperfectos para mejorar las estimaciones de variables hidrológicas. En este trabajo, se evalúa el valor agregado de actualizar las IHCs simuladas por un modelo hidrológico conceptual en un esquema dinámico de pronósticos estacionales de caudal, generados para la cuenca del río Aconcagua en Chacabuquito. Específicamente, se busca entender el potencial de configuraciones que asimilan el caudal u observaciones in situ del equivalente de agua en nieve (SWE, por sus siglas en inglés). Con este fin, se utiliza el método de predicción de caudales por conjunto (ESP, por sus siglas en inglés), para distintos tiempos de inicialización, utilizando IHCs actualizadas a través de la implementación del Filtro de Kalman por Conjunto (EnKF, por sus siglas en inglés). Los resultados muestran que la asimilación de caudales con EnKF mejora la habilidad ( $CRPSS > 0$ ) del pronóstico para casi todos los tiempos de inicialización, especialmente para el primer mes de adelanto, alcanzando un  $CRPSS = 0,5$  para los pronósticos emitidos en marzo con un mes de adelanto. Por otro lado, al asimilar SWE el impacto en el pronóstico de caudales es menor y más irregular respecto a la asimilación de caudal. El trabajo futuro se centrará en el efecto conjunto de asimilación de caudales y nieve en la generación de pronóstico estacional.

---

<sup>1</sup> Ingeniero de proyectos en el Advanced Mining Technology Center (AMTC) de la Universidad de Chile.

<sup>2</sup> Estudiante de magíster de recursos hídricos del departamento de Ingeniería Civil de la Universidad de Chile.

<sup>3</sup> Investigador Asociado, Advanced Mining Technology Center (AMTC) de la Universidad de Chile.

<sup>4</sup> Académico, Departamento de Ingeniería Civil de la Universidad de Chile.

## 1. INTRODUCCIÓN

Los pronósticos hidrológicos estacionales son un valioso insumo para una gestión adecuada de los recursos hídricos (DeChant y Moradkhani, 2011). Esta información es especialmente relevante en Chile central, donde se han observado cambios en los patrones de precipitación durante la última década, que se han visto reflejados en una disminución de la disponibilidad hídrica (Garreaud et al., 2019). A lo largo de los años, se han desarrollado diferentes metodologías de pronóstico (i.e. dinámicos, estadísticos e híbridos; ver revisión de Slater et al., 2023). Entre ellos, los métodos dinámicos han sido ampliamente utilizados para generar pronósticos estacionales (e.g. Slater y Villarini, 2018; Arnal et al., 2018; Wanders et al., 2019; Baker et al., 2021). Los pronósticos dinámicos se basan en modelos numéricos que simulan procesos hidrológicos, y que pueden ser forzados con series meteorológicas históricas como el método de predicción de caudales por conjuntos (ESP, por sus siglas en inglés; Day, 1985; Baker et al., 2021) o con pronósticos climáticos (e.g., Arnal et al., 2018; Lucatero et al., 2018). Para mejorar la calidad de pronósticos dinámicos, es común el uso de métodos de asimilación de datos (DA, por sus siglas en inglés), que combinan información de modelos imperfectos con observaciones inciertas para cuantificar y reducir la incertidumbre en las condiciones hidrológicas iniciales al momento de inicializar los pronósticos (e.g. Liu y Gupta, 2007; Rakovec et al., 2012; Noh et al., 2013; Huang et al., 2017; Piazzini et al., 2021).

En este estudio, se busca evaluar el impacto que tendría la corrección de condiciones hidrológicas iniciales en el desempeño de pronósticos estacionales dinámicos. Para esto, se utiliza el método de DA denominado Filtro de Kalman por Conjunto (EnKF, por sus siglas en inglés; e.g. Evensen, 1994, 2003; Rakovec et al., 2012; Huang et al., 2017; Piazzini et al., 2021), comúnmente utilizado en hidrología. El análisis busca responder las siguientes preguntas:

- i. ¿Cuál es el valor de asimilar observaciones de equivalente de agua en nieve (SWE, por sus siglas en inglés) o caudal (Q) en la calidad de los pronósticos estacionales de caudal?
- ii. ¿Para qué meses de inicialización y para cuántos meses de adelanto la DA disminuye los errores del pronóstico?

## 2. DATOS Y MÉTODOS

### 2.1. Zona de estudio

El estudio se desarrolla en la cuenca del río Aconcagua en Chacabuquito (2113 km<sup>2</sup>, Figura 1b), ubicada en la Región de Valparaíso. Esta es una cuenca cordillerana con una marcada estacionalidad en su régimen de caudales, resultado de la concentración de precipitaciones en la temporada de invierno, y en la predominancia de precipitaciones sólidas sobre más de la mitad de su superficie, como se aprecia en la Figura. 1. Aguas abajo de dicha cuenca se desarrolla el 12% de la agricultura nacional (Webb et al., 2021). La Figura 1 ilustra la ubicación de la cuenca dentro del territorio nacional, detallando su subdivisión en cinco bandas de elevación de igual área. Además, se señalan las ubicaciones de la estación fluviométrica Aconcagua en Chacabuquito, a partir de la cual se delimita la cuenca, y la estación Portillo, que mide datos de nieve y está contenida en la banda de elevación comprendida entre los 2471-3115 m s.n.m. Ambas estaciones pertenecen a la red de monitoreo de la Dirección General de Aguas (DGA).

