



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

DEPARTAMENTO DE INGENIERIA CIVIL

PRONÓSTICO DE LA DISTRIBUCIÓN ESPACIAL DEL SWE USANDO EL
MODELO CRHM Y UN MARCO DE ASIMILACIÓN DE PRODUCTOS
SATELITALES Y FORZANTES DEL MODELO. APLICACIÓN EN LA CUENCA
ALTA DEL RÍO TINGUIRIRICA, CHILE.

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL

JOSÉ IGNACIO VILLEGAS TAPIA

PROFESORA GUÍA:
XIMENA VARGAS MESA

MIEMBROS DE LA COMISIÓN:
NICOLÁS VÁSQUEZ PLACENCIA
JAMES MCPHEE TORRES

SANTIAGO DE CHILE
2022

**RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE:** Ingeniero Civil

POR: José Ignacio Villegas Tapia

FECHA: 2022

PROFESOR GUÍA: Ximena Vargas Mesa

**PRONÓSTICO DE LA DISTRIBUCIÓN ESPACIAL DEL SWE USANDO EL
MODELO CRHM Y UN MARCO DE ASIMILACIÓN DE PRODUCTOS
SATELITALES Y FORZANTES DEL MODELO. APLICACIÓN EN LA CUENCA
ALTA DEL RÍO TINGUIRIRICA, CHILE.**

La distribución espacial del equivalente en agua de nieve (SWE) incide en la generación de los caudales de deshielo que son utilizados para riego, hidroelectricidad o suministro de agua, por lo que su pronóstico acertado y oportuno puede significar una eficiente gestión del recurso hídrico. En la necesidad de pronosticar el SWE de la temporada de deshielo y gracias al desarrollo tanto de productos satelitales que pueden reemplazar mediciones in situ y de pronósticos estacionales animan la aplicación de modelos de base física para estimar la cantidad de SWE para la temporada de deshielo.

En esta memoria se asimila la fracción de área cubierta por nieve (fSCA) en el modelo hidrológico *Cold Regions hydrological Model* (CRHM; Pomeroy et al., 2007) usando el método asimilación variacional para calibrar los parámetros, mediante el modelo de distribución de subgrilla presentado por Liston (2004) en el período 2003-2012 para la cuenca Río Tinguiririca Bajo Los Briones, ubicada en la Región del Libertador Bernardo O'Higgins, Chile. Además se pronostica el SWE usando el pronóstico meteorológico SEAS5 (Johnson et al., 2019) del ECMWF. Las series de SWE son comparadas con las series de Cornwell et al. (2016) consideradas como estado verdadero.

La media del conjunto de series simuladas de fSCA presentas un desempeño de 0,42 de R^2 , 0,14 RMSE y -0,12 de sesgo para los 10 años simulados. La asimilación de fSCA no funciona para obtener buen ajuste de SWE debido a problemas de equifinalidad del modelo CRHM y del modelo de Liston (2004). Las series con asimilación de SWE presentan 0,55 de R^2 , 500 kg/m² de RMSE, que equivale a 1 m de altura de nieve con densidad de nieve uniforme de 495 kg/m³ y sesgo de -330 kg/m² promedio espacio-temporal.

El pronóstico de SWE con parámetros calibrados empeora la variabilidad temporal y en menor medida la magnitud del error medio, defectos que tienen relación directa con el monto de precipitación anual. La disminución del desempeño debido a ocupar el pronóstico es de 0,07 de R^2 , 27 kg/m² de RMSE y 29 kg/m² de sesgo. La fecha de inicio de pronóstico óptima se determina que es el 1 de agosto.

AGRADECIMIENTOS

Existen momentos que son gratificantes porque recompensan el tiempo y esfuerzo entregado. Estos momentos engrandecen la vida y dan pie a continuar aprendiendo, mejorando y persiguiendo las metas. El término de la educación superior es uno de ellos que vale la pena atesorar. Fueron varias instancias de estudio, espera, paciencia, dedicación que hacen de este momento uno especial y que queda plasmado en esta memoria. La universidad no es solo lo aprendido en las clases, uno comparte situaciones con compañeros, profesores, colegas de los cuales se aprenden maneras de ver las cosas y que entregan compañía y ayuda cuando se necesita.

En el término de esta etapa quiero agradecer a mi familia por la paciencia, el compromiso y el constante apoyo que me dan para perseguir y completar los sueños. Los valores y hábitos que me inculcaron desde joven.

Quiero agradecer a la profesora Ximena por su compromiso, paciencia, la ayuda y consejos entregados, buena disposición y oportunidad entregada para realizar esta memoria que en el comienzo no estuvo completamente clara. También quiero agradecer al profesor Nicolás por la paciencia, buenos consejos, disposición, optimismo. También al profesor James por su comunicación y sugerencias entregadas.

También agradezco a mis amigos por la ayuda entregada, hacer amenas las tardes de estudio y enfrentar lo que en comienzo fue una nueva etapa con dificultades y gran exigencia de tiempo y esfuerzo, pero no por eso menos agradable. También con quienes compartí en clases como en otras instancias y generamos lazos de amistad.

TABLA DE CONTENIDO

Capítulo 1: Introducción.....	1
1.1. Motivación	1
1.1. Objetivo general	4
1.2. Objetivos específicos.....	4
1.3. Organización de la memoria.....	4
Capítulo 2: Marco Teórico.....	5
2.1. Conceptos básicos	5
2.1.1. El manto nival	5
2.1.2. SWE.....	5
2.1.3. Contenido de frío	6
2.1.4. Agua líquida en la nieve.....	6
2.1.6. Balance másico	7
2.1.7. Balance energético	8
2.1.8. Transferencia de calor en el manto nival	9
2.2. Procesos de distribución del SWE.....	10
2.2.1. Intercepción por vegetación.....	10
2.2.2. Transporte por viento.....	11
2.2.3. Sublimación del transporte por viento.....	12
2.3. <i>Cold Regions Hydrological Model (CRHM)</i>	12
2.4. Percepción remota del manto nival	13
2.4.1. Espectro visible e infrarrojo cercano.....	13
2.4.2. Infrarrojo termal	14
2.4.3. Microondas	15
2.4.4. Productos MODIS.....	15
2.5. Asimilación de datos.....	16
2.5.1. Métodos de filtrado	17
2.5.2. Métodos de suavizado	18
2.5.3. Curvas de agotamiento (SDC).....	19
2.6. Pronósticos meteorológicos estacionales.....	20
2.7. Métricas de evaluación.....	20

Capítulo 3: Zona de Estudio	23
3.1. Hidroclimatología.....	23
3.2. Línea de nieves	25
Capítulo 4: Antecedentes y Metodología	27
4.1. Antecedentes.....	27
4.1.1. Información morfológica.....	27
4.1.2. Producto CR2Met v2.0 (DGA, 2019).....	27
4.1.3. Inventario de glaciares DGA	27
4.1.4. Productos MOD10A1 y MYD10A1 (Hall & G. A. Riggs., 2021) de MODIS	27
4.1.5. Pronóstico meteorológico SEAS5 (Johnson et al., 2019) de ECMWF ...	28
4.1.6. Series de SWE (Cornwell et al., 2016).....	28
4.2. Metodología.....	29
4.2.1. Remoción de nubes (Parajka and Blöschl, 2008)	29
4.2.2. Extracción de fSCA.....	30
4.2.3. Análisis de sensibilidad DELSA (Rakovec et al., 2014)	32
4.2.4. Asimilación con CRHM	33
4.2.4.1. Conversión entre fSCA y SWE (Liston, 2004).....	33
4.2.4.2. Asimilación variacional.....	35
4.2.5. Implementación modelo CRHM	37
4.2.6. Corrección de pronóstico meteorológico con QDM (Cannon et al., 2015)	38
4.2.7. Simulación hidrológica con CRHM	40
4.2.8. Comparación con Cornwell et al. (2016).....	40
Capítulo 5: Resultados	41
5.1. Análisis del producto MODIS corregido	41
5.2. Análisis de forzantes meteorológicas	41
5.3. Análisis de sensibilidad DELSA (Rakovec et al., 2014).....	43
5.4. Implementación modelo CRHM.....	45
5.5. Asimilación variacional	46
5.5.1. Resultados de calibración del modelo CRHM.....	46
5.5.2. Parámetros de distribución subgrilla de SWE (Liston, 2004) y parámetros representativos.....	47

5.5.3. Resultados de asimilación variacional	51
5.6. Corrección de pronóstico meteorológico con QDM (Cannon et al., 2015)....	56
5.7. Pronóstico de SWE	56
Capítulo 6: Conclusiones	60
6.1. Comentarios generales	60
6.2. Resultados de la asimilación variacional	61
6.3. Pronóstico meteorológico de SWE	62
6.4. Sobre el marco de asimilación.....	62
6.5. Sugerencias para el futuro trabajo.....	63
BIBLIOGRAFÍA.....	65
ANEXOS	i
ANEXO A: Parámetros usados en la calibración.....	ii
ANEXO B: Resultados de modelo de distribución subgrilla de Liston (2004)	iv
ANEXO C: Resultados asimilación de fSCA	xii

ÍNDICE DE TABLAS

Tabla 2-1 Sensores más idóneos para monitorear cubierta nival usando espectro visible e infrarrojo cercano.	14
Tabla 4-1: Módulos usados en la modelación hidrológica con CRHM.	37
Tabla 5-1: Resultados de remoción de nubes Parajka & Blöschl (2008).	41
Tabla 5-2: Parámetros que modifican la serie de SWE del modelo CRHM.	44
Tabla 5-3: Desempeño de calibración y validación de los miembros del conjunto. ..	49
Tabla 5-4: Comparación de desempeño entre simulación sin pronóstico y con pronóstico meteorológico.	57
Tabla A-1: Valores inferiores y superiores de los parámetros a determinar en el método variacional y utilizados como serie sin asimilación.	ii
Tabla A-2: Límites de parámetros de Liston (2004).	ii
Tabla A-3: Resultados de calibración para las 14 subcuencas para los dos años de calibración 2005 y 2009.	iii

ÍNDICE DE FIGURAS

Figura 2-1:Esquema de balance energético en el manto nival. <i>Snowpack</i> significa manto de nieve.	9
Figura 2-2: Modos de transporte por viento.	12
Figura 2-3: Gráfico de información de ozono a 10 hPa para el 1 de febrero de 1997 basado en mediciones de ozono del MLS (Microwave Limb Sounder) a bordo del satélite UARS (Upper Atmosphere Research Satellite) de NASA.	17
Figura 3-2: Series de variables hidroclimáticas.	24
Figura 3-3: Mapa con áreas sobre la línea de nieves.	26
Figura 3-4: Curva hipsométrica de cuenca Río Tinguiririca Bajo Los Briones.	26
Figura 4-1: Esquema de asimilación que se utiliza.	30
Figura 5-1: Comparación de precipitación con estación La Rufina (Código BNA 06027003-1).	42
Figura 5-2: Comparación de temperatura atmosférica con estación La Rufina (Código BNA 06027003-1).	43
Figura 5-3: Análisis de sensibilidad DELSA sobre los parámetros.	45
Figura 5-4: Delimitación de subcuencas utilizadas en el modelo hidrológico.	46
Figura 5-5: Distribución de parámetros calibrados del modelo CRHM.	47
Figura 5-6: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca A.	48
Figura 5-7: Comparación de series diaria de fSCA.	50
Figura 5-8: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2014) para la subcuenca A para los años 2004 y 2005.	52
Figura 5-10: Desempeño en cuanto a $\Delta R2$, $\Delta RMSE$ y $\Delta Sesgo$ de las series de SWE con asimilación y sin asimilación.	55
Figura 5-11: Comparación de pronóstico de precipitación escalado con QDM (Cannon et al. 2015) y precipitación utilizada en DGA (2019).	56
Figura 5-12: Desempeño en cuanto a $R2$, $RMSE$ y $Sesgo$ de las series de SWE forzadas con los distintos pronósticos meteorológicos para cada subcuenca para los años 2004 y 2005.	58
Figura 5-13: Desempeño en cuanto a $\Delta R2$, $\Delta RMSE$ y $\Delta Sesgo$ de las series de SWE forzadas con pronósticos meteorológicos. E	59
Figura B-1: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca A.	iv

Figura B-2: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca B.	v
Figura B-3: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca C.	v
Figura B-4: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca D.	vi
Figura B-5: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca E.	vi
Figura B-6: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca F.	vii
Figura B-7: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca G.	vii
Figura B-8: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca H.	viii
Figura B-9: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca I.	viii
Figura B-10: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca J.	ix
Figura B-11: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca K.	ix
Figura B-12: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca L.	x
Figura B-13: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca M.	x
Figura B-14: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca N.	xi
Figura C-1: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2014) para la subcuenca A para los años 2004 y 2005.	xii
Figura C-2: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca B para los años 2004 y 2005.	xiii
Figura C-3: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca C para los años 2004 y 2005.	xiii
Figura C-4: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca D para los años 2004 y 2005.	xiv
Figura C-5: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca E para los años 2004 y 2005.	xiv
Figura C-6: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca F para los años 2004 y 2005.	xv

Figura C-7: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca G para los años 2004 y 2005. xv

Figura C-8: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca H para los años 2004 y 2005. xvi

Figura C-9: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca I para los años 2004 y 2005..... xvi

Figura C-10: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca J para los años 2004 y 2005. xvii

Figura C-11: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca K para los años 2004 y 2005. xvii

Figura C-12: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca L para los años 2004 y 2005.xviii

Figura C-13: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca M para los años 2004 y 2005.xviii

Figura C-14: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca N para los años 2004 y 2005. xix

Capítulo 1: Introducción

1.1. Motivación

En Chile, el conocer las características del manto nival (densidad, espesor y cobertura espacial) existente a fines del mes de agosto son fundamentales para estimar el volumen de agua disponible para toda la temporada de deshielo. Estos recursos son utilizados, por ejemplo, para la generación de hidroelectricidad, irrigación, suministro de agua potable (Cornwell et al., 2016) y procesos mineros, siendo requerido su pronóstico con anterioridad a la época de deshielo para planificar su uso en dicho período. Así, en Chile, las grandes empresas mineras e hidroeléctricas licitan cada año estos pronósticos para satisfacer sus necesidades.

No obstante lo anterior, la Dirección General de Aguas (DGA) genera, gratuitamente, un pronóstico del volumen de agua mensual probable, para distintas cuencas de Chile en el que es actualizado mensualmente entre los meses de septiembre y marzo,. Este pronóstico es de tipo estadístico y se puede resumir en cinco pasos: (1) agrupación de cuencas en zonas hidro climáticas similares considerando la serie de tiempo de volumen de deshielo, (2) determinación de la componentes principales que expliquen, al menos, el 90% de la varianza del volumen de deshielo estandarizado para cada grupo hidroclimático definido y generación de un conjunto de miembros para cada cuenca con distribución normal del volumen de deshielo estandarizado y su varianza, (3) comparación y elección del mejor modelo que simule las componentes principales del volumen de deshielo, los cuales consideran predictores físicos del año del cual se pronostica. Los predictores corresponden al índice de precipitación del período abril-agosto, caudal medio de agosto, el equivalente en agua de nieve máximo del 31 de agosto y el índice de oscilación del sur entre abril y agosto (SOI₃₈). (4) La generación de curva de probabilidad de excedencia de volúmenes de deshielo para cada cuenca y clasificación del año actual en año seco, normal y húmedo para desagregación mensual y posterior caudal mensual, y (5) inspección visual y corrección de la serie de caudales mensuales debido a diferencias en el caudal simulado en meses previos usando modelos estadísticos definidos para cada cuenca (DGA, 2014).

El modelo de la (DGA, 2014) tiene la necesidad de realizar mediciones de nieve (una al menos en cada zona hidroclimática) por lo que un método de muestreo o modelo podría disminuir los esfuerzos que conllevan las campañas de terreno. En esta línea, otros autores han propuesto mejorar el pronóstico de los caudales de deshielo sin información de terreno. por ejemplo, Cartes Valdivia (2009) utilizó información de cobertura nival de MODIS y redes neuronales para generar pronósticos y evaluar el volumen de deshielo mensual, el cual tuvo un error menor a 10% para el mes de diciembre en una de las tres cuencas analizadas. Barría (2010) pronosticó el volumen de deshielo mensual para el período octubre-marzo en las cuencas del río Baker y Pascua utilizando redes neuronales y modelos lineales. En particular, Barría (2010)

utilizó información pluviométrica, limnimétrica, meteorológica, fluviométrica y obtuvo coeficientes de determinación (R^2) cercanos a 0,9.

A pesar de que los métodos para pronosticar presentados requieran menos datos de terreno, es necesario precisar que estos poseen una discretización mensual y por ende no han profundizado en la resolución temporal del pronóstico. Así, estos métodos comprimen información correspondiente a discretizaciones temporales mayores que podrían ser beneficiosas para la planificación hídrica.

El SWE es un atributo que caracteriza el agua disponible en el manto nival el que cambia según características geográficas, vegetacionales y meteorológicas. Por ejemplo, la nieve tiene a formarse de manera orográfica lo que genera regiones alpinas con nieve en desmedro de zonas de menor elevación. La pendiente y orientación gobiernan la radiación que incide en la nieve pero también lo hace la obstaculización del terreno circundante. La vegetación intercepta y genera derretimientos más rápidos. El viento transporta la nieve a zonas más estables generalmente de menor elevación. A esto se suman procesos más específicos como la redistribución por gravedad (avalanchas) o la disminución del albedo por oscurecimiento de la nieve (Gray & Landine, 1987).