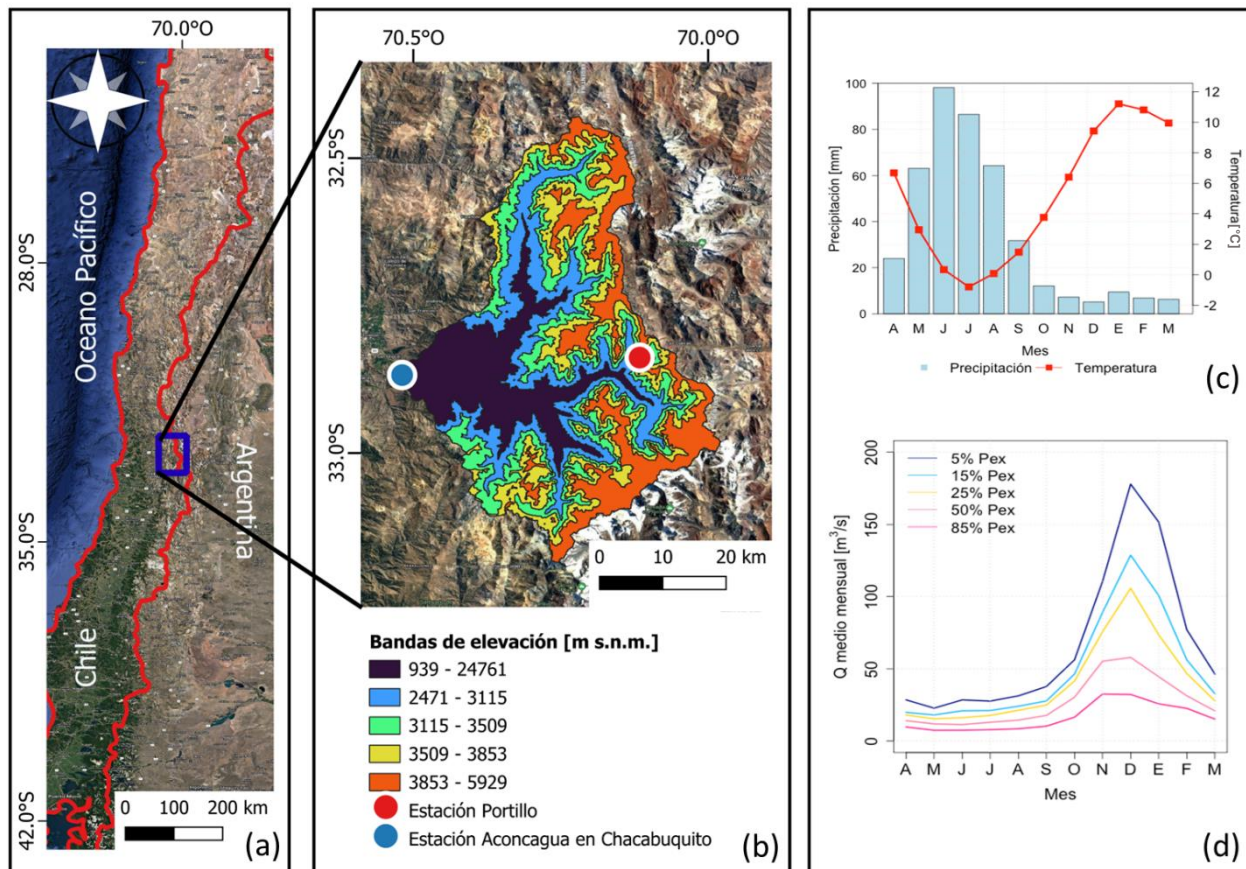


Figura 1: (a) Ubicación general de la zona de estudio, (b) Cuenca Aconcagua en Chacabuco, (c) Climograma (1979-2020), (d) Curvas de variación estacional de caudal (1979-2020).

## 2.2. Datos

Para el desarrollo de este estudio, se utilizaron datos observados de caudal medio diario en la estación río Aconcagua en Chacabuco y dos series diarias de SWE estimadas a partir de rutas de nieve (observaciones puntuales) y Snow Pillow (serie de observación continua) en la estación Portillo. Además, se generaron series diarias de precipitación y temperatura representativas de cada banda de elevación de la cuenca para el periodo 1979-2020, utilizando el producto grillado CR2met v2.0 (Boisier et al., 2018). Por último, se generó una serie de evapotranspiración potencial (ETP) representativa de cada banda de elevación mediante el método de Oudin (2005), a partir de la temperatura media y la radiación extraterrestre, que depende directamente de la latitud de la cuenca.

## 2.3. Método

La Figura 2 ilustra la metodología implementada en este trabajo, que consta de los siguientes pasos: (1) configuración del modelo hidrológico en la cuenca de interés; (ii) implementación del método de asimilación de datos EnKF; (3) generación de pronósticos con el método ESP; y (4) verificación probabilística de pronósticos retrospectivos. La descripción detallada de cada paso se presenta en las siguientes secciones.

**1. Simulación del modelo HBV.IANIGLA** previamente calibrado hasta el tiempo de inicialización del pronóstico (t).

**3. Generación del pronóstico ESP:** se generan N simulaciones a partir de series de forzantes meteorológicas correspondientes al período pronosticado, pero de distintos años hidrológicos.

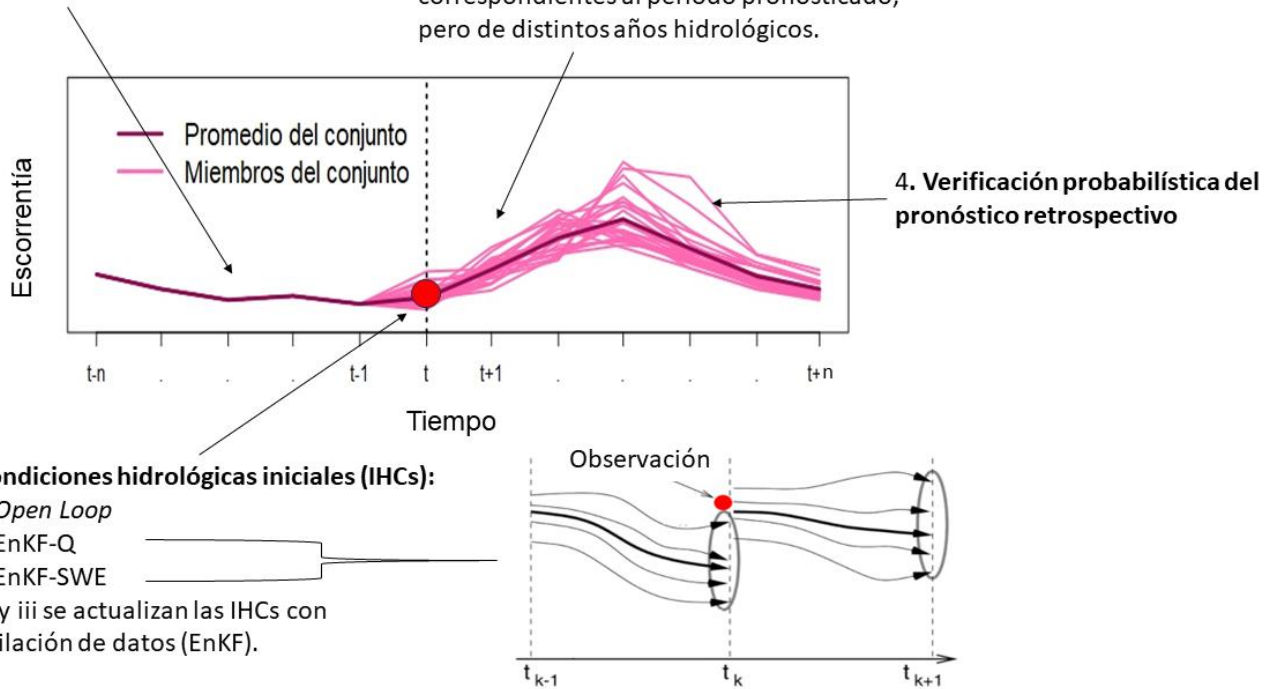


Figura 2: Esquema metodológico

### 2.3.1. Modelación hidrológica

Se configuró el modelo conceptual HBV.IANIGLA (Toum et al., 2021) a resolución temporal diaria, desagregando espacialmente las forzantes meteorológicas en cinco bandas de elevación. Para calibrar los parámetros del modelo, se utilizó el algoritmo de optimización global *Shuffled Complex Evolution* (SCE-UA; Duan et al., 1992), buscando generar un conjunto de parámetros óptimo que minimizar la siguiente función objetivo:

$$F.O. = \sqrt{(KGE1 - 1)^2 + (KGE2 - 1)^2} \quad (1)$$

donde KGE1 es la eficiencia de Kling-Gupta (KGE; Gupta et al., 2009) para el período 1990-2000, caracterizado por ser hidroclimáticamente húmedo y KGE2 corresponde a la eficiencia de Kling-Gupta para el periodo 2011-2021, caracterizado por condiciones de sequía sin precedentes y persistentes en el tiempo (Garreaud et al., 2017, 2019). Los dos años anteriores a dichos periodos se utilizaron para el calentamiento del modelo (i.e. generación de condiciones iniciales estables). La evaluación del modelo se realizó en el periodo de 2001-2010.

Las forzantes meteorológicas del modelo son series de precipitación, temperatura y ETP representativas de cada banda de elevación. Y entre sus salidas cuenta, además del caudal simulado, con series de SWE en cada banda, así como series del contenido de agua de los tres estanques de almacenamiento subterráneo del modelo.

### 2.3.2. Asimilación de datos

Se utiliza el método secuencial de asimilación de datos EnKF que combina observaciones y simulaciones imperfectas con el fin de cuantificar y reducir la incertidumbre en las estimaciones de los almacenamientos del modelo. En el EnKF, se genera un conjunto de simulaciones con número finito de miembros, donde cada miembro es una representación equiprobable obtenida del modelo hidrológico. El error del modelo se estima directamente a partir del conjunto, suponiendo que la media del conjunto es la “realidad” y calculando la varianza de las diferencias entre cada miembro del conjunto y la media de este (esto considera que el conjunto no tiene sesgo). Al igual que con otros métodos, la actualización de los estados del modelo depende de la diferencia relativa entre la covarianza del error del modelo y la covarianza del error de las observaciones (Liu y Gupta, 2007). Para generar el conjunto de simulaciones, se forzó el modelo con un conjunto de forzantes, que se generó perturbando las series de precipitación y temperatura con la metodología propuesta por Clark et al. (2008), obteniendo un conjunto de 30 miembros de cada forzante (P,T y ETP), el conjunto de ETP se generó a partir del conjunto de T.

El EnKF consta de dos pasos: (1) predicción del modelo, y (2) actualización de estados. El primer paso corresponde a la generación del vector de estados a priori a partir de la función de transferencia  $f$  y el vector de observaciones simuladas, generado a partir del operador de observaciones  $h$ . En las Ecuaciones 2 y 3 se plantean el vector de estados a priori y observaciones a priori, respectivamente:

$$\hat{x}_{t,i}^+ = f(x_{t-1,i}^+, u_{t,i}, \theta_f) + \omega_{t,i} \quad (2)$$

$f$  gobierna la evolución temporal del vector de estados  $x$  (e.g. modelo hidrológico), y depende de la condición inicial de los mismos ( $\hat{x}_{t-1,i}^+$ ), las forzantes  $u$  y el vector de parámetros  $\theta$ . Además, dada la naturaleza imperfecta del modelo se agrega el error aditivo  $\omega$ , el cual se denomina “error del modelo”.

$$\hat{y}_{t,i} = h(x_{t-1,i}^-, \theta) \quad (3)$$

$h$  permite vincular el espacio de estados con el espacio de observaciones (e.g., caudal). El vector de observaciones  $y$  depende del vector de estados  $x$  y del vector de parámetros  $\theta_h$ . Luego, cada vez que hay una nueva observación disponible ( $y_{t,i} = y_t + \epsilon_{t,i}$ ), donde  $\epsilon_{t,i}$  representa el error de la observación, se inicia el paso de actualización de estados:

$$x_{t,i}^+ = x_{t,i}^- + K(y_{t,i} - \hat{y}_{t,i}) \quad (4)$$

$$K = P_t h^t (h P_t h^t + R_t)^{-1} \quad (5)$$

Donde  $K$  corresponde a la ganancia de Kalman,  $R_t$  es la matriz de covarianza del error de las observaciones y  $P_t$  es la matriz de covarianza del error del modelo.

En este estudio se utilizaron tres configuraciones distintas, que consideran:

- (1) Asimilar el caudal observado para actualizar los niveles de los tres estanques de almacenamiento subterráneo del modelo.
- (2) Asimilar el SWE estimado a partir de las rutas de nieve para actualizar los almacenamientos de SWE en cada banda del modelo
- (3) Asimilar las estimaciones de SWE obtenidas con un Snow Pillow para actualizar los almacenamientos de SWE en cada banda del modelo.

La actualización se realiza cada vez que hay una observación disponible. Para llevar las observaciones de SWE desde la estación Portillo (a escala puntual) a la escala del modelo (específicamente, hacia la banda N° 2, la cual contiene la estación en cuestión), se calibró una relación entre las mediciones de SWE, tanto de las rutas de nieve como del Snow Pillow, y la simulación de SWE del modelo en la banda n°2. Se probaron distintos ajustes (e.g. lineales, cuadráticos, potenciales) que luego fueron evaluados mediante validación cruzada. Calibrando los ajustes con el 80% de los datos y evaluando con el 20% restante, las métricas utilizadas para la evaluación fueron el NRMSE, el Sesgo y el  $R^2$ .