Para caracterizar el manto nival es común tomar muestras del manto nival mediante instrumentación, como *snowpillows*, o mediante imágenes *LiDAR* (acrónimo del inglés *Laser Imaging Detection and Ranging*) aéreo o terrestre, o en campañas de terreno. En Chile existen pocas estaciones de medición de características de la nieve, por lo que resulta complejo representar la evolución del manto nival mediante modelos hidrológicos. No obstante, el lanzamiento de satélites con fines científicos ha hecho posible la obtención de información que caracteriza el manto nival (Dozier & Painter, 2004).

El uso de imágenes satelitales del sensor MODIS (acrónimo del inglés *MOderate Resolution Imaging Spectroradiometer*) ha sido utilizado para asimilar la cobertura nival (SCA, por sus siglas en inglés; Thirel et al., 2013; Oaida et al., 2019; Smyth et al., 2019 ; Erxleben et al., 2002). El producto MOD10A1 (Hall & G. A. Riggs., 2021) presenta una resolución espacial media de 500 m. que es mayor que la de 25 km. del producto de SWE obtenido de la unificación de los sensores AMSR-E/AMSR2 y la resolución temporal diaria es mayor que los productos del sensor MSS de 16 días, haciendo de éste un producto posible de ser usado para dichos fines. En muchos casos la SCA ha sido complementada con curvas de agotamiento (SDC, por sus siglas en inglés; Aalstad et al., 2018 ; Margulis et al., 2016) para obtener el SWE distribuido espacial y temporalmente.

Finalmente, se han desarrollado múltiples pronósticos meteorológicos (SEAS5 del ECMWF, acrónimo del inglés *European Centre for Medium-Range Weather Forecasts*; Johnson et al., 2019) que utilizan ecuaciones de procesos físicos y que han mejorado continuamente utilizando asimilación de variables meteorológicas observadas puntuales a escalas regional y global.

Es necesario destacar que si bien el sistema atmosférico y sus condiciones iniciales no pueden medidos debido a limitantes en los sistemas de observación y a que el sistema atmosférico es sensible a errores en las condiciones iniciales no es posible pronosticar el clima más allá de 15 días en el futuro, aun cuando el modelo fuese perfecto. Sin embargo, algunos sistemas componentes de la biósfera evolucionan más lentamente, como lo son el océano y la criósfera. Estos sistemas retienen información sobre las condiciones iniciales durante más tiempo y su evolución puede ser predicha para mayores extensiones temporales. Estos sistemas no influyen en las variaciones (de las forzantes) meteorológicas diarias sino en las variaciones meteorológicas medias mensuales o estacionales (Johnson et al., 2019). En el caso de Chile, las precipitaciones se ven favorecidas por la ocurrencia del fenómeno interanual ENSO (*El Niño Southern Oscillation*). Montecinos & Aceituno (2003) mostraron que la ocurrencia del fenómeno El Niño (episodio cálido de ENSO) tiene relación con una mayor precipitación entre las latitudes 30° y 35°S durante invierno, entre las latitudes 35 y 38°S durante primavera tardía y entre 38 y menor precipitación entre las latitudes 38° y 41°S en verano en Chile. Y que la ocurrencia del fenómeno La Niña (episodio frío de ENSO) genera el escenario opuesto.

Debido a la búsqueda de pronosticar el SWE de la temporada de deshielo sin la necesidad de realizar campañas de terreno y al desarrollo tanto de productos satelitales que miden variables que caracterizan el manto nival y de pronósticos estacionales que estiman variables meteorológicas necesarias para resolver ecuaciones matemáticas animan la aplicación de modelos de base física para estimar la cantidad de SWE para la temporada de deshielo.

1.1. Objetivo general

Pronosticar el SWE mediante el modelo de base física CRHM de manera retrospectiva para asimilar observaciones de fSCA del producto MOD10A1 distribuidas espacial y temporalmente durante la época de deshielo entre los años 2003 a 2012, en la cuenca alta del río Tinguiririca, Chile.

1.2. Objetivos específicos

Para lograr el objetivo de la presente memoria se propone:

- 1) Caracterizar espacial y temporalmente el manto nival de la cuenca de estudio mediante el producto satelital MOD10A1.
- 2) Implementar el modelo CRHM en la cuenca alta del río Tinguiririca.
- 3) Asimilar la fSCA del producto MODIS para mejorar la simulación de series de SWE. Evaluar la aplicación de la asimilación de datos en las series de SWE.
- 4) Escalar predicciones meteorológicas estacionales a escala de URH. Posteriormente, pronosticar el SWE para la temporada de deshielo y evaluar el pronóstico de SWE.

1.3. Organización de la memoria

En lo que sigue del documento, se encuentra el capítulo 2, donde se presentan los conceptos y recursos bibliográficos revisados para desarrollar la memoria. El capítulo 3 describe la zona de estudio y su caracterización hidroclimática. En el capítulo 4 se presentan los conjuntos de información y la metodología propuesta. En el capítulo 5 se presentan los resultados y en el capítulo 6 se presentan las conclusiones que se obtienen de la memoria.

Capítulo 2: Marco Teórico

A continuación, se abordan conceptos básicos del manto nival necesarios para el estudio y se presentan los recursos bibliográficos que contextualizan la teoría de los métodos utilizados en este trabajo.

2.1. Conceptos básicos

2.1.1. El manto nival

Se llama manto nival al volumen de nieve que cubre una extensa área¹. Están conformados por una o múltiples capas de nieve debido a la acumulación de una o sucesivas nevadas a lo largo de un periodo de tiempo. Es por este motivo que poseen una naturaleza verticalmente anisótropa y heterogénea (Bravo, 2018).

Los atributos que se utilizan para caracterizar el manto nival consisten principalmente en la cuantificación de la masa, energía y propiedades ópticas que posee el manto nival, los cuales permiten generar balances de energía y determinar la cantidad de masa que se derretirá o recongelará. Algunos atributos que caracterizan el manto nival son la densidad, el contenido de humedad, el contenido de frío o el albedo de la nieve.

Se mencionan a continuación los atributos más importantes del manto nival para este trabajo y los procesos que modifican la distribución espacial, en particular, del SWE.

2.1.2. SWE

El equivalente en agua de nieve se define como la altura de agua líquida que generaría el derretimiento del manto nival por unidad de área en condiciones estándar. La distribución espacial del SWE determina la evolución temporal del derretimiento, por ende, tiene directa relación con el caudal de deshielo. El SWE se define según la ecuación (2.1) (DeWalle & Rango, 2008).

$$SWE = z_s \frac{\rho_s}{\rho_w} \quad (2.1)$$

Donde:

SWE: Equivalente en agua de nieve, mm de columna de agua.

z_s : Altura de nieve, mm

ρ_s : Densidad de la nieve, Kg/m³.

ρ_w : Densidad del agua a 0°C, Kg/m³.

¹ Longman. Obtenido desde: <https://www.ldoceonline.com/dictionary/a-mantle-of-snow-darkness-etc>

2.1.3. Contenido de frío

El contenido de frío representa la cantidad de agua líquida que debe ser incorporada en el manto nival para que éste se eleve a una temperatura isotermal de 0°C. El contenido de frío se calcula según la ecuación (2.2) (DeWalle & Rango, 2008).

$$CC = \rho_s c_i \frac{273,16 - T}{\rho_w L_f} \quad (2.2)$$

Donde:

CC : Contenido de frío, m de agua.

ρ_s : Densidad promedio del manto nival, kg/m³.

c_i : Calor específico del hielo, J/Kg/m³.

T : Temperatura promedio del manto nival °K.

ρ_w : Densidad agua líquida, 1000 kg/m³.

L_f : Calor latente de fusión J/kg.

2.1.4. Agua líquida en la nieve

El agua líquida presente en el manto nival incluye el agua que se encuentra desplazándose producto de derretimiento o precipitación reciente y el agua que se encuentra almacenada debido a fuerza gravitacionales. El contenido de agua líquida de la nieve es expresado como un porcentaje volumétrico o un porcentaje másico (DeWalle & Rango, 2008).

2.1.5. Albedo

El albedo se define como el porcentaje de radiación de onda corta que refleja una superficie. El albedo de la nieve varía entre ~0,95 (nieve fresca) hasta valores de 0,4 cuando la nieve tiene un alto tiempo de vida o cuando tiene suciedades (DeWalle & Rango, 2008). Por otro lado, su modelación se hace compleja debido a los múltiples factores que afectan el albedo. Existen relaciones empíricas que estiman su valor en función de variables más simples. U.S. Army Corps of Engineers (1956), Anderson (1976) han modelado el decaimiento del albedo utilizando solo la temperatura en el primer caso y solo la densidad de nieve en el segundo caso. Rohrer & Braun (1994) determinó una relación empírica en función del tiempo que ha transcurrido desde la última nevada, la que se muestra en la ecuación (2.3) donde el coeficiente de recesión es 0,05 para temperaturas menores a 0°C y 0,12 para temperaturas mayores a 0°C.

$$\alpha = \alpha_0 + K \exp(-nr) \quad (2.3)$$

Donde:

α : Albedo de la nieve, sin unidades.

α_0 : Mínimo albedo de la nieve, $\cong 0,4$.

K : Constante, $\cong 0,44$.

n : Días desde la última nevada.

r : Coeficiente de recesión.

2.1.6. Balance másico

El manto nival es un almacenamiento del recurso hídrico, en el cual los flujos de entrada y salida están bien identificados. Los flujos de entrada principalmente se componen de precipitación sólida y líquida y condensación del vapor de agua, en cambio, los flujos de salida principalmente se componen volumen de agua que sale como efluente y de la sublimación del manto nival.

Una vez que la nieve se derrite y se transforma en agua líquida puede transformarse en escorrentía, flujo intermedio, o flujo subterráneo dependiendo de las características del suelo.

Existen muchas formas de expresar el balance másico dependiendo de los supuestos que se utilicen. Por ejemplo, DeWalle & Rango (2008) solo consideran precipitación, sublimación y fusión, J. W. Pomeroy et al. (2007) considera transporte por viento y distribuye el término sublimación en sublimación de superficie y sublimación por viento. Este modelo de balance de masa es el que se muestra en a que se muestra en la ecuación (2.4), el que es aplicado sobre un volumen de control definido.

$$\frac{dSWE}{dt}(x) = P - \rho \left[\nabla F(x) + \frac{\int E_B(x) dx}{x} \right] - E - M \quad (2.4)$$

Donde:

$\frac{dSWE}{dt}$: Diferencial temporal de SWE en el volumen de control, Kg/m²/s.

P : Tasa de precipitación sólida, Kg/m²/s.

ρ : Densidad de la nieve, Kg/m³.

$\nabla F(x)$: Gradiente de transporte por viento, Kg/m²/s.

$E_B(x)$: Tasa de sublimación del transporte por viento, Kg/m²/s.

x : Fetch de viento que posee el volumen de control, m.

- E : Tasa de evaporación de la nieve que se encuentra en la superficie, Kg/m²/s.
 M : Tasa de derretimiento de la nieve, Kg/m²/s.

2.1.7. Balance energético

El balance energético es la suma de los flujos energéticos que ocurren en el manto nival y es el que determina el derretimiento o recongelamiento de la nieve. Los flujos energéticos tienen mayor o menor importancia dependiendo de la zona que se está estudiando. Se puede escribir el balance energético como aparece en la ecuación (2.5) donde todos los sumandos tienen unidades del W/m² (J. W. Pomeroy et al., 2007).

$$\frac{dU}{dt} = Q_m + Q_n + Q_H + Q_E + Q_G + Q_D \quad (2.5)$$

Donde:

$\frac{dU}{dt}$: Variación de energía interna del manto nival.

Q_m : Flujo energético que sale debido a derretimiento.

Q_n : Radiación neta (onda corta y onda larga).

Q_H : Flujo energético de calor sensible debido a flujos turbulentos.

Q_E : Flujo energético de calor latente debido a flujos turbulentos.

Q_G : Flujos de calor con el suelo.

Q_D : Flujo de calor debido a la advección de masas, como por ejemplo de aire o precipitación.

En la Figura 2-1 se ejemplifica el balance energético el que especifica las variables descritas en la ecuación (2.5), en la cual K y L corresponden a la radiación de onda corta y larga respectivamente y $\uparrow\downarrow$ corresponden al sentido del flujo, es decir si entra o sale del manto nival. Q_H y Q_E corresponden a los flujos de calor debido a flujos turbulentos de calor sensible y latente respectivamente debido a flujos turbulentos. P corresponden al flujo energético de precipitación y T corresponde al flujo de calor por transporte de nieve y ambas variables conforman Q_D . El Q_m corresponden a los flujos por derretimiento y por ende, pérdida de masa y el flujo Q_G al flujo con el suelo.




Figura 2-1: Esquema de balance energético en el manto nival. *Snowpack* significa manto de nieve. Fuente: Modificado de Pomeroy et al. (2007).

Male & Granger (1981) compararon resultados de 15 estudios que mostraban que la radiación neta explica cerca de un 59% del total del intercambio energético, mientras que los intercambios debido a convección del calor sensible y latente representan cerca del 10% y 35%, respectivamente, del total del intercambio energético. Prowse & Owens (1982), Cline (1997) y Hong & Yifeng (1992) midieron los flujos radiativos y analizaron la proporción de los flujos netos radiativos (onda corta y larga) sobre los flujos convectivos (de calor sensible y latente, encontrando valores entre 17 y 42, 75 y 76 % respectivamente. Cabe destacar que en los estudios que se mencionan, existe una relación, la cual no se presentó en los estudios, que señalaría que a mayor altitud la proporción antes dicha sea mayor.

2.1.8. Transferencia de calor en el manto nival

Una vez que los flujos energéticos se han embebido en el manto nival, ya sea por la superficie o por la interfaz nieve-suelo, estos son propagados, principalmente, por tres procesos:

- a) Conducción a través de matriz sólida del hielo
- b) Conducción del aire a través de los poros del manto nival
- c) Intercambio de calor latente debido a la difusión molecular del vapor de agua.

El intercambio térmico es fuertemente controlado por la conducción a través de matriz sólida de hielo debido a la diferencia entre conductividad termal entre la nieve y el aire (DeWalle & Rango, 2008). La conductividad térmica de la nieve se agrupa, para fines

prácticos, en una conductividad térmica efectiva como la combinación de los efectos anteriores. Así, la ecuación de calor (2.6) se puede escribir como:

$$q = -k_{eff} \frac{dT}{dz} \quad (2.6)$$

Donde:

q : Flujo de calor que se conduce por el manto nival, W/m².

k_{eff} : Conductividad térmica del manto nival, W/m/°K.

dT/dz : Gradiente térmico, °K/m.

2.2. Procesos de distribución del SWE

La distribución de la nieve es dinámica y cambia estacionalmente, incluso a escala diaria o sub-diaria. Los procesos que modifican la distribución espacial de la nieve tienen distintas escalas de acción. Los procesos atmosféricos y patrones que gobiernan las tormentas y la formación de la precipitación sólida determinan la distribución espacial a escala regional, 10 a 1000 km (Stewart et al., 1998). La elevación, la pendiente y la orientación del terreno regulan el monto de la radiación para derretimiento que recibe el manto de nieve a escala local, 100 m a 10 km (Déry & Yau, 1999). La redistribución por viento y la intercepción por vegetación determinan la distribución de SWE a escala pequeña, 10 a 100 m (McKay & Gray, 1981).

2.2.1. Intercepción por vegetación

Las nevadas a menudo interactúan con la vegetación antes de que se forme el manto nival. El proceso en el cual la nieve se acumula en la vegetación se denomina intercepción por vegetación. La nieve puede depositarse posteriormente en el suelo debido a la acumulación de peso sobre los tallos y ramas o puede derretirse y fluir por medio de los tallos y ramas hasta llegar al suelo. Cuando la nieve se sublima o evapora desde la vegetación se denomina pérdida por intercepción (DeWalle & Rango, 2008).

J. Pomeroy et al. (1998) propusieron un modelo basado en un coeficiente empírico de descarga según la especie vegetal, la máxima carga de nieve que puede soportar por área de ramas y la fracción de área que ocupa la cubierta vegetal vista en planta, además de la cantidad de nieve interceptada existente. El modelo de J. Pomeroy et al. (1998) se traduce en las ecuaciones (2.7), (2.8) y (2.9).

$$I = I_1 e^{-U t} \quad (2.7)$$

$$I_1 = (L^* - L_0) \left(1 - e^{-\frac{c_p P}{L^*}}\right) \quad (2.8)$$

$$L^* = \bar{S} \left(0,27 + \frac{46}{\rho_s}\right) LAI \quad (2.9)$$

Donde:

I : Masa de nieve interceptada por vegetación, Kg.

I_1 : Intercepción de nieve antes de la descarga, Kg.

U : Coeficiente de descarga de nieve, 1/días.

t : Tiempo desde la nevada anterior, días.

L^* : Máxima carga de nieve que puede ser interceptada, Kg.

L_0 : Carga de nieve interceptada inicial, Kg.

c_p : Máxima área de contacto nieve-hoja por unidad de suelo.

P : Nieve caída, Kg.

\bar{S} : Máxima carga de nieve por unidad de área de ramas, Kg/m². Depende de la especie vegetal.

ρ_s : Densidad de nieve, Kg/m³.

LAI : Índice de área folial.

Otro modelo es el de J. W. Pomeroy et al. (2002) que determina la intercepción en función de la densidad de cubierta vegetal, el índice de área folial y la masa de nieve que se encuentra bajo los árboles. Moeser et al. (2015) plantea otro modelo basado en la intercepción máxima y la precipitación sólida acumulada, el que mejora a un R² de 0,64 en comparación a un 0,39 obtenido al usar el modelo de J. Pomeroy et al. (1998)

Entre las características propias de la especie de vegetación y meteorológicas que afectan la intercepción están la temperatura del aire, la cual cuando es cercana 0°C aumenta la cohesividad de la nieve lo que lleva a mayor almacenamiento de nieve en la vegetación. Por el contrario, temperaturas bajo 0°C induce una menor cohesividad y si, además, existe la presencia de vientos, el almacenamiento de nieve en la vegetación disminuye. La precipitación que ocurre sobre las especies vegetativas puede generar dos efectos, el aumento de almacenamiento en la vegetación o caída de la nieve debido al peso (DeWalle & Rango, 2008).

2.2.2. Transporte por viento

El viento transporta la nieve, la cual puede sublimarse o llegar a depositarse sobre la superficie. Este proceso produce una distribución irregular del manto nival. El transporte por viento y su magnitud afecta la sublimación por viento, el cual, a su vez, es afectado por características del terreno como espacios abiertos o la presencia de árboles o vegetación que intercepten la nieve.

Existen tres modos mayores de transporte por viento los que son: (1) suspensión turbulenta, (2) saltación y (3) arrastre. El primero ocurre cuando los flujos de viento pueden mantener suspendidos los granos de nieve en el aire. El segundo ocurre cuando los remolinos y flujos abruptos de aire transportan los granos de nieve, pero no lo suficiente para mantenerlos suspendidos. El tercero ocurre cuando las partículas ruedan producto de la fuerza del viento (DeWalle & Rango, 2008). En la Figura 2-2 se esquematizan los modos de transporte por viento en la cual se aprecia que estos transportan tamaños de partículas de nieve preferentes, es decir la suspensión turbulenta afecta principalmente partículas más pequeñas que las que transporta la saltación, y ésta a su vez que las que transporte el arrastre.




Figura 2-2: Modos de transporte por viento. Fuente: Modificado de DeWalle & Rango (2008).

2.2.3. Sublimación del transporte por viento

La sublimación es producto de los flujos radiativos y se ve aumentada cuando las partículas de nieve son transportadas por viento, debido a una mayor exposición superficial de la partícula con los flujos de aire, extrayendo el calor latente de estos. Como consecuencia, el aire aumentará gradualmente en humedad.

Las pérdidas por sublimación se estiman mediante modelos entre 10-15% de nevazón anual en lugares fríos o sin presencia de viento y hasta un 40% en lugares cálidos y ventosos. (Xiao et al., 2000; Déry & Yau, 1999).

2.3. *Cold Regions Hydrological Model (CRHM)*

El modelo *Cold Regions Hydrological Model (CRHM)* (J. W. Pomeroy et al., 2007) desarrollado en la Universidad de Saskatchewan, Canadá, es un modelo de base física que tiene por objetivo realizar modelación de recursos hídricos en zonas frías, donde la nieve, hielo, permafrost y los procesos que modelan la distribución de la nieve cobran

relevancia. Este modelo es un modelo semi distribuido pues utiliza unidades de respuesta hidrológica (URH) como unidad de modelación, las cuales tienen propiedades físicas como latitud, pendiente, orientación y elevación. En cuanto a resolución temporal puede ocuparse hasta una resolución horaria.

Este modelo resuelve la ecuación de masa incluyendo términos como precipitación, transporte por viento, sublimación por viento, sublimación por radiación y derretimiento. También resuelve la ecuación de balance energético considerando las componentes producto de conducción, convección, advección y radiación.

El modelo funciona en base a módulos que se acoplan según los requerimientos del usuario o la disponibilidad de información de forzantes meteorológicas o variables físicas. Los módulos se pueden clasificar según el proceso físico o hidrológico que se esté representando

En Chile se ha utilizado el modelo CRHM en varias oportunidades debido a las regiones montañosas que existen en la Cordillera de Los Andes. Comte (2017) utilizó el modelo en las cuencas Mapocho en Los Almendros con el fin de representar bien el caudal medido en las estaciones fluviométricas obteniendo coeficientes de Nash-Sutcliffe (NSE) de 0,74 y obteniendo una buena modelación de fSCA. Vásquez (2018) modeló las cuencas río Cochiguaz en el Peñón, estero Derecho en Alcohuaz y río Toro antes junta río La Laguna con información satelital e información fluviométrica obteniendo coeficientes de Nash-Sutcliffe entre 0,7 y 0,9. Finalmente, Gómez (2019) modeló la cuenca Mapocho en Los Almendros para comparar el SWE en la estación Valle Nevado, obteniendo un NSE de 0.84. Esto indica que el modelo no solo simula bien el caudal a la salida de la cuenca sino también, variables importantes del manto nival como el fSCA o el SWE.

2.4. Percepción remota del manto nival

En la actualidad, es posible obtener información del manto nival mediante percepción remota. Sin embargo, no todos los sensores son útiles para obtener información acerca del manto nival. Algunos de ellos tienen ventajas y desventajas que hacen que sean complementarios. A continuación, se muestra un resumen de las principales ventajas y desventajas de los sensores más utilizados, ordenados por espectro electromagnético, para monitorear distintas características del manto nival.

2.4.1. Espectro visible e infrarrojo cercano

El espectro visible es una primera fuente de la cual se podría extraer información pues es fácil distinguir propiedades como la SCA. Este espectro tiene limitantes para diferenciar la cobertura nival y glacial y no se puede obtener el equivalente en agua de nieve, además, la presencia de nubes limita las observaciones.

Cada satélite tiene sus ventajas y desventajas, que pueden servir para cada situación que se esté analizando. En la Tabla 2-1 se muestran las principales características de

los sensores para monitorear el manto nival. Se ha usado la banda roja del sensor MSS presente en los satélites Landsat para mapear la extensión del manto nival por el contraste que tiene con áreas libres de nieve. También se ha usado la banda roja del sensor TM y ETM+ pero, estos sensores tienen limitantes para muestrear el manto nival pues tienen una baja frecuencia de toma de muestras de entre 16 a 18 días. Si se suma la presencia de nubes, la cantidad resultante de imágenes no es suficiente para llevar un muestro que sea completo. AVHRR se ha usado para mejorar esta limitante, pero la resolución espacial de 1100 m es insuficiente para muestrear los cambios que presenta el manto nival. El sensor MODIS con una resolución de 250 m y frecuencia de muestreo diaria puede capturar con precisión el cambio temporal del manto nival. Este sensor se ha utilizado en conjunto con otros para complementar los sets de datos de y aumentar la resolución temporal de las observaciones de los sensores anteriores. El sensor MERIS, a bordo del satélite ENVISAT, con una resolución de 300 m en nadir y resolución temporal diaria tiene oportunidades de ser una fuente de información para estas aplicaciones las cuales no se han explorado en profundidad (DeWalle & Rango, 2008).

Tabla 2-1 Sensores más idóneos para monitorear cubierta nival usando espectro visible e infrarrojo cercano. Fuente: Modificado de DeWalle & Rango, (2008).

Satélite	Sensor	Resolución espacial	Resolución temporal	Ancho de franja de muestreo	Año de lanzamiento
NOAA	AVHRR	1100 m	Mitad de un día	2400-3000 km	1972
Landsat	MSS	80 m	16 días	185 km	1972
	TM	30 m	16 días	185 km	1982
	ETM+	15 m	16 días	186 km	1999
NOAA	GOES	1100 m	Mitad de un día	Geoestacionario	1975
DMSP	OLS	600 m	3 días	3000 km	1982
Terra/Aqua	MODIS	250, 500 1000 m	Diaria	2300 km	1999
	ASTER	15, 30 m	16 días	60 km	1999

2.4.2. Infrarrojo termal

Esta longitud espectral tiene la ventaja que se puede realizar durante el muestreo nocturno del satélite pero, tiene un menor potencial para aplicaciones de hidrología pues tiene la limitante de que es afectada por la presencia de nubes. Esto porque las diferencias de temperatura entre el ambiente y el manto nival son bajas no es posible distinguir ambas extensiones de buena manera.

2.4.3. Microondas

Se ha demostrado que mantos nivales más profundos dispersan la temperatura de brillo (T_B) de la superficie bajo la nieve y por lo tanto es posible generar una relación estadística entre el SWE y la temperatura de brillo. Además, el tamaño de las partículas de nieve afecta la temperatura de brillo (Hall et al., 1986), pero una de las ventajas de este método es que se puede utilizar indiferente del tiempo meteorológico (Chang et al., 1997).

Rott et al. (1993) propuso que los algoritmos para derivar el SWE se pueden generalizar según se muestra en la ecuación (2.10).

$$SWE = A + B(T_B(f_1) - T_B(f_2))/(f_2 - f_1) \quad (2.10)$$

Donde A y B son coeficientes de la regresión lineal. T_B es la temperatura de brillo, f_2 es el canal de alta dispersión, que usualmente es 37 GHz y f_1 es el canal de baja dispersión, comúnmente 18 o 19 GHz.

Chang et al. (1997) planteó una ecuación específica para una capa de nieve de radio medio de partícula de nieve de 0,3 mm y densidad de 300 Kg/m³ que se muestra en la ecuación (2.11).

$$SWE = 4,8 (T_{18H} - T_{37H}) \quad (2.11)$$

Donde T_{18H} y T_{37H} son las temperaturas de brillo para las bandas de 18 y 37 GHz respectivamente en polarización horizontal. Obtuvo una buena estimación del SWE al compararlo con mapas de nieve a excepción por regiones boscosas y de tundra de alta latitud (Chang et al., 1997).

Los sensores que proveen percepción remota de ondas microondas presentan ventajas sobre otros sensores, por ejemplo el sensor SSM/I provee cobertura sub-diaria de la mayoría de las áreas con nieve y permite la oportunidad de estudiar la variabilidad diurna de la nieve. Por otro lado, el sensor SAR tiene una ventaja adicional al tener resolución espacial de 25 m haciéndolo útil para mantos nivales de montaña (DeWalle & Rango, 2008).

2.4.4. Productos MODIS

El sensor MODIS a bordo de los satélite Terra (EOS AM) y AQUA (EOS PM) fueron lanzados al espacio en los años 1999 y 2002 respectivamente. Tienen un espectro de observación compuesto por 36 bandas entre 0,4 y 14,4 μm con una resolución espacial que va desde 250 m a 1000 m dependiendo de la banda.

El uso de productos MODIS ha sido común para asimilar el SCA (Thirel et al., 2013; Oaida et al., 2019). MODIS presenta una resolución espacial media (500 m) mayor que

otros productos satelitales y una resolución temporal diaria, haciendo de éste un producto posible de ser usado para dichos fines. En muchos casos, la SDC (Aalstad et al., 2018; Margulis et al., 2016) se utiliza para obtener el SWE distribuido espacial y temporalmente. Larue et al. (2018) asimilaron la temperatura del sensor MODIS en conjunto con el sensor AMSR-2 en el norte de Canadá. Todos presentaron mejoras en las estimaciones del modelo.

2.5. Asimilación de datos

Normalmente se trabaja con modelos para representar el comportamiento de un sistema y realizar estudios frente a distintos escenarios, pronósticos o reanálisis. Por otro lado, existen observaciones del sistema, como lo son mediciones de estados y/o variables hidrológicas, que contienen información que sería útil de incorporar en el modelo del sistema. Sin embargo, no se pueden incorporar de manera directa debido a que el modelo puede no representar explícitamente aquella variable o pueden infringir las ecuaciones físicas que rigen el modelo. El proceso que une ambas fuentes de información mediante técnicas específicas considerando las limitantes antes dichas se llama asimilación de datos.

La asimilación se define como *“los procedimientos que apuntan a producir representaciones físicas consistentes o estimaciones del comportamiento dinámico de un sistema al unir información de modelos imperfectos e incertidumbre de las observaciones de una manera óptima para cuantificar y reducir la incertidumbre”* (Liu & Gupta, 2007).

Según Lahoz et al. (2010) las observaciones poseen errores que son de tres tipos: (1) aleatorios, (2) sistemáticos y (3) de representatividad. Los primeros se producen por la capacidad de medición de los instrumentos y la propagación de éstos en las ecuaciones tienen la propiedad que pueden ser reducidos mediante la acción de promediar varias mediciones, los segundos no pueden ser reducidos mediante la acción de promediar y solo pueden ser eliminados si son conocidos y los terceros están asociados con la diferencia entre la resolución de la observación y el modelo que interpreta la información (Lahoz et al., 2010).

Otro aspecto importante es que las observaciones son discretas en el tiempo y espacio y por lo tanto poseen vacíos de información (véase Figura 2-3). Es deseable rellenar los vacíos de información para que sea más útil y para cuantificar las características de la información, que es más fácil de hacer en una escala regular que en una irregular (Lahoz et al., 2010).




Figura 2-3: Gráfico de información de ozono a 10 hPa para el 1 de febrero de 1997 basado en mediciones de ozono del MLS (Microwave Limb Sounder) a bordo del satélite UARS (Upper Atmosphere Research Satellite) de NASA. Muestra las características de vacíos espaciales del dominio del sistema. Fuente: Lahoz et al. (2010).

De manera paralela, se sabe que los modelos son sólo una representación de la realidad y por ende tienen errores. Un modelo se puede componer de las siguientes componentes: bordes, forzantes, estado inicial, parámetros y estructura del modelo. De cada uno de los componentes pueden surgir errores, los cuales se pueden resumir en tres tipos de errores: (1) errores estructurales, (2) errores paramétricos y (3) errores de información. Los primeros son debido a falta de entendimiento de los procesos y formulación de sus ecuaciones matemáticas. Los segundos tienen relación con la imprecisión de los parámetros al ser promedios espaciales o temporales de las características de un sistema. Los últimos tienen relación con la representación de las forzantes y estado inicial del sistema (Liu & Gupta, 2007).

Los métodos de asimilación de datos tienen como supuestos que los errores de las observaciones y modelos son de tipo aleatorios y, por lo tanto, es necesario corregir errores sistemáticos y de representatividad. Una vez que ya se realizó la corrección de errores, la asimilación de ambas partes, observaciones y modelo genera beneficios entre los que están la generación de observaciones de mayor resolución, acercamiento entre los estados del modelo y observaciones y la disminución de los errores (Lahoz et al., 2010). Los métodos de asimilación se pueden clasificar en métodos de filtrado (*filters*) y de suavizado (*smoothing*) (Liu & Gupta, 2007).

2.5.1. Métodos de filtrado

Los métodos de filtrado se usan para corregir de manera recursiva la estimación o corrección de los estados de un sistema cada instante en que la observación (Liu & Gupta, 2007). Entre los métodos de filtrado más utilizados se encuentra el Filtro de

Kalman (Kalman, 1960), el filtro de Kalman extendido (EKF; Jazwinski, 1970), el filtro de Kalman de conjuntos (EnKF; Evensen, 1994) y el filtro de partículas.

El Filtro de Kalman usa el supuesto que los errores del modelo y de las mediciones son de tipo gaussiano y que el modelo es de tipo lineal. Actualiza el estado del modelo mediante un algoritmo que minimiza la varianza de los errores de las observaciones y del modelo con respecto al nuevo estado del modelo. Este método no considera los principios de conservación de energía, masa y *momentum* a lo largo de la actualización.

Versiones modificadas del Filtro de Kalman se han implementado para resolver el supuesto de linealidad del modelo, Extended Kalman Filter (EKF) y Ensemble Kalman Filter (EnKF) son métodos que se basan en una actualización tangencial modelo y en una evolución no lineal que se realiza mediante Monte Carlo respectivamente.

El EnKF es un método que consiste en actualizar el estado del sistema mediante una matriz que considera el error asociado al modelo y el error asociado a las observaciones, generando un estado intermedio entre ambos estados. La no linealidad se considera mediante la generación de varias predicciones perturbadas mediante métodos de Monte Carlo para cada paso de tiempo. El filtro de Kalman de conjuntos se ha usado en múltiples estudios (Charrois et al., 2016; Stigter et al., 2017) particularmente para asimilar el SCA y la profundidad de nieve.

Los supuestos que utiliza el método EnKF, es que los residuos deben ser aleatorios, lo que no se cumple cuando los datos presentan sesgo (Kumar et al., 2012). Se debe, entonces, utilizar un método de corrección de sesgo tanto para el modelo como para las observaciones, el que puede ser el de escalamiento o de curva de frecuencia acumulada de los datos (Kumar et al., 2012).

2.5.2. Métodos de suavizado

Los métodos de suavizado son usados para estimar los estados del modelo de varios instantes de tiempo en un intervalo de tiempo definido mediante la minimización de una función objetivo que corresponde al método de mínimos cuadrados o alguna aproximación aplicada entre las observaciones y las observaciones obtenida de la transformación de los estados del modelo. El método más utilizado corresponde al método de asimilación variacional que también se puede llamar 1D-Var, 3D-Var y 4D-Var dependiendo de cuantas dimensiones temporales y espaciales utilice el modelo (Liu & Gupta, 2007).

El método de asimilación de datos variacional resuelve el suavizado de los estados de un sistema sobre una ventana de tiempo y así disminuye la suma de los errores de los estados del sistema. Obtiene el set de estados iniciales y/o parámetros óptimos que minimizan el error del conjunto de observaciones. Es decir se realiza cuando ya se tienen todas las observaciones del sistema en una ventana de tiempo. Este método se

utiliza para reanálisis y mejorar las series de variables hidrológicas que han ocurrido en el pasado una vez obtenidas todas las observaciones que ocurrieron durante el período.

Tiene la ventaja de que satisface las ecuaciones de continuidad del modelo en todo momento por ende se complementa bien con modelos de base física. Tiene la desventaja que es más costoso computacionalmente, pues comúnmente se asimilan varias fuentes de información, distribuida espacial y temporalmente en el caso de trabajar con modelos físicos distribuidos.