### **2.3.3. Pronóstico ESP retrospectivo**

Para evaluar el impacto de la asimilación de datos en un esquema de pronóstico, se implementó la metodología ESP (Day, 1985), que consiste en generar un conjunto de pronósticos de caudales, donde cada miembro del conjunto se obtiene forzando el modelo hidrológico, en el horizonte del pronóstico (e.g., septiembre a marzo), con series de meteorología histórica correspondiente al mismo periodo, pero de años distintos al pronosticado. Específicamente, los pasos requeridos son:

1. Generar una simulación determinística durante dos años previos al tiempo de inicialización del pronóstico para estimar las IHCs de la cuenca.
2. Generar un pronóstico probabilístico de 37 miembros, forzando el modelo con series meteorológicas correspondientes a la misma temporada a pronosticar, pero de 37 años distintos al pronosticado. Los años utilizados están comprendidos en el periodo 1979-2016.

El pronóstico retrospectivo se realizó para 180 tiempos de inicialización correspondientes al primer día de cada mes comprendido entre el 01/01/2001 y el 31/12/2015. Se utiliza este periodo de análisis dada la disponibilidad de datos de SWE medidos con Snow Pillow. Para los experimentos con DA, se repite el paso 2, estimando las condiciones iniciales del pronóstico asimilando caudal o SWE con el EnKF cada vez que una hay una observación disponible, durante dos años previos a la inicialización del pronóstico. Luego, siguiendo estos pasos se generan, además del ESP de referencia (sin DA) tres experimentos de pronóstico con asimilación de datos:

- i. ESP actualizando IHCs con asimilación de caudal (ESP-DA-Q)
- ii. ESP actualizando IHCs con asimilación de SWE estimado en base a mediciones en rutas de nieve (ESP-DA-SWE-RN)
- iii. ESP actualizando IHCs con asimilación de SWE estimado en base a Snow Pillow (ESP-DA-SWE-SP)

### 2.3.4. Verificación

Para evaluar la calidad de los pronósticos, se utilizó una métrica de habilidad probabilística continua (CRPSS por sus siglas en inglés; Ecuación 6; e.g. Mendoza et al., 2017; Lucatero et al., 2018; Slater y Villarini, 2018) que compara el error probabilístico (CRPS; Hersbach, 2000; Ecuación 7) del experimento ESP-DA con una referencia, que en este caso corresponde a ESP sin asimilación de datos. El CRPS mide la discrepancia entre la función de distribución acumulada (CDF por sus siglas en inglés) pronosticada y la CDF de la observación, siendo 0 el valor óptimo. Por otro lado, el CRPSS varía ente  $-\infty$  y 1, siendo 1 el puntaje perfecto, mientras que valores positivos (negativos) indican que el esquema ESP-DA tiene un mejor (peor) desempeño que el esquema ESP sin DA. Valores cercanos al 0 indican que el esquema analizado tiene un desempeño comparable con la referencia.

$$CRPSS = 1 - \frac{CRPS_{ESP-DA} \text{ (pronóstico)}}{CRPS_{ESP} \text{ (referencia)}} \quad (6)$$

La métrica CRPS se calcula con la siguiente expresión:

$$CRPS(p(x), y) = \int (p(x) - H(x < y))^2 dx \quad (7)$$

Donde:

$p(x)$ : representa la función de distribución acumulada del pronóstico

$y$ : Observación

$H$ : es la función escalonada, que es igual a 0 cuando  $x < y$ , y 1 cuando  $x > y$

## 3. RESULTADOS Y DISCUSIÓN

### 3.1. Calibración y evaluación del modelo hidrológico

La Figura 3 muestra un índice KGE de 0,84 para el periodo de calibración, lo que refleja un alto nivel de concordancia entre los valores simulados y observados. Asimismo, en el periodo seco, el caudal modelado presentó un índice KGE de 0,82, indicando nuevamente una adecuada capacidad de reproducción de los caudales observados en dicho periodo. Además, en el periodo de evaluación (periodo no utilizado para la calibración) se obtuvo un KGE igual a 0,83 (Figura 3a). Las Figuras 3b y 3c muestran una alta correlación ( $R^2 \geq 0,95$ ) entre los módulos mensuales de caudal simulados y observados. Estos resultados respaldan la confiabilidad y la utilidad del modelo en la estimación de caudales en diferentes condiciones hidro-climáticas.

### 3.2. Asimilación de datos

#### 3.2.1. Asimilación de caudal observado

En la Figura 4, se muestra que la asimilación de caudal observado entrega un  $R^2 = 0,99$  para el año hidrológico 2000-2001. (Figura 4c). Se destaca el potencial de la actualización de los estanques de almacenamiento del modelo vía asimilación de caudal con el EnKF para simular correctamente el caudal de la cuenca en un esquema de pronóstico operacional.