A diferencia de los métodos de filtrado no requiere actualizar el estado del sistema a medida que se obtengan observaciones debido a que la simulación se realiza una vez. Sin embargo, los estados y/o parámetros óptimos que se obtienen dependen fuertemente de la ventana en la cual se realiza la asimilación por lo que es mejor asimilar en una ventana temporal que contenga varios escenarios hidrológicos o generar un conjunto de parámetros asimilados en distintos escenarios hidrológicos con el fin de que la validación de los parámetros y/o estados represente bien escenarios hidrológicos que no se hayan considerado.

2.5.3. Curvas de agotamiento (SDC)

La curva de agotamiento se ha utilizado para relacionar la fSCA y la profundidad de nieve -y por ende el SWE suponiendo densidad media-. Estas se basan en que la distribución espacial del SWE en un área se puede parametrizar con una función de distribución y que al sufrir derretimiento homogéneo la función de distribución no cambia.

Thirel et al. (2013) y Margulis et al. (2016) usaron la parametrización formulada por Liston (2004) y que ha sido corroborada en el pasado por Donald et al. (1995). Esta parametrización supone una acumulación de SWE o distribución subgrilla dada por la función de distribución tipo log-normal con parámetros media y desviación estándar, además de supuestos de tasa de derretimiento homogéneo y una muy usada en modelación hidrológica de precipitación homogénea en una celda de modelo durante el período de acumulación.

Un desafío que tiene esta parametrización es el de precipitaciones ocasionales durante la temporada de derretimiento ya que si se tiene un manto nival somero una fSCA entre cero y uno y precipita, el valor de la fSCA en el sistema verdadero cambia a uno cambiando la función de distribución subgrilla. Liston (2004) resuelve este desafío usando un algoritmo de iteración de rápida convergencia para obtener nuevos parámetros de distribución subgrilla.

Oaida et al. (2019) utilizó el algoritmo de SDC propuesto por Cherkauer & Lettenmaier (2003) que se basa en parametrizar la distribución subgrilla de la profundidad de nieve con una función de distribución gamma o log-normal y que además considera mantos nivales que no han acumulado la profundidad de nieve necesaria para que su

distribución sea igual a la de la parametrización y efecto de precipitación ocasional homogénea sobre manto nival somero.

2.6. Pronósticos meteorológicos estacionales

Los pronósticos carecen de certeza más allá de 10 a 15 días desde la fecha de inicio de pronóstico debido a la sensibilidad del sistema a pequeños cambios y errores en las condiciones iniciales. Sin embargo, es posible pronosticar a escalas de semanas, meses y años debido a la lenta evolución que tienen ciertos componentes del sistema Tierra como lo son el océano y la criósfera. Estos sistemas no permiten una gran certeza en el pronóstico del tiempo a escala diaria pero si lo pueden hacer para el promedio mensual o estacional (Johnson et al., 2019).

Los pronósticos meteorológicos son creados usando modelos numéricos. En particular el modelo SEAS5 (Johnson et al., 2019) del ECMWF resuelve las ecuaciones hidrodinámicas que describen la evolución de la atmósfera y el océano y genera un conjunto de trayectorias al considerar el error del estado inicial del sistema y así disminuyendo su error. Por el contrario, errores sistemáticos pueden aparecer dependiendo de la estación, región o del tiempo transcurrido desde el inicio del pronóstico. Este sesgo puede ser estimado al comparar retrospectivamente observaciones meteorológicas con pronósticos retrospectivos (Johnson et al., 2019).

2.7. Métricas de evaluación

Las métricas de evaluación del pronóstico que se utilizan son la raíz del error cuadrático medio (RMSE), el sesgo medio, el coeficiente de determinación (R^2) y diferencias de las anteriores.

El coeficiente de determinación que se define en la ecuación (2.12) muestra la correlación que existe entre la variable estimada y la variable observada. Dicho de otra manera, que fracción de la varianza observada puede ser explicada por la varianza de la estimación. El dominio de la métrica de evaluación es entre 0 y 1 siendo 1 el ajuste perfecto.

$$R^2 = 1 - \frac{\sigma_r^2}{\sigma^2} \quad (2.12)$$

Donde:

R^2 : Coeficiente de determinación.

σ_r^2 : Varianza de los errores.

σ^2 : Varianza de la variable estimada.

La raíz del error cuadrático medio (RMSE) que se define en la ecuación (2.13) es una medida de la precisión de la estimación y minimiza la magnitud de los errores cuadrados. El dominio es entre 0 y $+\infty$, siendo 0 el ajuste perfecto.

$$RMSE = \sqrt{\frac{\sum_i^N (y_i^o - y_i^s)^2}{N}} \quad (2.13)$$

Donde:

RMSE: Raíz del error cuadrático medio.

y_i^o : Variable observada en el tiempo *i*.

y_i^s : Variable simulada en el tiempo *i*.

N: Número de observaciones.

El sesgo medio que se define en la ecuación (2.14) es una medida de precisión pero, además informa si la variable estimada subestima o sobrestima la variable observada. El dominio del sesgo es entre $-\infty$ y $+\infty$ siendo el valor 0 el ajuste perfecto.

$$Sesgo = \frac{\sum_i^N (y_{sim,i} - y_{obs,i})}{N} \quad (2.14)$$

Donde:

Sesgo: Sesgo medio.

$y_{obs,i}$: Variable observada en el tiempo *i*.

$y_{sim,i}$: Variable simulada en el tiempo *i*.

N: Número de valores en la serie.

La diferencia de coeficiente de determinación que se define en la ecuación (2.15) sirve para comparar dos estimaciones de una variable. Un valor positivo significa una mejora en coeficiente de determinación.

$$\Delta R^2 = R_f^2 - R_i^2 \quad (2.15)$$

Donde:

ΔR^2 : Diferencia de coeficiente de determinación.

R_f^2 : Coeficiente de determinación final.

R_i^2 : Coeficiente de determinación inicial.

La diferencia de RMSE que se define en la ecuación (2.16) sirve para comparar dos estimaciones de una variable. Un valor positivo significa una mejora en RMSE (reducción de RMSE).

$$\Delta RMSE = RMSE_i - RMSE_f \quad (2.16)$$

Donde:

$\Delta RMSE$: Diferencia de RMSE.

$RMSE_i$: RMSE inicial.

$RMSE_f$: RMSE final.

La diferencia de sesgo medio se define en la ecuación (2.17) sirve para comparar dos estimaciones de una variable. Un valor positivo significa una mejora en sesgo (reducción de sesgo).

$$\Delta sesgo = \begin{cases} sesgo_i - sesgo_f & \text{si } 0 < sesgo_i \text{ y } 0 < sesgo_f \\ sesgo_i + sesgo_f & \text{si } 0 < sesgo_i \text{ y } 0 > sesgo_f \\ -sesgo_i - sesgo_f & \text{si } 0 > sesgo_i \text{ y } 0 < sesgo_f \\ -sesgo_i + sesgo_f & \text{si } 0 > sesgo_i \text{ y } 0 > sesgo_f \end{cases} \quad (2.17)$$

Donde:

$\Delta sesgo$: Diferencia de sesgo.

$sesgo_f$: Sesgo final.

$sesgo_i$: Sesgo inicial.

Capítulo 3: Zona de Estudio

3.1. Hidroclimatología

La zona de estudio corresponde a la cuenca Río Tinguiririca Bajo Los Briones (Código BNA 06028001-0), ubicada en la Región del Libertador Bernardo O'Higgins, Chile. La cuenca se ubica entre las latitudes $-35^{\circ},1'$ y $-34^{\circ},30'$ y las longitudes $-70^{\circ},51'$ y $-70^{\circ},18'$ y posee un área de 1438 km^2 . En la Figura 3-1 se muestra una imagen satelital de la cuenca.

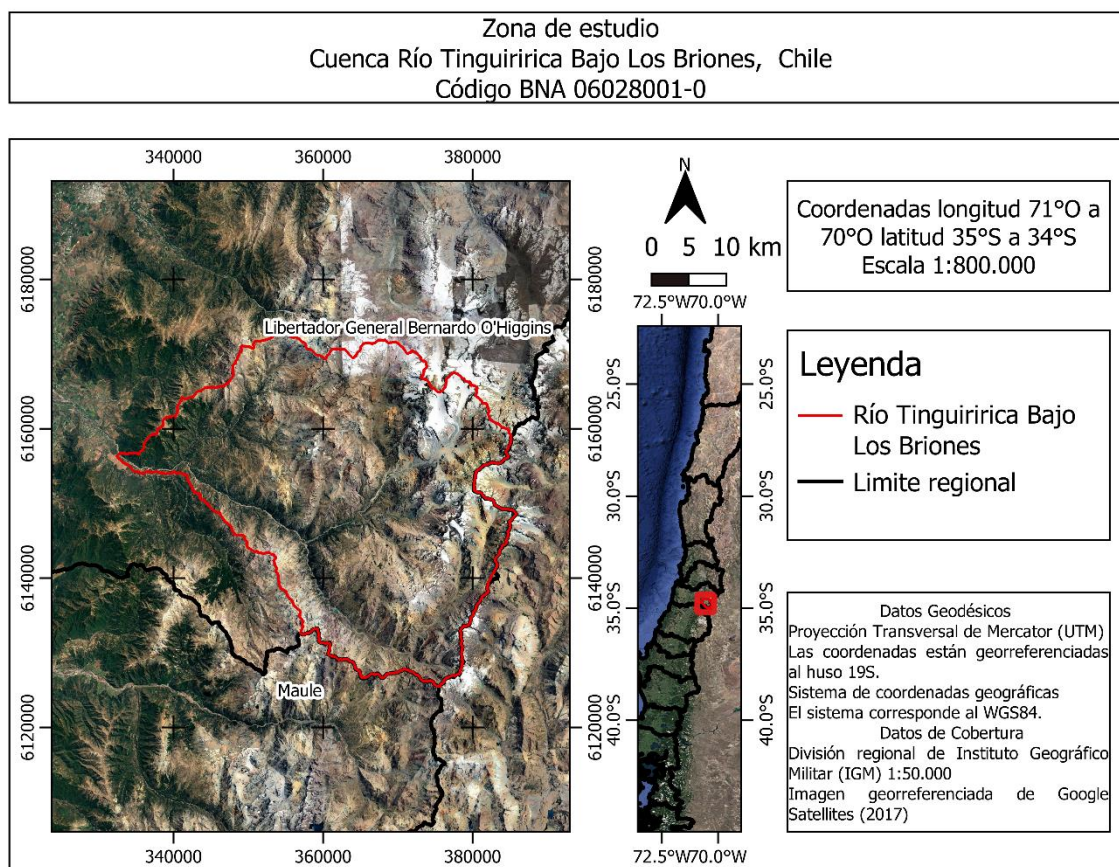


Figura 3-1: Zona de estudio.

En la Figura 3-2 se presentan las variables hidroclimáticas medias del período 1979-2020 del producto CR2Met v2.0 (DGA, 2017). La cuenca presenta temperaturas dentro del rango -4 y $17 \text{ }^{\circ}\text{C}$ en promedio durante el año. Es una cuenca nival cuya precipitación (P) máxima se obtiene durante el mes de mayo, evapotranspiración potencial (PET) máxima durante diciembre y escorrentía (R) máxima durante enero. Además, en el panel b) de la Figura 5-2 se presenta la acumulación al término del mes calculada como un balance entre las variables hidroclimáticas, que si se supone que la infiltración es despreciable, sirve como aproximación a la cantidad de SWE que almacena la cuenca. Los montos máximos de SWE ocurren durante el término del mes

de agosto con un valor máximo de 800 mm para dar paso a la temporada de derretimiento. De acuerdo con este cálculo existe una acumulación negativa al término del año hidrológico que sería consecuencia de la sobreestimación de utilizar la PET como la evapotranspiración (ET).

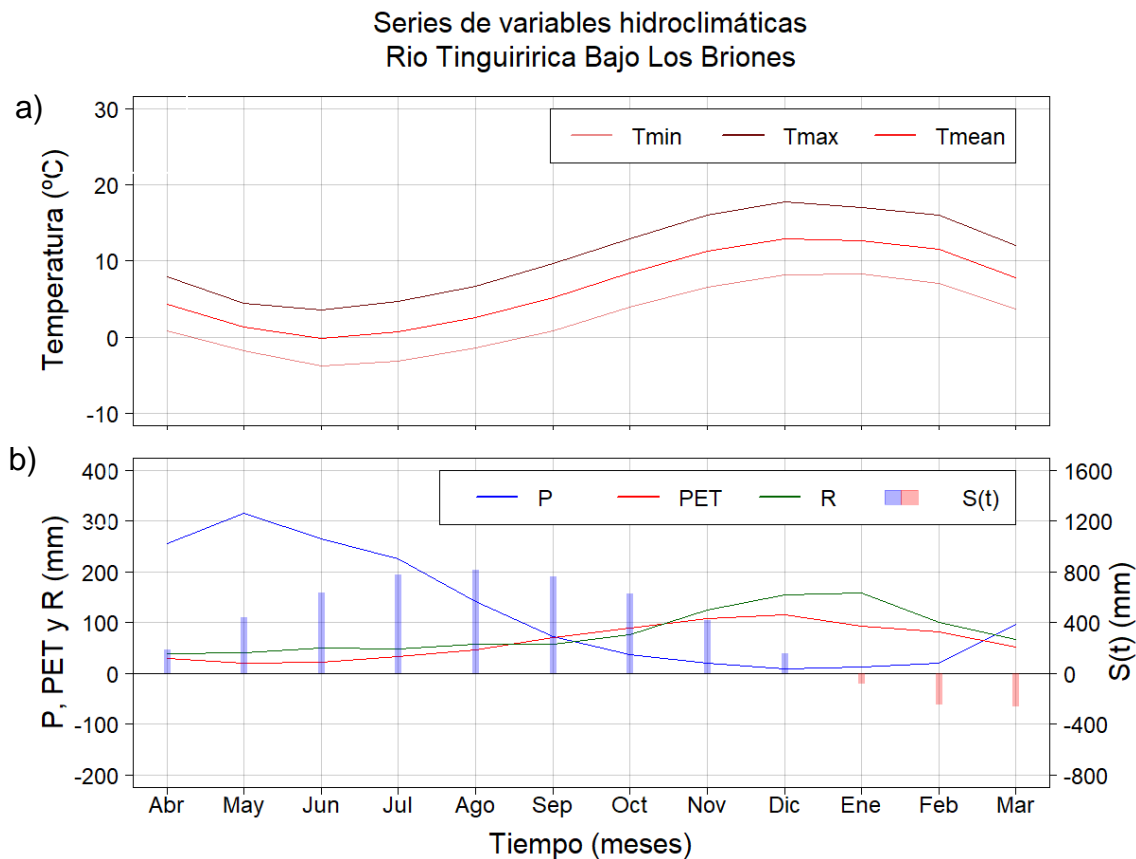


Figura 3-2: Series de variables hidroclimáticas. En el panel a) se presentan las variables Tmin, Tmax y Tmean que corresponden a temperatura mínima, máxima y media. En el panel b) se presentan las variables P, PET, R y S(t) que corresponden a precipitación, evapotranspiración potencial calculada con el método de Hargreaves, escorrentía superficial y almacenamiento al final del mes.

3.2. Línea de nieves

La cuenca también posee glaciares, extendiéndose en un área de 120,5 km² según el inventario público de glaciares (DGA, 2021), el cual delimita los contornos glaciares mediante imágenes Landsat, considerando glaciares descubiertos y rocosos. Algunos glaciares importantes que se encuentran en esta cuenca son el glaciar Universidad, Cortaderal y Tinguiririca con una extensión de 27,6, 15,6 y 5,6 Km² respectivamente.

La nieve y el hielo presente en los glaciares poseen características distintas pues la segunda permanece de un año a otro a diferencia de la nieve. Además poseen dinámicas de derretimiento distintas, el hielo no es afectado por procesos que si interfieren la nieve, como lo hace el transporte por viento. También el hielo posee menor albedo que la nieve. De acuerdo con Ajai (2010) la nieve fresca tiene un albedo cercano a uno en contraste con el de hielo glaciar de 0,6 y el de hielo glaciar sucio 0,15. Por esto, el proceso de modelación de la criósfera, como es el presente trabajo, se debiese parametrizar distintamente nieve y glaciares. Debido a esto es que el área glaciar debe considerarse, más aún si el sensor MODIS no lo puede distinguir de la nieve.

De acuerdo con Peña y Vidal (1993) se puede definir la línea de nieves anual para las cuencas de latitud -34.8° en 1470 m.s.n.m.. En cambio, Lagos Zúñiga & Jara (2017) estiman la línea de nieves usando imágenes satelitales entre los años 2001 y 2015 considerando los días cuya precipitación haya superado los 10 mm y definiendo la línea de nieves como el percentil de cota cuya fSCA del área del terreno que está sobre esta cota sea 0,5. Según este método se obtiene una línea de nieves variable anualmente entre 1670 y 2750 m.s.n.m. para la misma latitud.

Mediante la curva hipsométrica que se muestra en la Figura 3-4 se puede obtener el área de la cuenca que está sobre la línea de nieves y que según Lagos Zúñiga & Jara, (2017) sería de más del 30% del área en verano, y no solo donde existen glaciares. En el caso de invierno cerca del 80% de la cuenca se encontraría sobre la línea de nieves. Esto confirma que en particular esta cuenca es relevante estimar el SWE para determinar su aporte en el caudal.

En la Figura 3-3 se ejemplifican las cotas de línea de nieves en conjunto con las áreas que estarían sobre éstas y existiría nieve. La curva que delimita el área blanca de celeste claro corresponde a la línea de Lagos Zúñiga & Jara (2017) en verano, la que delimita el área celeste claro con celeste oscuro corresponde a la línea de nieves de Lagos Zúñiga & Jara (2017) en invierno y la curva que delimita el área celeste oscuro y café corresponde a la línea de nieves de Peña y Vidal (1993).