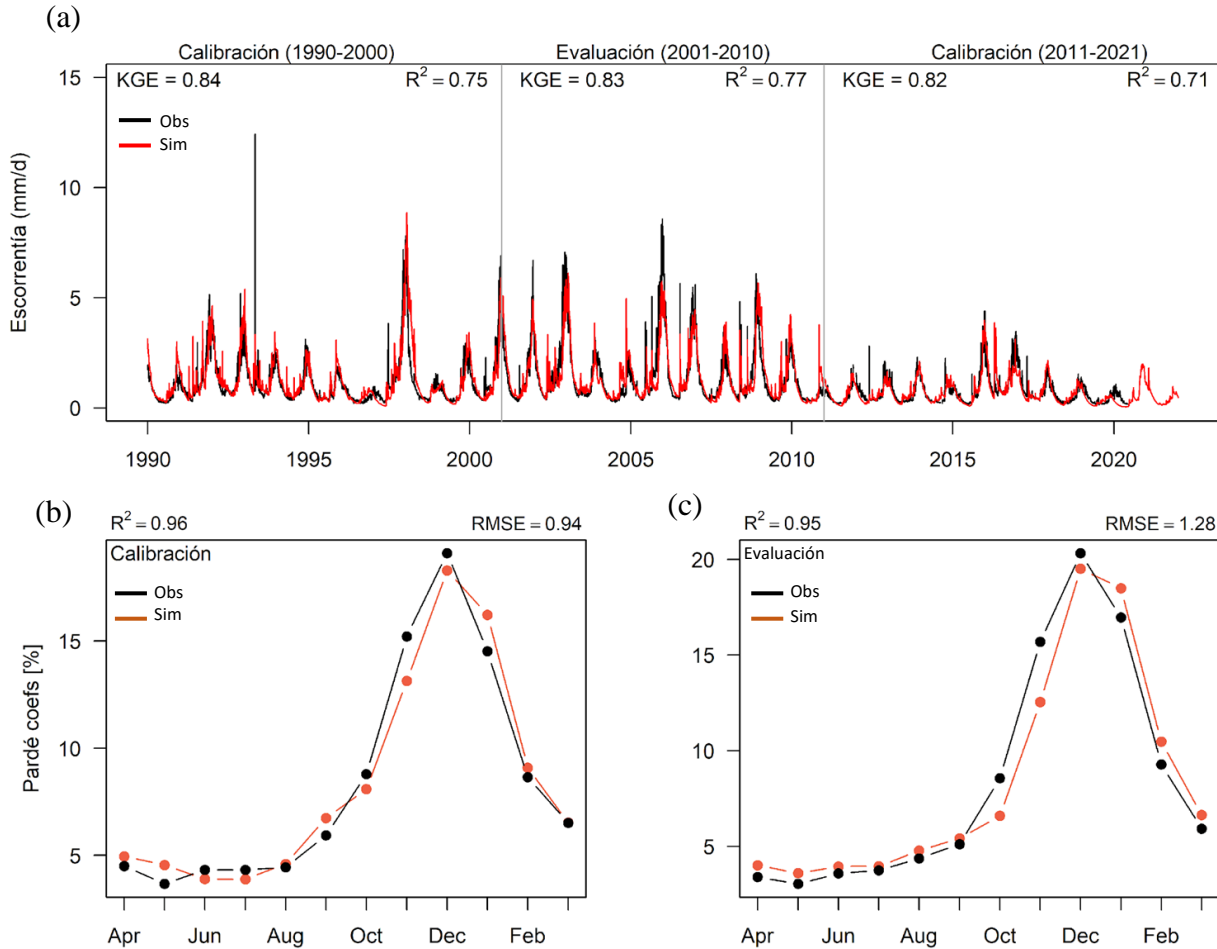


Figura 3: Calibración y evaluación del modelo hidrológico HBV.IANIGLA; (a) Serie diaria 1990-2021; (b) y (c) Series estacionales.

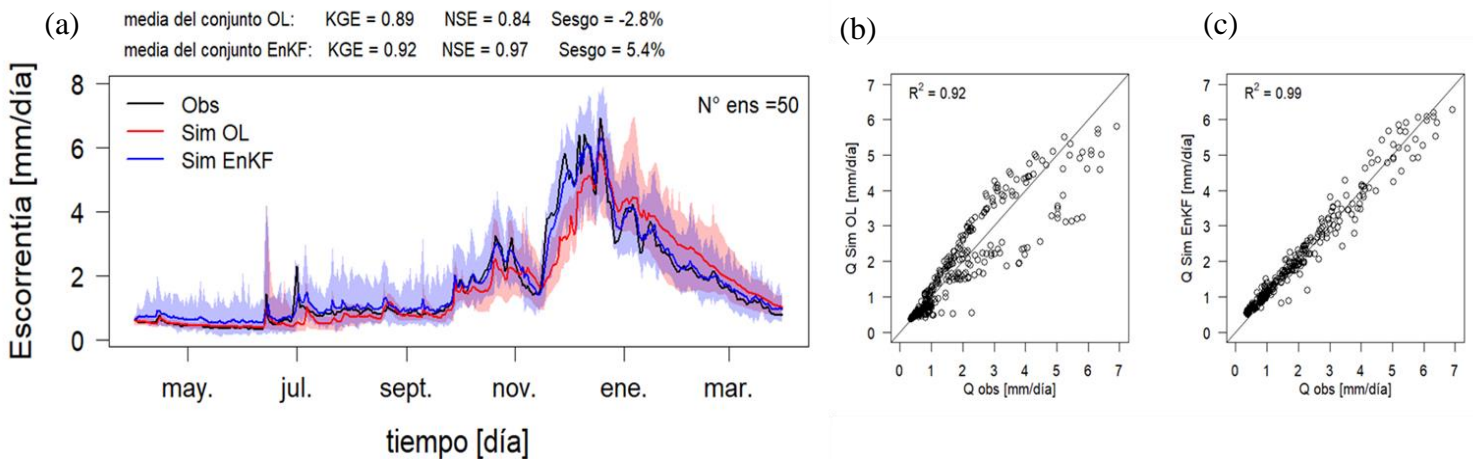


Figura 4: Asimilación de datos de caudal en el periodo 01/04/2000 – 31/03/2001. (a) Series simuladas con DA y sin DA (OL); (b) Gráfico de dispersión entre la serie observada y la serie simulada sin DA; (c) Gráfico de dispersión entre la serie observada y la serie simulada con DA; OL = Simulación sin DA (Open Loop en inglés).

### 3.2.2. Asimilación de datos de SWE

La asimilación de datos observados de SWE resulta en una mejora significativa en las simulaciones de dicha variable, disminuyendo el sesgo en ambos experimentos, como se puede apreciar en las Figuras 5a (rutas de nieve) y 5b (Snow Pillow).

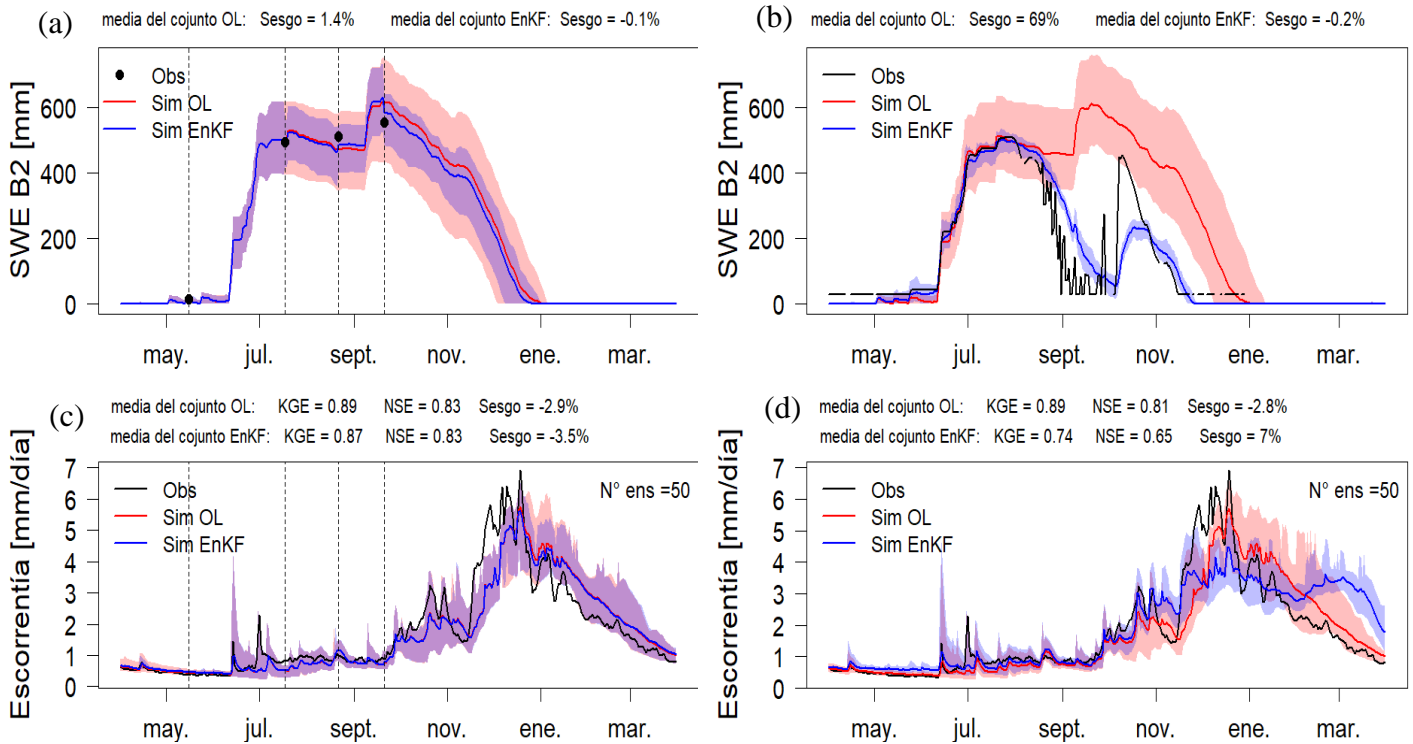


Figura 5: Experimentos de actualización de los almacenamientos de SWE asimilando estimaciones de SWE. Los paneles de la izquierda (a y c) corresponden al experimento de asimilación de datos de SWE estimado a partir de rutas de nieve (observaciones puntuales) y los paneles de la derecha (b y d) corresponden al experimento de asimilación de datos de SWE estimado a partir de mediciones de Snow Pillow (observaciones continuas). Los paneles a y b presentan las simulaciones y observaciones de SWE en la banda de elevación n° 2. Los paneles c y d presentan los caudales simulados en ambos experimentos. Periodo: 01/04/2000 – 31/03/2001.

Sin embargo, esto no se traduce en mejores simulaciones de caudal (Figuras 5c y 5d), especialmente al asimilar mediciones de Snow Pillow. Esto podría atribuirse a que los parámetros de las rutinas de acumulación y derretimiento de nieve fueron calibrados con el objetivo de simular el caudal de salida de la cuenca, y no necesariamente simular correctamente el SWE observado.

### 3.3. Pronóstico ESP retrospectivo

Los resultados de la Figura 6 muestran que, al actualizar los niveles de los estanques de almacenamiento subterráneo del modelo asimilando caudal (ESP-DA-Q; Figura 6a). Se obtienen CRPSS > 0 (al menos para un mes de adelanto) en nueve de los doce tiempos de inicialización, siendo los meses de invierno (junio, julio y agosto) los tiempos de inicialización para los cuales ESP-DA-Q no presenta una mejoría respecto al ESP tradicional (CRPSS < 0). Las mejoras más relevantes provocadas por la DA de caudal se observan para el primer mes de adelanto, cuando el pronóstico es emitido entre enero y abril, donde se obtienen valores de CRPSS ≥ 0,4. Esto indica