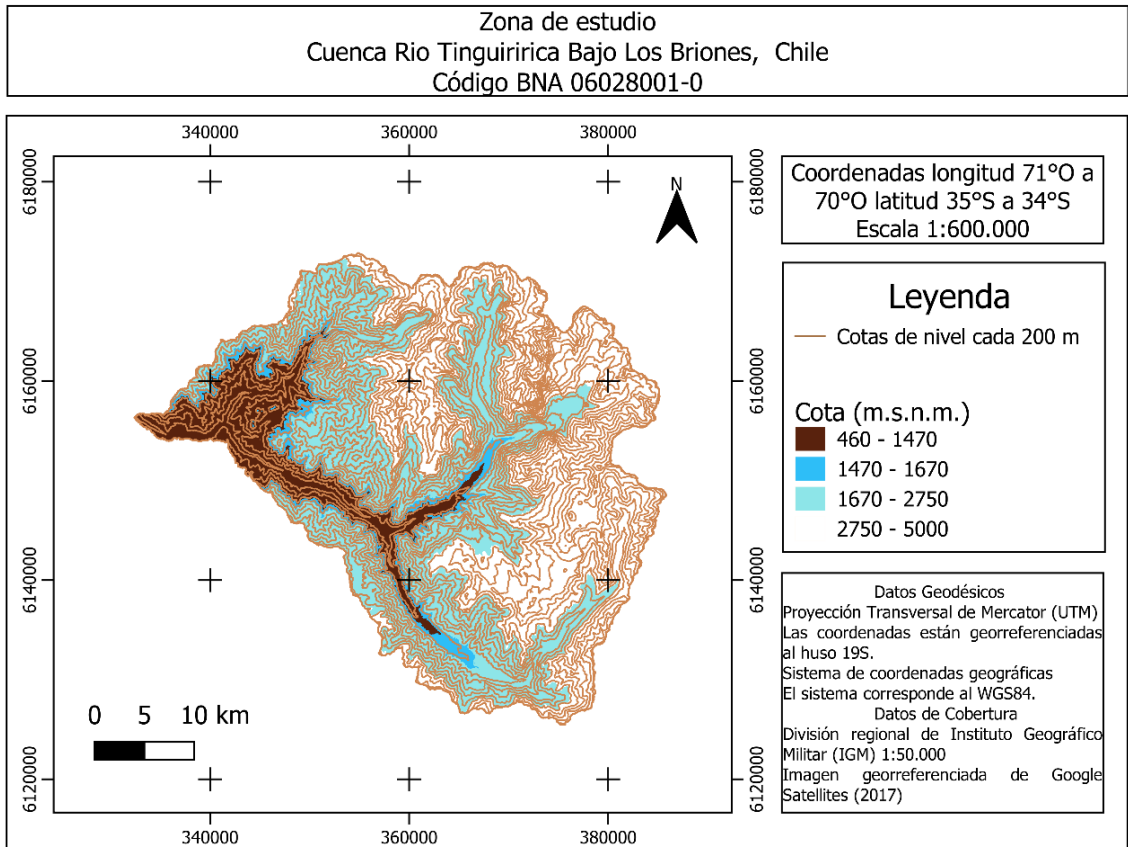


Figura 3-3: Mapa con áreas sobre la línea de nieves. El límite entre blanco corresponde a la línea de nieves de Lagos Zúñiga y Jara (2017) en verano, el límite entre celeste claro y celeste más oscuro corresponde a la línea de nieves de Lagos Zúñiga y Jara (2017) en invierno y el límite entre café y celeste oscuro corresponde a la línea de nieves de Peña y Vidal (1993).

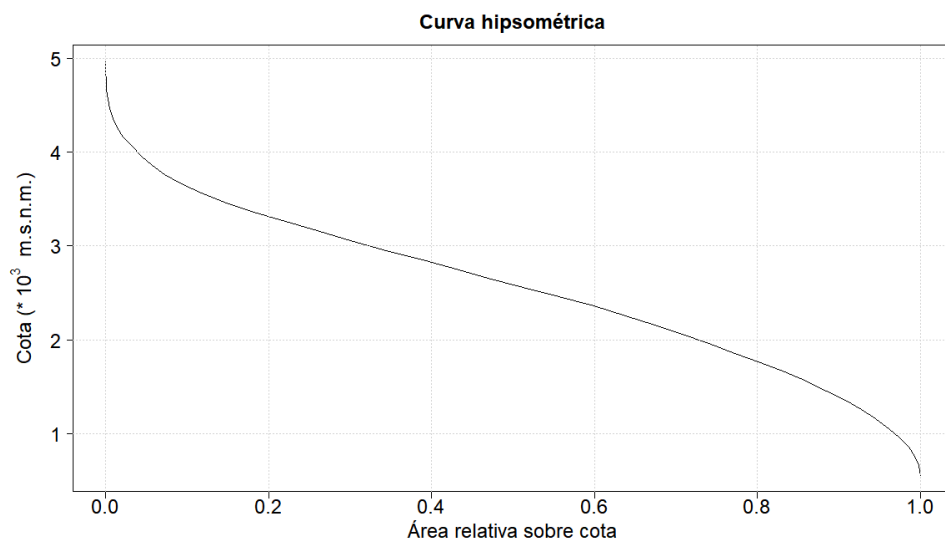


Figura 3-4: Curva hipsométrica de cuenca Río Tinguiririca Bajo Los Briones.

Capítulo 4: Antecedentes y Metodología

4.1. Antecedentes

A continuación, se describen los antecedentes utilizados para implementar el marco de asimilación de imágenes satelitales y pronosticar las series de SWE con el modelo CRHM.

4.1.1. Información morfológica

Para definir la topografía de la zona en estudio se usa el modelo de elevación digital *Shuttle Radar Topography Mission Global 1 arc second V003* de NASA. Este DEM (acrónimo del inglés *Digital Elevation Model*) tiene una resolución de espacial de 30 m por 30 m nominal.

4.1.2. Producto CR2Met v2.0 (DGA, 2019)

Se utilizan las variables meteorológicas estimadas a partir del proyecto Actualización del Balance Hídrico de Chile (DGA, 2017; 2019), las que se usan como forzantes para el modelo hidrológico. Las forzantes consideran temperatura a 2 m sobre el nivel del suelo, precipitación, velocidad de viento a 10 m sobre el nivel del suelo, humedad relativa, radiación de onda corta incidente y radiación de onda larga incidente sobre la cuenca con resolución temporal tri-horaria y resolución espacial 0,05° de latitud y 0,05° de longitud.

4.1.3. Inventario de glaciares DGA

Se utiliza el inventario de glaciares de DGA que delimita el área de glaciares libres y rocosos entre los años 2002 y 2014. Se utiliza para determinar el área no cubierta por glaciares y realizar la modelación sobre estas regiones. Esto es debido a que glaciares y nieves que perduran más de un año tienen un comportamiento hidrológico distinto que el manto nival que se derrite totalmente en la temporada de deshielo. Por consiguiente, el conjunto de parámetros que sea óptimo para los glaciares puede no serlo para el manto nival que no está en la zona de glaciares.

4.1.4. Productos MOD10A1 y MYD10A1 (Hall & G. A. Riggs., 2021) de MODIS

Los productos MOD10A1 y MYD10A1 que estiman la fSCA se elaboran a partir de las imágenes de reflectancia obtenidas de los sensores MODIS a bordo de los satélites TERRA y AQUA respectivamente. Ambos productos presentan una resolución espacial rectangular de 500 m por 500 m nominal (Hall & G. A. Riggs., 2021). Estos productos

tienen una resolución temporal diaria con algunos registros faltantes en su período de operación. El satélite TERRA presenta imágenes con distinto tiempo de adquisición con respecto al satélite AQUA, teniendo el primero un tiempo de adquisición de 10:30 AM hora local en la línea del Ecuador con sentido N-S. Es importante conocer el tiempo de adquisición de las imágenes para aplicar en métodos de asimilación cuya discretización temporal sea intradiaria.

4.1.5. Pronóstico meteorológico SEAS5 (Johnson et al., 2019) de ECMWF

Se utiliza el pronóstico meteorológico estacional SEAS5 de ECMWF² para obtener las forzantes meteorológicas que pronostican en una ventana de siete meses. Los resultados del pronóstico meteorológico tienen una discretización temporal cada seis horas y posee una discretización espacial de 0,5° por 0,5°. Además cada pronóstico posee 25 miembros que son obtenidos de perturbar las condiciones iniciales del pronóstico, particularmente, temperatura de la atmósfera, humedad del suelo, temperatura del suelo, de la nieve, del mar-hielo y la temperatura de la tropopausa, que es la delgada capa de transición entre la tropósfera y estratósfera (Johnson et al., 2019).

Se utilizan las forzantes meteorológicas que entrega el pronóstico llamadas: velocidad de viento a 10 metros sobre el suelo, temperatura de punto de rocío a dos metros sobre el suelo, precipitación total y temperatura a dos m sobre el suelo. Se utilizan cuatro pronósticos cuyos inicios comienzan el agosto-1, septiembre-1, octubre-1 y diciembre-1.

4.1.6. Series de SWE (Cornwell et al., 2016)

Debido a la importancia que tiene la nieve en la hidrología y la falta de estaciones de medición de nieve, es que se han creado bases de datos retrospectivos de nieve en Chile central principalmente. En particular Cornwell et al. (2016) generó una base de datos de SWE en Chile central utilizando *clustering* de cuencas y un modelo de convolución de curvas de agotamiento y forzantes de energía variable para cada pixel. Así, obtuvo un coeficiente de determinación (R^2) de 0,68 y RMSE de 278 mm al comparar con 12 estaciones automáticas de medición de SWE.

El set de datos de SWE de Cornwell et al. (2016) para los años 2004 y 2005 es utilizado como valores medidos reales de SWE para contrastar las estimaciones y pronósticos de SWE simulado mediante el modelo hidrológico.

² Guía de información de usuario se encuentra en:
<https://confluence.ecmwf.int/display/CKB/Description+of+SEAS5+C3S+contribution>.

4.2. Metodología

La metodología que se utiliza se resume en la Figura 4-1 y será explicada detalladamente más adelante. En términos generales, primero se realiza una remoción de nubes propuesto sobre los productos MOD10A1 y MYD10A1 para obtener un producto MOD10A1 corregido, del cual se extrae fSCA mediante análisis geoespacial para obtener fSCA en cada URH. Luego se realiza un análisis de sensibilidad para determinar los parámetros que tienen sensibilidad en la serie de SWE para ser calibrados. Se utiliza el método asimilación variacional asimilando el fSCA mediante el método de discretización subgrilla de Liston (2004) en el modelo CRHM, en dos años independientes para obtener dos conjuntos de parámetros que se utilizarán para generar un conjunto de estimaciones de pronóstico de SWE.

Paralelamente se corrige mensualmente el pronóstico meteorológico con el método QDM (acrónimo de *Quantile Delta Mapping*; Cannon et al. 2015), es decir, se generan curvas de distribución acumuladas mensuales para corregir el pronóstico. Finalmente se utiliza el modelo CRHM con los conjuntos de parámetros anteriores y los pronósticos meteorológicos corregidos para pronosticar el SWE y se compara con las series de SWE de Cornwell et al. (2016).

4.2.1. Remoción de nubes (Parajka and Blöschl, 2008)

Mediante el paquete de R MODISstsp (Busetto & Ranghetti, 2016) se descargan los productos MOD10A1 y MYD10A1 de MODIS entre los meses abril a marzo para la zona de estudio y el período 2003-2013. Para remover los días y celdas con nubes, se recurre al método propuesto por Parajka & Blöschl (2008) que consiste en una combinación temporal diaria de los productos: primero se traza una grilla con la mayor resolución espacial que tengan los productos MOD10A1 y MYD10A1 y se le asigna a cada pixel el valor correspondiente según el método del vecino más cercano de cada producto. Luego los pixeles sin cobertura de nieve del producto MOD10A1, es decir que tengan clasificación mayor a 100, son reemplazados con el valor que tiene el mismo pixel en el producto MYD10A1.

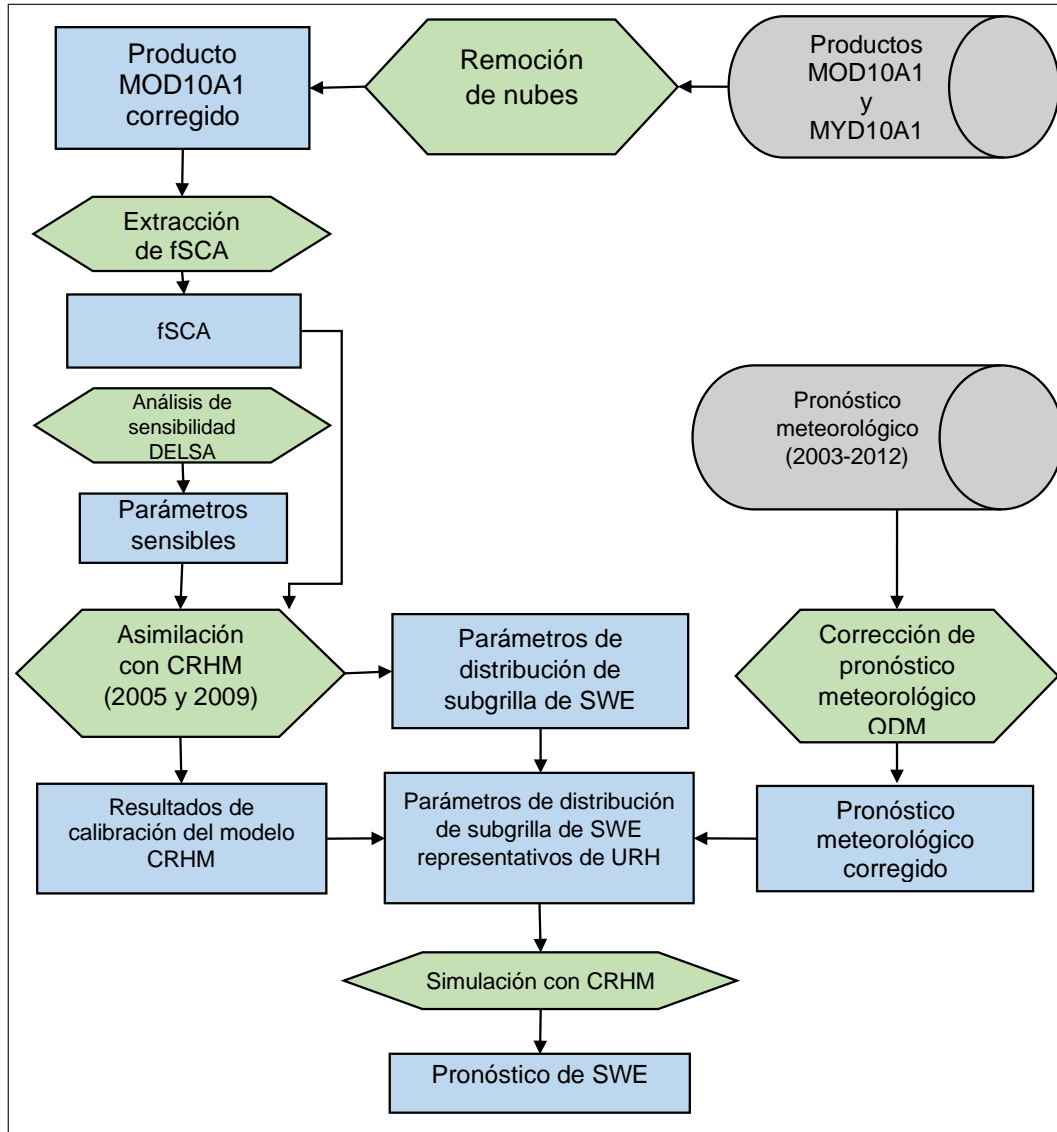


Figura 4-1: Metodología que se utiliza. Figuras cilíndricas corresponden a productos utilizados, figuras hexagonales corresponden a procesos realizados y figuras cuadradas corresponden a resultados obtenidos de los procesos realizados.

4.2.2. Extracción de fSCA

Los productos MOD10A1 y MYD10A1 presentan píxeles cuya fSCA fueron estimados entre 0 y 100 % los que serán llamados *píxeles identificados* y otros cuya fSCA no pudo ser estimada, debido a presencia de nubes, de noche o algún defecto del sensor, lo que serán llamados *píxeles no identificados*. Para extraer la fSCA de una URH de la cuenca es necesario tener la fSCA de todos los píxeles que se solapan con la región proyectada de la URH, por lo que es necesario estimar la fSCA de los píxeles no identificados. El error de estimación de fSCA cuando existen *píxeles identificados* es

igual al error de medición equivalente a la mitad de la unidad de medición (es decir, 0,5 %).

Al no tener información sobre los pixeles no identificados, el valor del pixel se puede modelar como una variable aleatoria uniforme con valores entre 0 y 100%, sin embargo, se decide utilizar la esperanza de la variable aleatoria, la que es 50%. Así el valor de un pixel no identificado tiene el valor y la desviación estándar del error dadas por las ecuaciones (4.1) y (4.2).

$$fSCA(P_{NI}) = 50\% \quad (4.1)$$

$$\sigma_{fSCA}(P_{NI}) = \sqrt{\frac{100\%}{12}} \quad (4.2)$$

Donde:

$fSCA(P_{NI})$: fSCA de un pixel no identificado.

$\sigma_{fSCA}(P_{NI})$: Varianza del error de un pixel no identificado.