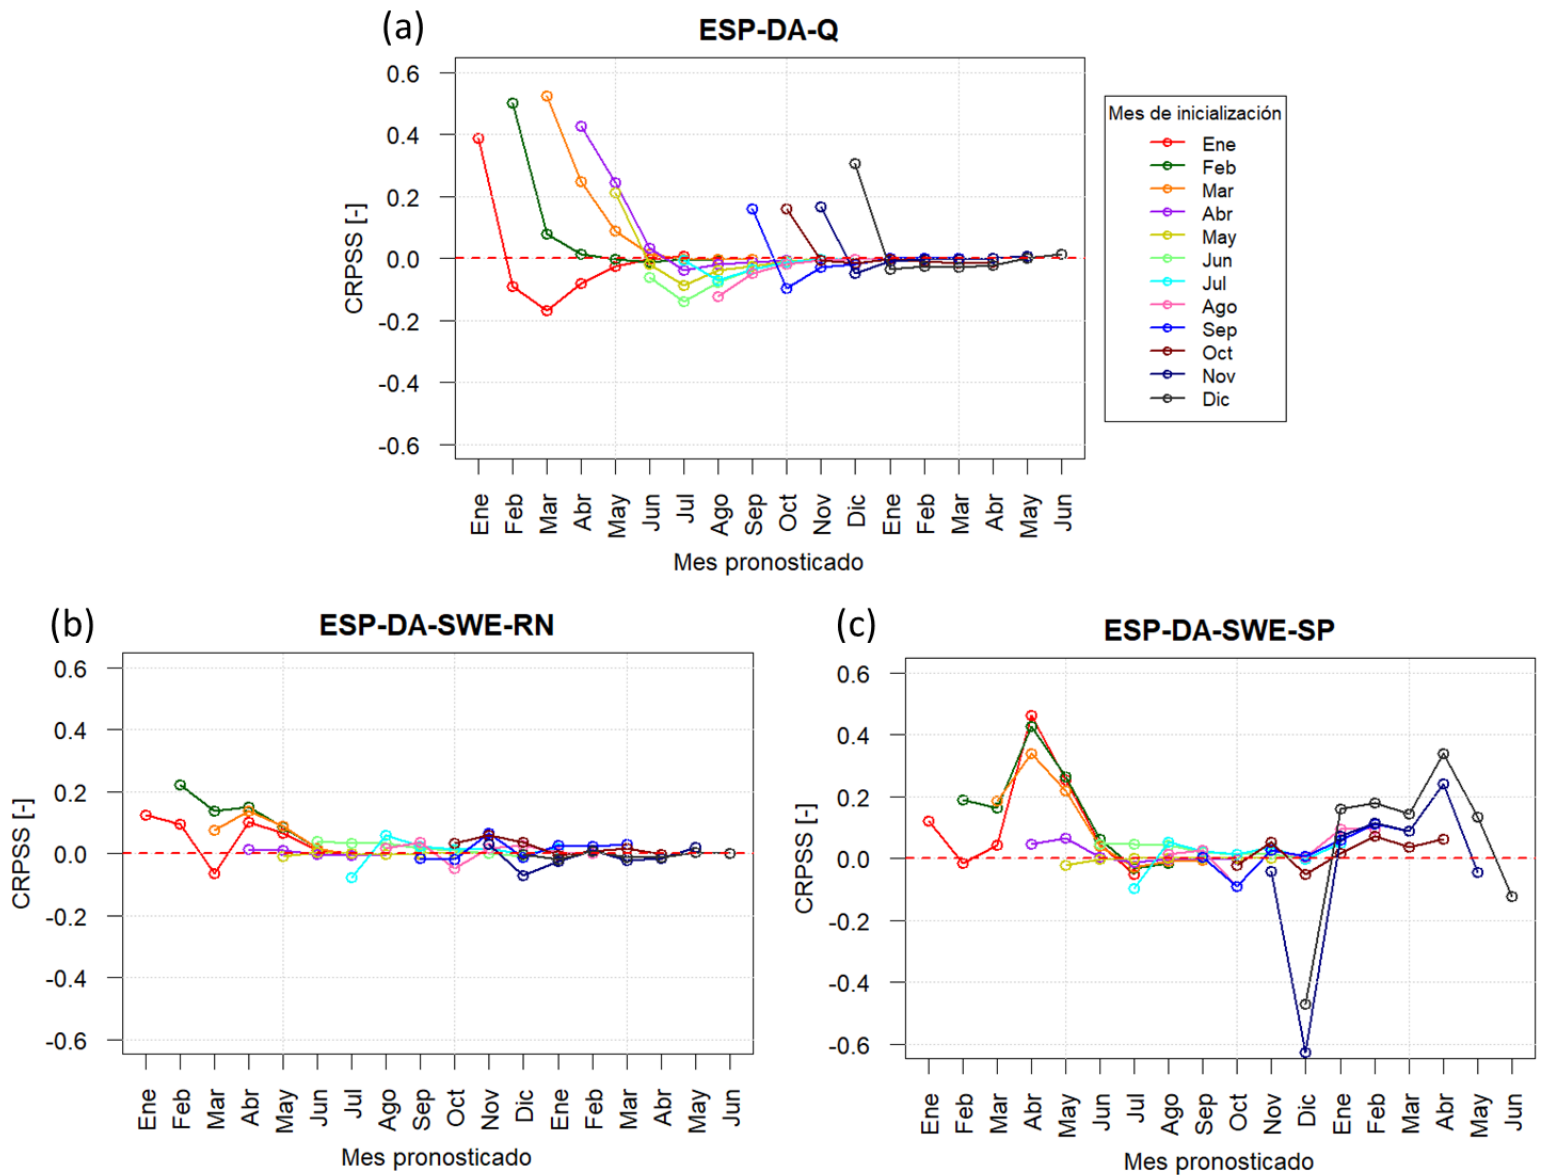


Figura 6: CRPSS del pronóstico ESP-DA con ESP como referencia. Cada línea de color representa un mes de inicialización del pronóstico distinto (i.e., la línea roja representa el CRPSS promedio de los 15 pronósticos emitidos el 1 enero para los próximos 7 meses entre el 2001 y el 2015). (a) ESP-DA-Q, (b) ESP-DA-SWE-RN y (c) ESP-DA-SWE-SP.

que el error probabilístico del ESP-DA-Q en dichos meses es al menos un 40% menor que el error probabilístico del ESP. En términos generales el esquema ESP-DA-Q genera pronósticos más hábiles ( $CRPSS > 0$ ) que el ESP tradicional al menos para el primer mes de adelanto, especialmente en los meses de verano y otoño y en menor medida en primavera. Por otro lado, en el esquema ESP-DA-SWE-RN (Figura 6b) el impacto de la DA es menor y más irregular, obteniéndose un  $CRPSS = 0,22$  en marzo, el mes de inicio con el puntaje más alto. Finalmente, en el esquema ESP-DA-SWE-SP (Figura 6c) se aprecia que el impacto de la DA depende en mayor medida del mes pronosticado y no tanto del tiempo de inicialización, obteniendo un impacto positivo en los meses de otoño (marzo, abril, mayo),  $CRPSS=0,46$  cuando se pronostica abril iniciando el pronóstico en enero, y un impacto negativo cuando se pronostica diciembre iniciando el pronóstico en noviembre ( $CRPSS = -0,6$ ) y diciembre ( $CRPSS = -0,4$ ). Que el pronóstico no mejore en los meses en los que

la nieve tiene un rol importante en la generación de escorrentía (primavera), al actualizar los almacenamientos de SWE del modelo, puede deberse a la incertidumbre asociada a las series de SWE utilizadas. Donde destacan, la incertidumbre de las estimaciones puntuales de SWE tanto de las rutas de nieve como del Snow Pillow y la incertidumbre asociada al paso de llevar el SWE observado de la escala puntual a la escala del modelo.

#### **4. CONCLUSIONES**

En este estudio, se analizó el impacto de actualizar las condiciones iniciales de un modelo hidrológico conceptual en la calidad de pronósticos estacionales de caudal generados con el método ESP. Para actualizar las IHCs, se implementaron y testearon tres esquemas de asimilación de datos vía EnKF. Los resultados muestran el impacto positivo de asimilar datos de caudal para actualizar los niveles de los estanques de almacenamiento del modelo, lo que se ve reflejado en valores positivos de CRPSS, para todos los meses de inicialización exceptuando los meses de invierno (junio, julio, agosto), especialmente para el primer mes de adelanto, alcanzándose un  $CRPSS = 0,5$  cuando se pronostica el caudal de marzo iniciando el pronóstico el primer día del mismo mes. En el caso de la asimilación de datos de SWE, el impacto es menor y más irregular que al asimilar caudal, lo que se puede explicar con lo observado en la sección 3.2.2, donde se mostró que una simulación de SWE más cercana a la observación, no necesariamente se traduce en una mejor simulación del caudal.

Los esfuerzos futuros se concentrarán en la implementación de una asimilación conjunta de caudal y SWE para actualizar las IHCs del modelo, así como un esquema de calibración secuencial que permita el ajuste de los parámetros asociados a procesos nivales con datos de SWE observado, para luego calibrar parámetros relacionados con la generación de escorrentía con datos de caudal observado.

#### **AGRADECIMIENTOS**

Los autores agradecen el financiamiento del proyecto ACTUALIZACIÓN DE MODELOS PARA PRONÓSTICO DE CAUDALES DE DESHIELO INTEGRANDO RED NIVAL D.G.A. Y SU DISPOSICIÓN EN APLICACIÓN INFORMÁTICA por parte de la DGA.

#### **REFERENCIAS**

- Arnal, L., Cloke, H. L., Stephens, E., Wetterhall, F., Prudhomme, C., Neumann, J., ... & Pappenberger, F. (2018). Skilful seasonal forecasts of streamflow over Europe?. *Hydrology and Earth System Sciences*, 22(4), 2057-2072.
- Baker, S. A., Rajagopalan, B., & Wood, A. W. (2021). Enhancing Ensemble Seasonal Streamflow Forecasts in the Upper Colorado River Basin Using Multi-Model Climate Forecasts. *JAWRA Journal of the American Water Resources Association*, 57(6), 906-922.
- 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. *En EGU General Assembly Conference Abstracts*, Vol 20, p. 19739.
- Clark, M. P., Rupp, D. E., Woods, R. A., Zheng, X., Ibbitt, R. P., Slater, A. G., ... & Uddstrom, M.J. (2008). Hydrological data assimilation with the ensemble Kalman filter: Use of streamflow observations to update states in a distributed hydrological model. *Advances in water resources*, 31(10), 1309-1324.
- Day, G. N. (1985). Extended streamflow forecasting using NWSRFS. *Journal of Water Resources Planning and Management*, 111(2), 157-170.

- DeChant, C. M., & Moradkhani, H. (2011). Improving the characterization of initial condition for ensemble streamflow prediction using data assimilation. *Hydrology and Earth System Sciences*, 15(11), 3399-3410.
- Duan, Q., Sorooshian, S., & Gupta, V. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, 28 (4), 1015–1031.
- Evensen, G. (2003). The ensemble Kalman filter: Theoretical formulation and practical implementation. *Ocean dynamics*, 53, 343-367.
- Garreaud, Rene & Boisier, Juan P. & Rondanelli, Roberto & Montecinos, Alejandro & Sepúlveda, Héctor & Veloso, Daniel. (2019). The Central Chile Mega Drought (2010-2018): A Climate dynamics perspective. *International Journal of Climatology*.
- 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*, Vol. 377, No. 1-2, pp. 80-91.
- Hersbach, H.: Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems, *Weather Forecast.*, 15, 559–570
- Huang, C., Newman, A. J., Clark, M. P., Wood, A. W., & Zheng, X. (2017). Evaluation of snow data assimilation using the ensemble Kalman filter for seasonal streamflow prediction in the western United States. *Hydrology and Earth System Sciences*, 21(1), 635-650.
- Liu, Y., & Gupta, H. V. (2007). Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework. *Water resources research*, 43(7).
- Lucatero, D., Madsen, H., Refsgaard, J. C., Kidmose, J., & Jensen, K. H. (2018). Seasonal streamflow forecasts in the Ahlergaard catchment, Denmark: the effect of preprocessing and post-processing on skill and statistical consistency. *Hydrology and Earth System Sciences*, 22(7), 3601-3617.
- Mendoza, P. A., Wood, A. W., Clark, E., Rothwell, E., Clark, M. P., Nijssen, B., ... & Arnold, J. R. (2017). An intercomparison of approaches for improving operational seasonal streamflow forecasts. *Hydrology and Earth System Sciences*, 21(7), 3915-3935.
- Noh, S. J., Tachikawa, Y., Shiiba, M., & Kim, S. (2013). Sequential data assimilation for streamflow forecasting using a distributed hydrologic model: particle filtering and ensemble Kalman filtering. *Floods: From Risk to Opportunity*, 357, 341–349.
- 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*, Vol. 303, No. 1-4, pp. 290-306.
- Piazzzi, G., Thirel, G., Perrin, C., & Delaigue, O. (2021). Sequential data assimilation for streamflow forecasting: assessing the sensitivity to uncertainties and updated variables of a conceptual hydrological model at basin scale. *Water Resources Research*, 57(4).
- Pechlivanidis, I. G., Crochemore, L., Rosberg, J., & Bosshard, T. (2020). What are the key drivers controlling the quality of seasonal streamflow forecasts?. *Water Resources Research*, 56(6), e2019WR026987.
- Rakovec, O., Weerts, A. H., Hazenberg, P., Torfs, P. J. J. F., & Uijlenhoet, R. (2012). State updating of a distributed hydrological model with Ensemble Kalman Filtering: effects of updating frequency and observation network density on forecast accuracy. *Hydrology and Earth System Sciences*, 16(9), 3435-3449.
- Slater, L. J., & Villarini, G. (2018). Enhancing the predictability of seasonal streamflow with a statistical-dynamical approach. *Geophysical Research Letters*, 45(13), 6504-6513.
- Slater, L. J., Arnal, L., Boucher, M. A., Chang, A. Y. Y., Moulds, S., Murphy, C., ... & Zappa, M. (2023). Hybrid forecasting: blending climate predictions with AI models. *Hydrology and earth system sciences*, 27(9), 1865-1889.
- Toum, J. E., Masiokas, M. H., Villalba, R., Pitte, P., & Ruiz, L. E. (2021). The HBV. IANIGLA Hydrological Model.
- Wanders, N., Thober, S., Kumar, R., Pan, M., Sheffield, J., Samaniego, L., & Wood, E. F. (2019). Development and evaluation of a pan-European multimodel seasonal hydrological forecasting system. *Journal of Hydrometeorology*, 20(1), 99-115.
- Webb, M. J., Winter, J. M., Spera, S. A., Chipman, J. W., & Osterberg, E. C. (2021). Water, agriculture, and climate dynamics in central Chile's Aconcagua River Basin. *Physical Geography*, 42(5), 395-415.
- Wood, A. W., Sankarasubramanian, A., & Mendoza, P. (2018). Seasonal ensemble forecast post-processing. *Handbook of Hydrometeorological Ensemble Forecasting*; Springer: Berlin/Heidelberg, Germany.