En el caso de un pixel identificado, este posee su fSCA estimado por el producto MOD10A1 corregido como lo muestra la ecuación (4.3) y su desviación estándar se determina según la ecuación (4.4), que corresponde al error de instrumento, en este caso el sensor MODIS.

$$fSCA(P_I) = fSCA_{MODIS} \quad (4.3)$$

$$\sigma_{fSCA}(P_I) = 0,5\% \quad (4.4)$$

Donde:

$fSCA(P_I)$: fSCA de un pixel identificado.

$fSCA_{MODIS}$: fSCA determinado por producto MODIS corregido.

$\sigma_{fSCA}(P_I)$: Varianza del error de un pixel identificado.

Luego se extrae la fSCA sumando el producto entre la fracción de área que aporta cada pixel a una URH por su valor de fSCA de todos los pixeles que aportan a la URH, según se indica en la ecuación (4.5) la que se desarrolla para llegar a la ecuación (4.6)

$$fSCA(URH) = \left[\sum_{i=1}^{nI} fSCA(P_i) f_i + \sum_{i=1}^{nNI} fSCA(P_{NI}) f_i \right] \quad (4.5)$$

$$fSCA(URH) = \left[\sum_{i=1}^{nI} fSCA(P_i) f_i + 50\% \sum_{i=1}^{nNI} f_i \right] \quad (4.6)$$

Donde:

$f_{SCA}(URH)$: fSCA de la URH.

$f_{SCA}(P_i)$: fSCA del pixel identificado i .

P_{NI} : fSCA del pixel no identificado.

nI : Número de pixeles identificados que se solapan con la URH.

nNI : Número de pixeles no identificados que se solapan con la URH.

f_i : Cociente entre la fracción de área del pixel i y el área de la URH.

La varianza de la observación queda determinada de manera análoga, tal como se indica en la ecuación (4.7):

$$\sigma_{f_{SCA}}^2(URH) = \left[\sum_{i=1}^{nI} \sigma^2(P_i) f_i + \frac{100\%}{12} \sum_{i=1}^{nNI} f_i \right] \quad (4.7)$$

Donde:

$\sigma_{f_{SCA}}^2(URH)$: Varianza de los errores de fSCA de la URH.

$\sigma^2(P_i)$: Varianza de fSCA del pixel identificado i .

nI : Número de pixeles identificados que se solapan con la URH.

nNI : Número de pixeles no identificados que se solapan con la URH.

f_i : Cociente entre la fracción de área del pixel i y el área de la URH.

4.2.3. Análisis de sensibilidad DELSA (Rakovec et al., 2014)

La sensibilidad de los parámetros depende del modelo y de las forzantes y, por lo tanto, se elige un año con precipitaciones promedio, que corresponde al año 2003 para tres URH ficticias de 10 km² cada una a una elevación de 4.000 m.s.n.m. con pendientes de 0, 20 y 40° y orientación Norte (azimut -90° a 90°) o Sur (90° a 270°) ubicadas en la latitud de Rio Tinguiririca Bajo Los Briones.

Se consideran parámetros variables todos aquellos que no tengan dependencia de límite superior o inferior con otro parámetro. Por lo tanto, se considera un total de 26 parámetros del modelo hidrológico CRHM. Y como función objetivo Ψ que se muestra en la ecuación (4.8) y que corresponde a el error cuadrático medio entre la serie de tiempo de SWE con parámetros modificados, SWE_{θ_j} , y la serie de tiempo de SWE con parámetros default del modelo $SWE_{\theta_j^*}$ con N el total de observaciones.

$$\Psi = \sqrt{\frac{\left(SWE_{\theta_j} - SWE_{\theta_j^*} \right)^2}{N}} \quad (4.8)$$

4.2.4. Asimilación con CRHM

Se describe en este acápite la metodología detallada que se utiliza para assimilar la fSCA con CRHM. En particular la conversión entre de SWE del modelo CRHM a fSCA y la asimilación de este para obtener el set de parámetros óptimos que son utilizados en la simulación con CRHM.

4.2.4.1. Conversión entre fSCA y SWE (Liston, 2004)

El módulo SnobalCRHM utiliza como variable de estado de la URH la cantidad de SWE (kg/m^2) y, por lo tanto, es necesario transformar ya sea el SWE o el fSCA para poder assimilar las observaciones. Muchos investigadores (Donald et al., 1995; Liston, 2004) proponen una distribución log-normal de dos parámetros recogida de datos empíricos para poder determinar la SDC que relaciona el fSCA y el SWE. Estas distribuciones son llamadas distribuciones subgrilla debido a que parametrizan el valor de una variable al interior de una unidad de área.

Se utiliza la notación propuesta por Liston (2004) donde la fracción de área cubierta por nieve $\Gamma(D_m)$ está en función de la altura de derretimiento. Esto supone que se derrite de forma uniforme una superficie dada y por lo tanto, se utiliza en época de deshielo. Un caso particular es el de las lluvias en temporada de deshielo cuando el manto nival es somero, la cual al ser uniforme aumentaría el fSCA a 100% y modificaría la función de distribución de la nieve. Esto no se considera en el presente trabajo y se utiliza una sola función de distribución para toda la temporada. Las ecuaciones (4.9), (4.10), (4.11) y (4.12) son las que modelan este proceso.

$$fSCA = \Gamma(D_m) = 1 - \int_0^{D_m} f(D)dD \quad (4.9)$$

$$f(D) = \frac{1}{D\xi\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left[\frac{\ln(D) - \lambda}{\xi}\right]^2\right) \quad (4.10)$$

$$\lambda = \ln(\mu) - \frac{1}{2}\xi^2 \quad (4.11)$$

$$\xi^2 = \ln(1 + CV^2) \quad (4.12)$$

Donde:

$\Gamma(D_m)$: Área cubierta por nieve, SCA (m^2).

$f(D)$: Función de distribución de la nieve.

μ : Media de profundidad de nieve cuando el área está totalmente cubierta por nieve.

CV : Coeficiente de variación de la distribución.

λ, ξ : Parámetros de la distribución log-normal.

La expresión que aparece en la ecuación (4.9) se puede reemplazar por la expresión (4.10) y al realizar el cambio de variable de D_m por z_{D_m} como se muestra en (4.13) se puede llegar a la expresión (4.14). Si se genera un cambio de variable $z = \sqrt{2} u$ y se utiliza la función error complementario que se muestra en la ecuación (4.15) se puede determinar $\Gamma(D_m)$ como aparece en la ecuación (4.16).

$$z_{D_m} = \frac{\ln(D_m) - \lambda}{\xi} \quad (4.13)$$

$$\Gamma(D_m) = 1 - \left\{ \int_{-\infty}^0 \frac{1}{\sqrt{2\pi}} e^{[-(1/2)z^2]} dz + \int_0^{z_{D_m}} \frac{1}{\sqrt{2\pi}} e^{[-(1/2)z^2]} dz \right\} \quad (4.14)$$

$$erfc(x) = \frac{2}{\sqrt{\pi}} \int_0^{\infty} e^{-x^2} dx \quad (4.15)$$

$$\Gamma(D_m) = \frac{1}{2} erfc\left(\frac{z_{D_m}}{\sqrt{2}}\right) \quad (4.16)$$

Debido a que el modelo CRHM considera el transporte por viento como proceso que influye en el almacenamiento de nieve (además del derretimiento), es que considera la suma de pérdidas o ganancias de SWE como derretimiento. También se debe considerar que el modelo también realiza un ajuste de la densidad de la nieve interiormente y, por lo tanto, D_m debe estar en unidades de masa, en particular kg/m^2 . Así, para determinar los parámetros λ y ξ se ajusta una curva minimizando el RMSE entre las observaciones de fSCA, y las pérdidas de masa de nieve, D_m . Las pérdidas de masa son obtenidas del modelo CRHM como la diferencia entre la masa en dos pasos de tiempo como lo indica la ecuación (4.17).

$$D_m = SWE_{t+1} - SWE_t \quad (4.17)$$

Las pérdidas de masa dependen de los parámetros del modelo, y por lo tanto, λ y ξ se determinan de manera iterativa a la vez que se buscan los parámetros óptimos del modelo, lo que en su conjunto es el método de asimilación. Dicho de otra manera, para cada iteración de calibración de la función objetivo $J(x)$ se determina el set de parámetros λ y ξ que ajustan la función de distribución subgrilla de Liston (2004).

4.2.4.2. Asimilación variacional

Se usó el método de asimilación variacional que minimiza la función de costo $J(x)$, que se muestra en la ecuación (4.18). La función de costo es la suma de las diferencias entre el estado de las observaciones y estado de análisis, amplificado por el inverso de la varianza de las observaciones, y la diferencia entre el estado inicial y el estado de análisis inicial, amplificado por el inverso de la varianza de estado inicial.

Este método busca la minimización de la función de costo $J(x)$ con respecto a las observaciones y estado inicial del sistema. En la Figura 4-2 se ejemplifica el método 4D-Var en donde las observaciones puntuales son los círculos verdes, el pronóstico anterior es la curva azul y el pronóstico actual es la curva roja, también llamado vector de análisis.

$$J(x) = (x_1 - x_b)B^{-1}(x_1 - x_b)^T + \sum_{i=1}^n (H(x_i) - y_i)P^{-1}(H(x_i) - y_i) \quad (4.18)$$

Donde:

$J(x)$: Función de costos.

x_i : Vector de análisis en el tiempo i .

x_b : Valor inicial de la predicción a priori. De otra forma, vector de estados iniciales.

B^{-1} : Matriz de covarianza de errores entre el valor inicial de la predicción a priori y el modelo.

H : Operador de transformación desde el espacio de estados al espacio de observaciones.

P^{-1} : Matriz de covarianza de errores en el estado del sistema en el espacio de las observaciones y la observación.

y_i : Observación en el tiempo i .




Figura 4-2: Esquema de método de asimilación de 4D-Var. Fuente: ECMWF.

La variable de estado para asimilar es el valor de fSCA en cada URH. Se supone que las observaciones son independientes y, por lo tanto, su incertidumbre es independiente y de igual varianza a la que se calcula según (4.7) lo que significa que B^{-1} y P^{-1} solo contienen elementos, que son positivos en la diagonal. Se supone que el vector de estado iniciales x_b es igual a la observación ya que no se dispone de un pronóstico anterior. El operador H corresponde al modelo de Liston (2004), el cual transforma el SWE simulado a fSCA para un instante de tiempo o paso de tiempo i . Es decir, usando el modelo de Liston con los parámetros λ y ξ ya definidos transforma el SWE a fSCA para un paso de tiempo puntual.

Los estados en el tiempo están en función del estado inicial del sistema, de los parámetros y forzantes. Si se supone que las forzantes son conocidas, sólo depende de las otras variables. Por esto, es que el método sirve para estimar los parámetros de un modelo y, en este caso, se utiliza para determinar dos conjuntos de parámetros en dos años distintos para generar un conjunto de resultados y obtener la serie de SWE mediante el promedio entre los dos conjuntos de resultados.

Los parámetros corresponden a los que tienen sensibilidad con la presencia de SWE en la cuenca. Si se define N_p como el número de parámetros a determinar para una URH, \bar{N}_{URH} la cantidad promedio de URH por subcuenca y $N_{subcuencas}$ el número de subcuencas, el número total de parámetros a determinar es $N_p \cdot \bar{N}_{URH} \cdot N_{subcuencas}$. Con el fin de disminuir el tiempo computacional se opta por determinar un solo set de parámetros para las URH de una subcuenca, lo que significa que el nuevo total de parámetros a determinar es $N_p \cdot N_{subcuencas}$.

Para determinar los parámetros se utiliza el algoritmo SCE-UA (Duan et al., 1992) presente en el paquete *rtop* de R. Se realiza este procedimiento para los años 2005 y 2009.

4.2.5. Implementación modelo CRHM

Se determinan las URH según tres factores relevantes para la distribución de la nieve, orientación norte (azimut -90° a $+90^\circ$) y sur (azimut $+90^\circ$ a $+270^\circ$) ya que condiciona la energía radiativa por unidad de área recibida, pendiente leve (0° - 30°) y abrupta (30° - 90°) -pendientes más leves pueden almacenar mayor cantidad de nieve- y elevación cada 1000 metros para discretizar las forzantes importantes en los procesos de derretimiento.

Luego se delimitan las URH mediante puntos de salida del cauce intentando mantener URH que tuviesen cada uno de los tres factores relevantes en la mayor parte de la URH, es decir que tuviese toda el área de un aspecto específico, de un tipo de pendiente específica y de una elevación específica. Como límite inferior se consideró un área de $0,9 \text{ km}^2$ para la delimitación de las URH.

El modelo CRHM tiene distintos módulos que se implementan la cantidad de información meteorológica que se disponga y/o según el grado de complejidad de modelación que se requiera. En el caso del presente trabajo se buscan modelar óptimamente los procesos relacionados con la nieve y por esto se elige la mayor complejidad en cuanto a módulos de nieves. Así, se converge a que los módulos que se implementan son los que se presentan en la Tabla 4-1.

Tabla 4-1: Módulos usados en la modelación hidrológica con CRHM.

Módulo	Objetivo
Albedo:	Cuantifica el albedo de la nieve y su decaimiento en función del tiempo.
Basin:	Caracteriza propiedades físicas y geomorfológicas de las URH, tales como elevación pendiente, orientación, entre otras.
CanopyClearing:	Controla el proceso de intercepción de la nieve y la intercepción radiativa de la cobertura vegetal y, así, cuantifica la energía que recibe el suelo bajo la cobertura vegetal.
Evap:	Controla la evapotranspiración de la primera capa de suelo para los distintos tipos de suelo.
FrozenAyers:	Controla la infiltración en suelos desnudos de acuerdo con el modelo de infiltración empírico de Ayers y la infiltración de suelos congelados según el modelo de Zhao and Gray (1999).
Global:	Determina la radiación neta incidente.
Netall:	Determina la radiación neta incidente.

Tabla 4-1 (Continuación): Módulos usados en la modelación hidrológica con CRHM.

Módulo	Objetivo
Netroute	Controla el ruteo de caudal mediante el método propuesto por Clark (1945) según hidrograma unitario entre URH. mediante un modelo de cascada.
Obs:	Maneja las observaciones y discretiza en resolución mayor o menor.
PbsmSnobal:	Controla la sublimación de la nieve y el transporte por viento entre URH.
SnobalCRHM:	Controla el balance radiativo sobre la nieve.
Soil:	Caracteriza los suelos y controla los flujos superficiales y subterráneos entre URH.

Los parámetros morfológicos que tiene cada URH corresponden a área, elevación, latitud del centroide, pendiente de la cuenca y orientación. Estos parámetros son determinados a partir del DEM, promediando los valores de cada URH. También, se considera la elevación de medición de las forzantes como temperatura y humedad relativa (dos metros sobre el suelo) y velocidad de viento (10 metros sobre el suelo).

Las observaciones del proyecto de Actualización del Balance Hídrico Nacional (DGA, 2019) están ordenadas en forma de grilla de $0,05^\circ$ por $0,05^\circ$ y por facilidad de método son escaladas a escala de URH usando polígonos de Thiessen.

La calibración se realiza ajustando la fSCA observada con la estimada por el modelo de Liston (2004) para el año hidrológico (abril-marzo) para los años 2005 y 2009. No se consideran las observaciones que presentan nieve nula. Una vez creado el modelo y las observaciones, se modela la serie de SWE con parámetros de la literatura lo que genera la serie que se llama "Sin asimilación" que equivale a serie *open loop* y la serie con parámetros calibrados provenientes de la asimilación que se llama "Con asimilación"

4.2.6. Corrección de pronóstico meteorológico con QDM (Cannon et al., 2015)

Cada pronóstico tiene un conjunto de 25 miembros de cada forzante meteorológica, los que fueron promediados para obtener la forzante media en cada punto de la grilla. En el caso de la precipitación se promedia la serie de precipitación acumulada. Luego son interpolados a cada centroide de URH usando interpolación bilineal para obtener la forzante meteorológica media de cada URH.

El método de corrección de sesgo QDM corrige los sesgos de distribución relativa al período histórico manteniendo las tendencias del modelo -el cual puede ser pronóstico

o modelo GCM- (Cannon et al., 2015). El método al ser aplicado para un año del pronóstico puede ser descrito como se menciona en los párrafos siguientes.

El método QDM aplicado a la precipitación primero ordena los valores de la precipitación observada con los del pronóstico y asigna el valor cero a los valores de precipitación del pronóstico menores del cuantil equivalente al valor cero en los valores observados. Luego se genera una curva de frecuencia acumulada y se determina el cuantil al que corresponde un valor $x_{m,p}(t)$ de ser corregido, $\tau_{m,p}(t) = F_{m,p}^{-1}(x_{m,p}(t))$, se determina el cambio de magnitud en el cuantil entre el período histórico del pronóstico y el período de ser corregido del pronóstico -que corresponde a un año-, $\Delta_m(t)$ como lo muestra la ecuación (4.19).

$$\Delta_m(t) = \frac{F_{m,p}^{-1}(\tau_{m,p}(t))}{F_{m,h}^{-1}(\tau_{m,p}(t))} \quad (4.19)$$

Donde:

$\Delta_m(t)$: Cambio en la magnitud para un mismo cuantil del pronóstico.

$F_{m,p}^{-1}(\tau_{m,p}(t))$: Magnitud de la precipitación para el mismo cuantil $\tau_{m,p}(t)$ en el período predicción del pronóstico meteorológico.

$F_{m,h}^{-1}(\tau_{m,p}(t))$: Magnitud de la precipitación para el mismo cuantil $\tau_{m,p}(t)$ en el período histórico del pronóstico meteorológico.

Luego se obtiene el valor del cuantil del período histórico observado $x_{o,h}(t) = F_{o,h}^{-1}(\tau_{m,p}(t))$ y se obtiene el valor predicción corregido del pronóstico como se muestra en la ecuación (4.20).

$$\hat{x}_{m,p}(t) = x_{o,h}(t) \Delta_m(t) \quad (4.20)$$

Donde:

$\hat{x}_{m,p}(t)$: Magnitud corregida de precipitación en el período de predicción del pronóstico.

$x_{o,h}(t)$: Magnitud de la precipitación para el mismo cuantil $\tau_{m,p}(t)$ en el período histórico de las observaciones.

$\Delta_m(t)$: Cambio en la magnitud para un mismo cuantil del pronóstico.

El método de corrección QDM se aplica a cada mes de pronóstico considerando el presente año de corrección como período de predicción y los nueve años restantes como período histórico y utilizando las forzantes de la actualización del balance hídrico como observaciones. El período de que se corrige dentro de cada año corresponde al período de pronóstico.

El mismo procedimiento se aplicó para los cuatro pronósticos, los cuales comienzan a pronosticar los días 1 de agosto, 1 de septiembre, 1 de octubre y 1 de diciembre, corrigiendo los siete meses de pronóstico de cada uno.

4.2.7. Simulación hidrológica con CRHM

Se modela con CRHM la serie de SWE utilizando el pronóstico meteorológico SEAS5 escalado y corregido con QDM de precipitación, temperatura a dos m sobre el suelo, velocidad de viento a 10 m sobre el suelo. Se utiliza la radiación solar incidente de onda larga y la radiación solar incidente de onda corta del proyecto de Actualización del Balance Hídrico de Chile (DGA, 2019) debido a su facilidad de parametrización. La humedad relativa se determina mediante la ecuación (4.21) obtenida de la aproximación de Clausius-Clapeyron³:

$$HR = 100 * \frac{e^{\left[\frac{17.625 T_d}{243.04 + T_d}\right]}}{e^{\left[\frac{17.625 T}{243.04 + T}\right]}} \quad (4.21)$$

Donde:

HR: Humedad relativa (%).

T_d: Temperatura de punto de rocío (°C).

T: Temperatura del aire (°C).

Luego, se generan las series de forzantes meteorológicas que se utilizan para modelar con el modelo CRHM. Estas series se componen de las forzantes del proyecto de Actualización del Balance Hídrico de Chile hasta el momento de inicio del pronóstico y las forzantes meteorológicas provenientes del pronóstico SEAS5.

4.2.8. Comparación con Cornwell et al. (2016)

Se compara mediante las métricas de evaluación las series de SWE con y sin asimilación y pronosticadas con las series de SWE de Cornwell et al., (2016) a escala de URH. Se analiza espacialmente la distribución de los valores de las métricas de evaluación.

Posteriormente se analiza la utilización de pronósticos con distintos días de inicio para determinar el instante óptimo de inicio de pronóstico. Esto se realiza mediante la determinación y análisis de las métricas de evaluación ΔR^2 , $\Delta RMSE$ y $\Delta sesgo$ en cada URH.

³ Obtenido desde <https://cals.arizona.edu/azmet/dewpoint.html> y https://en.wikipedia.org/wiki/Clausius%E2%80%93Clapeyron_relation.

Capítulo 5: Resultados

En este capítulo se presentan los resultados obtenidos de los procesos involucrados y se discute y analiza las causas de tales.

5.1. Análisis del producto MODIS corregido

El método de remoción de nubes de Parajka & Blöschl (2008) fue evaluado al generar píxeles sin datos en la imagen del satélite TERRA y aplicar el relleno de datos sobre estos puntos al reemplazarlos por los valores que se obtienen del satélite AQUA y comparar los valores de los píxeles rellenos con la imagen original. Fueron comparados todos los píxeles que estuviesen identificados en el satélite AQUA durante los 10 años, obteniendo un sesgo y RMSE 0.5 y 8% de la fSCA del píxel como lo muestra la Tabla 5-1.

Tabla 5-1: Resultados de remoción de nubes Parajka & Blöschl (2008).

Método	Sesgo (% SCA de píxel)	RMSE (% SCA de píxel)
Remoción de nubes	0.5	8

Se destaca que la mayor cantidad de relleno de píxeles se realiza entre los meses de acumulación (desde abril hasta agosto) y que los meses siguientes tienen poco relleno de nubes, debido claramente a la estacionalidad lluviosa y no lluviosa.

5.2. Análisis de forzantes meteorológicas

Debido a la falta de estaciones meteorológicas solo fue posible comparar las forzantes meteorológicas del proyecto Actualización del Balance Hídrico de Chile con la estación La Rufina (Código BNA 06027003-1). Las forzantes usadas en la comparación corresponden a las estimadas mediante polígonos de Thiessen en las coordenadas de la estación. La precipitación se compara solo para aquellos días en donde la precipitación observada es mayor a 0 para evitar una disminución del sesgo por considerar días sin precipitación.

Las forzantes correspondientes al proyecto Actualización del Balance hídrico de Chile (DGA, 2019) son identificadas como *forzantes utilizadas* a diferencia de las forzantes meteorológicas medidas en la estación La Rufina, que son denominadas *forzantes observadas*.

La forzante de precipitación tiene un coeficiente de determinación de 0,27 a escala diaria, lo que significa que la forzante solo explica un 27% de la varianza de la observación. El sesgo medio es de -14 mm a escala diaria, es decir subestima la

precipitación observada, pero es de 2.1 mm a escala mensual y de 20 mm a escala anual. Esto significa que la precipitación utilizada se distribuye en días en donde no hubo precipitación observada lo que explica el sesgo negativo diario (subestimación), luego obteniendo menores sesgos a nivel mensual, luego a nivel anual el sesgo aumenta debido a la disminución del número de observaciones y una particular subestimación de la precipitación el año 2005.

Así se infiere que la precipitación utilizada subestima montos diarios pero, a escala mensual y anual mantiene montos similares con excepción del año 2005 que se subestimó la precipitación observada.

El año más lluvioso y menos lluvioso a escala de cuenca es el año 2005 con 1418 mm y el año 2007 con 499 mm de precipitación de acuerdo con la serie de DGA (2019). En cambio el año 2009 precipitó 901 mm. Así los años de simulación corresponden a uno lluvioso (2005) y uno normal (2009).

Las diferencias entre la precipitación utilizada en este trabajo y la precipitación observada traen consecuencias en la variabilidad temporal del SWE, sin embargo, en cuanto a montos mensuales los errores entre las series son pequeños (12 mm de RMSE) y por lo tanto la magnitud del SWE no se ve afectada por las forzantes utilizadas.




Figura 5-1: Comparación de precipitación con estación La Rufina (Código BNA 06027003-1). En el panel a) se muestra la precipitación diaria, en el b) precipitación media mensual y en el c) la precipitación media anual para el período comprendido entre 2003 y 2012. La serie con color verde corresponde a la forzante meteorológica utilizadas en el presente trabajo y con color negro a la forzante meteorológica observada en la estación.

Las series de temperatura media diaria presentan un año completo, es decir, con una cantidad de datos faltantes menor a ocho cada mes, de temperatura en la estación La Rufina. Al comparar las mediciones se observa que las forzantes utilizadas presentan una sesgo de $-2.3\text{ }^{\circ}\text{C}$ a escala diaria (subestimación), $-2.1\text{ }^{\circ}\text{C}$ a escala mensual y $-2,1\text{ }^{\circ}\text{C}$ a escala anual.

Esto disminuye la tasa de derretimiento de las simulaciones de SWE con respecto al verdadero SWE y/o modifica los parámetros del modelo para que la simulación y el estado verdadero se ajusten mejor.




Figura 5-2: Comparación de temperatura atmosférica con estación La Rufina (Código BNA 06027003-1). En el panel a) se muestra la temperatura diaria, en el b) temperatura media mensual y en el c) la temperatura media anual para el período comprendido entre 2003 y 2012. La serie con color verde corresponde a la forzante meteorológica utilizadas en el presente trabajo y con color negro a la forzante meteorológica observada en la estación.

5.3. Análisis de sensibilidad DELSA (Rakovec et al., 2014)

La función objetivo del análisis de sensibilidad, la cual se presenta la ecuación (4.8) corresponde al RMSE entre dos series de SWE distintas y, por ende, cuantifica tanto la diferencia en montos de nieve como también en la distribución temporal de la nieve (deshielo temprano o tardío).

Del total de 26 parámetros correspondientes a cada URH, solo 12 influyen en la cantidad y distribución temporal de SWE en la cuenca en cada URH. Los parámetros que influyen en la serie de SWE pertenecen a los módulos de interceptación (CanopyClearing) por vegetación, nieve (SnobalCRHM) y albedo (Albedo). Módulos

relacionados con el suelo y la infiltración no fueron considerados en el análisis debido a que el modelo CRHM se implementa secuencialmente entre módulos y los resultados en cada paso de tiempo del módulo de nieves es utilizado como variable de entrada en los módulos de suelo e infiltración. No obstante lo anterior, el módulo de nieve considera parámetros de suelo como temperatura de suelo y conductividad termal del suelo. El módulo de transporte por viento (PbsmSnobal) tampoco influye en la serie de SWE porque la forzante de viento que se utiliza tiene magnitudes del orden de 1 m/s y el módulo necesita magnitudes del orden de 10 m/s para que empiecen a influir en la serie de SWE ínfimamente.

En la Tabla 5-2 se describe el significado de los parámetros, los cuales pertenecen a los módulos de interceptación por vegetación y transporte másico y energético en la nieve.

Tabla 5-2: Parámetros que modifican la serie de SWE del modelo CRHM.

Parámetro	Descripción
Ht	Altura de vegetación (m).
Albedo_bare	Albedo de suelo desnudo.
Albedo_snow	Albedo de la nieve.
LAI	Índice de área foliar.
Sbar	Máxima carga de nieve que puede interceptar la vegetación (kg/m ²).
unload_t_water	Temperatura a la cual la nieve presente en la vegetación cae en estado líquido (°C).
hru_rho_snow	Densidad de la nieve (Kg/m ³).
max_h2o_vol	Máximo volumen de agua en la nieve (m ³ /m ³).
KT_sand	Conductividad termal de la arena húmeda (J/m/s/°K).
max_z_s_0	Máximo espesor de la capa activa de la nieve (m).
z_0	Rugosidad de la nieve (m).
hru_T_g	Temperatura del suelo (°C).

La distribución de sensibilidad de primer orden DELSA de los parámetros que impacta en el SWE se muestra en la Figura 5-3. Los parámetros más sensibles en orden decreciente corresponden a "hru_T_g", "Sbar", "LAI", "z_0", "KT_sand", "Albedo_bare", "max_z_s_0", "Albedo_snow", "hru_rho_snow", "Ht" y "max_h2o_vol" de acuerdo con el valor promedio de sensibilidad DELSA de primer orden del espacio de parámetros.

Los parámetros con mayor número de parámetros (o mayor espacio de parámetros) con sensibilidades mayor a 0,2 corresponden "hru_T_g", "S_bar" y "LAI" con 7, 5 y 5 % respectivamente. Estos parámetros controlarían en gran medida la serie de SWE y por

lo tanto es de importancia calibrar tener buenas estimaciones de estos parámetros para restringir problemas de equifinalidad.

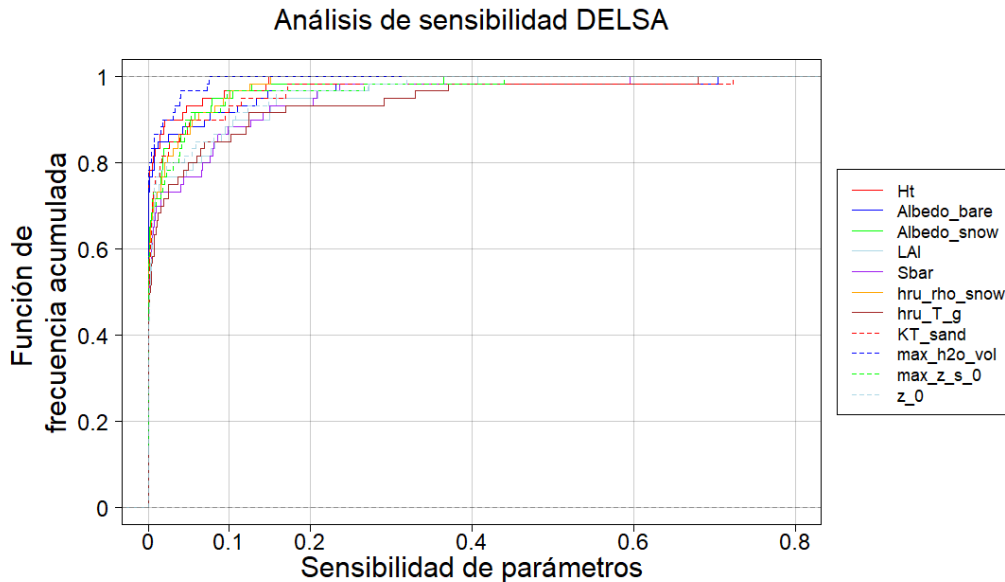


Figura 5-3: Análisis de sensibilidad DELSA sobre los parámetros.

5.4. Implementación modelo CRHM

Se modela hidrológicamente para cada subcuenca generando un total de 14 modelos hidrológicos (1 por cada URH) con el fin de obtener rapidez de cálculo de calibración de parámetros en el caso de haber considerado parámetros únicos para cada URH. Este enfoque de calibración no fue considerado finalmente debido a que la mejora de considerar parámetros distribuidos por URH aumenta el costo computacional de la modelación.

De los 12 parámetros que son importantes para la modelación se descarta el parámetro “Ht” debido a problemas de equifinalidad que distan con realidad, pues en las zonas de alta elevación existe poca o nula vegetación. El parámetro que representa la altura de la vegetación converge a valores mayores de dos metros en la parte alta de la cuenca donde no existe vegetación.

En la Figura 5-4 se observan las distintas subcuencas que se utilizan en la modelación, con identificación las letras desde la A hasta la N, estando las subcuencas A, B, E, F y K en la parte alta y J, M y N en la parte baja de la cuenca. Las subcuencas A, B, C y E son las que tienen mayor área glaciar y son las que tienen URH que tienen fSCA con magnitudes altas durante todo el año.

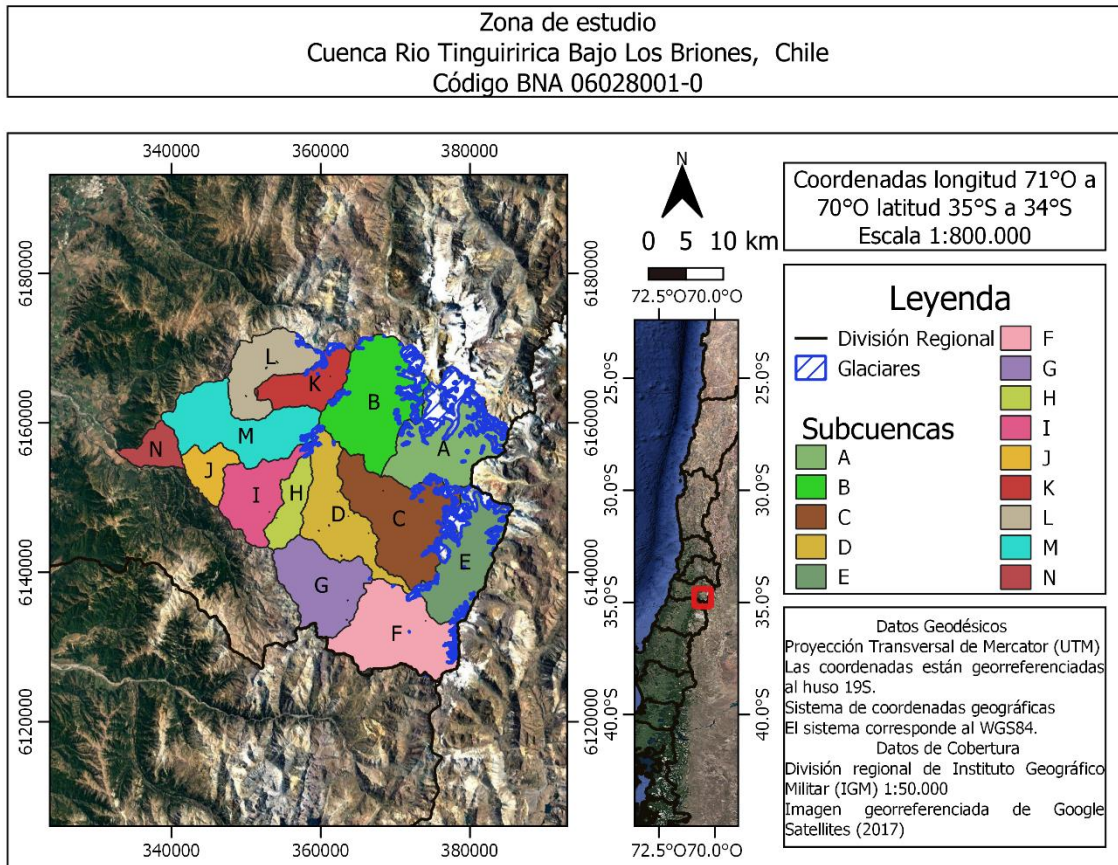


Figura 5-4: Delimitación de subcuencas utilizadas en el modelo hidrológico.

5.5. Asimilación variacional

5.5.1. Resultados de calibración del modelo CRHM

El conjunto de parámetros calibrados se muestra en la Tabla A-3 en el ANEXO A los que después de ser analizados se infiere de que no existe relación entre los valores de éstos y el tipo de año (húmedo o normal) o la elevación de la subcuenca. Los parámetros tienen una gran dispersión como se muestra en la Figura 5-5 lo que sugiere una baja identificabilidad de parámetros por subcuenca. Más aún parámetros como “hru_T_g” presentan valores de aproximadamente -40°C lo que de acuerdo con estudios como el de Rankinen et al. (2004), realizado en cuencas donde la temperatura media del aire varía entre -1 y 4°C , no presenta mediciones de temperatura menores a -10°C , por lo que existe un problema con la calibración de estos parámetros y de equifinalidad que es discutido en el punto 5.5.3. La calibración de estos parámetros se puede realizar con mapas de cobertura vegetal, y promedio de estimaciones de temperatura de suelo bajo el manto nival lo cual es complicado ya que mediciones satelitales no pueden determinar esta variable. Por lo tanto, es necesario la implementación de un modelo basado en propiedades del suelo como el de Rankinen et

al. (2004) que requiere conductividad termal del suelo, calor específico del suelo seco y calor específico del suelo debido a congelamiento y descongelamiento, además de mediciones in situ para validar el modelo. A falta de la existencia de estos parámetros, el valor de los parámetros calibrados debe estar en un rango aceptable y corroborado por estudios similares.

Los problemas de equifinalidad, tanto en parámetros sensibles como en no tanto, también pueden deberse a la agrupación por cercanía y elevación de URH y que no es la mejor. Parámetros como “Albedo_bare” o “Albedo_snow” pueden estar relacionados con la cantidad de radiación solar que los impacta, que a su vez está dada por la topografía y por lo tanto otros métodos de agrupación de URH como basados en la serie de tiempo de SWE, la radiación neta incidente en el plano inclinado o la precipitación pueden entregar mejores resultados.

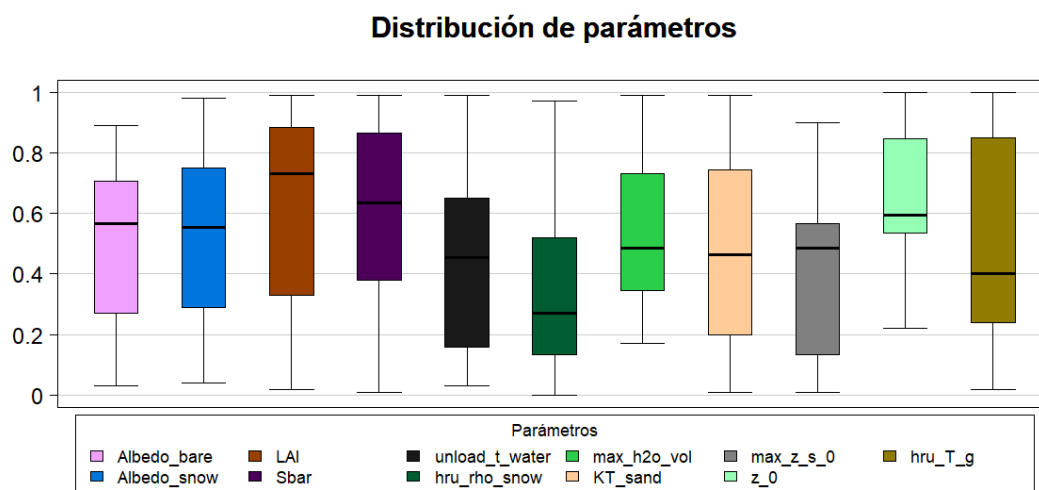


Figura 5-5: Distribución de parámetros calibrados del modelo CRHM. Los parámetros están normalizados por el límite inferior y superior entregados por CRHM.

5.5.2. Parámetros de distribución subgrilla de SWE (Liston, 2004) y parámetros representativos

Se obtuvieron parámetros de distribución de subgrilla de SWE para cada URH para cada año para los dos miembros del conjunto. Los parámetros λ y ξ fueron determinados entre los límites que se presentan en el ANEXO A.

En la Figura 5-6 se muestra la distribución de valores de parámetros del modelo de Liston (2004) para la subcuenca A en los años 2005 y 2009. Las URH que presentan valores de parámetros λ igual al límite superior permitido representan malos ajustes pues el valor óptimo de parámetros está fuera del espacio de parámetros. En el caso de las URH cuyo parámetro ξ tiene valores cercanos al límite inferior presentan buenos ajustes porque el modelo está definido para valores de ξ estrictamente mayores que 0, es decir no se puede alcanzar el límite inferior. Considerando esto y la dispersión de los

parámetros, los parámetros calibrados tanto para el año 2005 y 2009 presentan buenos ajustes de parámetros. Esto no ocurre en subcuencas de baja elevación de la cuenca (H, I, J, K, M y N) puesto que la dispersión del parámetro ξ es mucha. También las URH pertenecientes a las subcuencas A, B y E que están asociadas a gran elevación y cercanas a glaciares -y por ende presentan hielo durante la mayor parte del año- presentan mayor dispersión en los valores del parámetro ξ . El parámetro λ posee más dispersión que el parámetro ξ , lo que se puede deber a que la función de distribución de nieve $f(D)$ cambia interanualmente y/o que el efecto de precipitación ocasional sobre manto de nieve somero modifica la función de distribución $f(D)$, que en el presente trabajo se considera constante durante la temporada de deshielo. Lo anterior se traduce en un derretimiento que modela CRHM que no se condice con el derretimiento real, generando presencia de nieve constante (baja variabilidad temporal).

El valor de los parámetros representativos corresponde al set de parámetros λ y ξ tal que el valor del parámetro ξ corresponde a la mediana de los parámetros ξ obtenidos. Esto es debido a que el parámetro ξ tiene mayor importancia ya que incide sobre la forma de la curva de agotamiento -que se traduce en una distribución subgrilla- y en cambio el parámetro λ incide sobre la posición de la curva de agotamiento con respecto al derretimiento acumulado.




Figura 5-6: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca A. Cada caja agrupa los valores de lambda o épsilon ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .

Es necesario destacar que la fSCA simulada fue acotada a la temporada de derretimiento entre septiembre y marzo debido a que el modelo de Liston (2004) no parametriza la temporada de acumulación. Además la validación se realiza para el resto de años que no son considerados en la calibración (9 años para cada miembro). La calibración no fue exitosa y existe una subestimación en la temporada de deshielo que se traduce en un bajo R^2 y la validación presenta una disminución de variabilidad temporal dado por R^2 y una mejora en la magnitud del error dado por el RMSE con respecto a la calibración para ambos miembros. La calibración obtiene un 0,23 y 0,32 de R^2 , 0,31 y 0,24 de RMSE y -0,13 y -0,14 de sesgo para los años 2004 y 2005. A pesar de lo anterior la media de los miembros del conjunto entrega una mejor variabilidad al ser evaluadas en el período completo obteniendo 0,42 de R^2 , 0,14 de RMSE y -0,12 de sesgo como se muestra en la Tabla 5-3. Esto significa que los miembros son complementarios y la media entrega mejores resultados de fSCA simulada.

En la Figura 5-7 se compara la serie simulada y observada de fSCA para la cuenca Rio Tinguiririca Bajo Los Briones. En el panel a) se muestra la serie diaria de fSCA donde se observa que la fSCA observada de MODIS tiene mayor incertidumbre en la temporada de precipitación y menor durante la temporada de deshielo, sin embargo aún existe incertidumbre en eventos puntuales durante la temporada de deshielo. Además, existen muchos *peaks* instantáneos de fSCA con valor 0,5 lo que significaría que la estimación de pixeles no identificados como el valor 0,5 no es la mejor. En el panel b) se aprecia de mejor manera la subestimación de SWE y la existencia de muchos pixeles estimados como 0,5.

No se obtiene un buen ajuste en los años 2003,2007, 2010 y 2012. Dos de estos presentan bajos montos de precipitación anual lo que se debe al no considerar años secos como uno de los años de asimilación de fSCA. Por esto, aún en modelos de base física la respuesta hidrológica del modelo cambia importantemente de acuerdo con los escenarios hidrológicos.

Tabla 5-3: Desempeño de calibración y validación de los miembros del conjunto.

Serie	Calibración			Validación			Periodo completo		
	R2	RMSE	Sesgo	R2	RMSE	Sesgo	R2	RMSE	Sesgo
Miembro 2005	0.23	0.31	-0.13	0.10	0.21	-0.14	-	-	-
Miembro 2009	0.32	0.24	-0.14	0.16	0.18	-0.14	-	-	-
Promedio del conjunto	-	-	-	-	-	-	0.42	0.14	-0.12

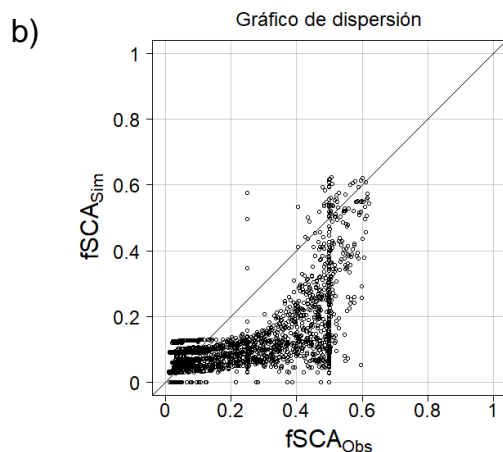
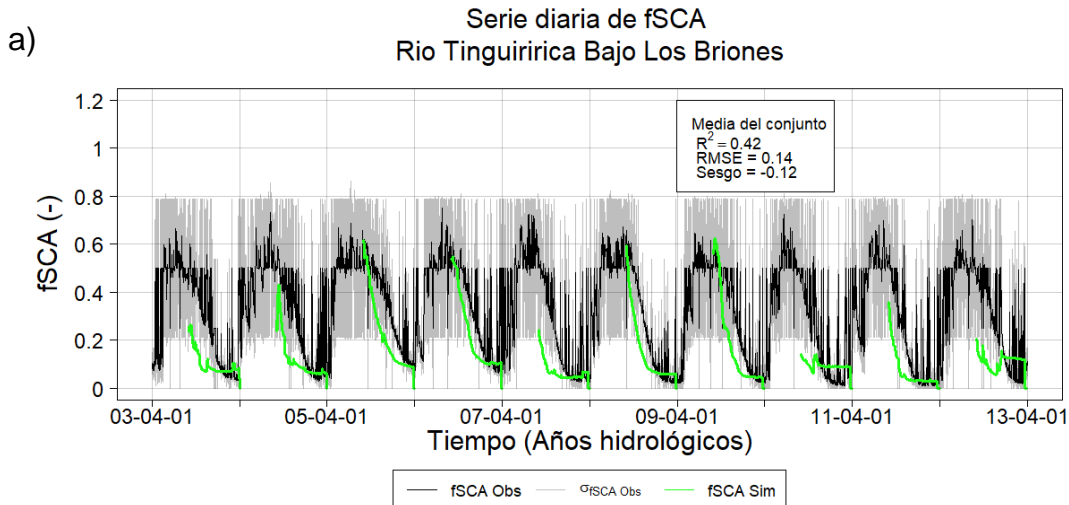


Figura 5-7: Comparación de series diaria de fSCA. En el panel a) se muestra las series diaria de fSCA simulada en la temporada de derretimiento (septiembre a marzo), y observada de la cuenca Rio Tinguiririca Bajo Los Briones entre los años hidrológicos 2003 y 2012 inclusive. El panel b) corresponden a gráficos de dispersión entre las series observadas y simuladas considerando la temporada de derretimiento (septiembre a marzo).

5.5.3. Resultados de asimilación variacional

Las series de tiempo de SWE que se modelan con parámetros *default* son denominadas “sin asimilación” en este trabajo. Los parámetros *default* del modelo se muestran en la Tabla A-1. El promedio del conjunto de dos miembros corresponde a la serie “con asimilación”. Si bien cada miembro del conjunto satisface las ecuaciones de continuidad del modelo, este promedio no necesariamente satisface las ecuaciones de continuidad porque depende de la linealidad de las ecuaciones del modelo, sin embargo, representa una simulación que se ajusta a una mayor cantidad de escenarios distintos debido a que los parámetros fueron obtenidos en dos años hidrológicamente distintos.

Las series con y sin asimilación son contrastadas con la serie generada por Cornwell et al., (2016), que es utilizada como verdadero estado del sistema. La Figura 5-8 muestra las series de SWE para la subcuenca A. El uso de la asimilación de la fSCA disminuye la tasa de acumulación de nieve, aumento la tasa de derretimiento y puede mejorar series de SWE en relación directa con el monto de precipitación anual lo que se corrobora en la Figura 5-10. El aumento en la tasa de derretimiento es efecto del modelo de Liston (2004) pero no así la acumulación debido a que observaciones de dicho período no fueron consideradas para calibrar.

Si se compara las series con asimilación con el verdadero estado, las series con asimilación presentan diferencias notorias. Presentan menores magnitudes máximas lo que indica que el modelo al calibrarse con observaciones de fSCA no genera un set de parámetros que satisface el sistema. Esto se debe a que las observaciones se pueden ajustar de buena manera a distintos montos de SWE que tengan un derretimiento tal que satisfagan la ecuación (4.16) sobre $\Gamma(D_m)$. Por esto se sugiere usar complementariamente otra fuente de información para calibrar el modelo, la cual podría ser series de caudal o montos de SWE en determinados instantes de tiempo. Tienen menor dispersión en cuanto a magnitudes *peak* para un instante específico que se puede deber a que la radiación neta de onda corta no considera la atenuación por presencia espacialmente variable de nubes principalmente desde marzo a agosto aunque a escala de URH no varíe demasiado. También se puede deber a que la regularización de parámetros generaría series de SWE similares en cuanto a magnitud que solo serían afectadas por las ecuaciones que dispone el modelo. En este caso el modelo CRHM genera diferencias radiativas entre URH que actualmente son consecuencias de pendiente y orientación, lo que se llama la radiación neta sobre plano inclinado, y no considera factores como la obstrucción por topografía o alta reflectancia de pendientes colindantes que presenten un albedo alto debido a presencia de nieve. No presentan un monto de SWE nulo debido a que la serie de fSCA con que se calibra presenta el mismo comportamiento sin anularse incluso en el término de la temporada de deshielo. Presentan un desfase en la sincronización al comparar los *peaks* del estado verdadero que es durante el mes de agosto o incluso antes y en la simulación es aproximadamente el 21 de septiembre. Esto implica que el modelo no representa bien la época de acumulación, que en efecto no fue considerada en la asimilación, y sugiere

que para implementar el presente marco de asimilación se debe considerar información del período de acumulación, ya sea fSCA o SWE como información complementaria.

Por otro lado, las series de tiempo de SWE estimadas por Cornwell et al. (2016) presentan mayor dispersión de magnitudes *peak* a diferencia de las series con y sin asimilación debido a los factores antes dichos. Además, poseen un derretimiento más intenso y prematuro al punto que antes del inicio de febrero el SWE es nulo lo que sugiere que Cornwell et al., (2016) utiliza un método de remoción de la influencia glacial para determinar el SWE que es distinta de quitar la máscara del inventario glacial de la DGA.




Figura 5-8: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2014) para la subcuenca A para los años 2004 y 2005.

En las otras subcuencas, cuyas figuras se muestran en el ANEXO C en general se aprecia un comportamiento similar el que consta de una mejora de modelación del sistema por parte de la serie con asimilación pero que no es suficiente para modelar características importantes de las series que fueron nombradas en los párrafos anteriores.

Las figuras Figura 5-9 y Figura 5-10 presentan las métricas de evaluación de las series diarias de SWE de las URH de cada subcuenca para los años 2004 y 2005 pero, la primera muestra las métricas de evaluación absolutas y la segunda muestra las métricas de diferencia al usar el marco de asimilación, las cuales si son positivas indican una mejora y negativas un empeoramiento. Las series con asimilación presentan una media espacial y temporal de 0,55 de R^2 , 500 kg/m² de RMSE y -330 kg/m² de sesgo. El sesgo implica que las series en general subestiman la cantidad de

SWE pero, en cambio el RMSE al ser mayor en valor absoluto que el sesgo implica que la diferencia con el verdadero estado es mayor en ciertos instantes de las series y que además no subestima durante todo el período sino que subestima durante los instantes de *peaks* máximos y sobreestima durante los meses de diciembre y enero. Esto se corrobora con lo dicho anteriormente, que durante la época estival el SWE simulado es mayor al verdadero SWE.

La Figura 5-10 presenta las métricas de cambio, que indican una mejora de la variabilidad temporal, dado por la ΔR^2 , y de magnitud, dado por la $\Delta RMSE$ y la $\Delta Sesgo$. En promedio el R^2 mejora unas 0,11 y 0,3 unidades en 2004 y 2005 respectivamente. En cuanto a magnitud se obtienen mejoras de 170 y 610 kg/m² de RMSE y de 90 y 560 kg/m² de sesgo para los años 2004 y 2005 respectivamente. Esto indica que los parámetros calibrados mejoran más la simulación para años más húmedos ya que el año 2005 es más húmedo que el 2004 lo que se debe a que los años utilizados para calibrar el modelo corresponden a un año húmedo y normal (2005 y 2009 respectivamente).

Por otra parte, se destacan las series con asimilación de las subcuencas H, I, J, M y N presentan una mediana de RMSE más bajo que las demás subcuencas. Sin embargo, lo anterior no implica que estas subcuencas tengan una buena simulación debido a que se encuentran en la parte baja de cuenca, bajo los 2000 m.s.n.m. y equivalen a menos del 30% de extensión de la cuenca, donde no nieva. Por lo tanto, el sesgo relativo medio sería grande aun cuando su mediana de RMSE sea menor a 400 kg/m². Lo anterior también ocurre el año 2004 que presenta menores valores de RMSE para más subcuencas en comparación con el año 2005 pero, en este caso se debe a que el año 2004 es un año menos húmedo que el 2005 y por lo tanto, presenta menores magnitudes de SWE.

Evaluación de modelación sin y con asimilación

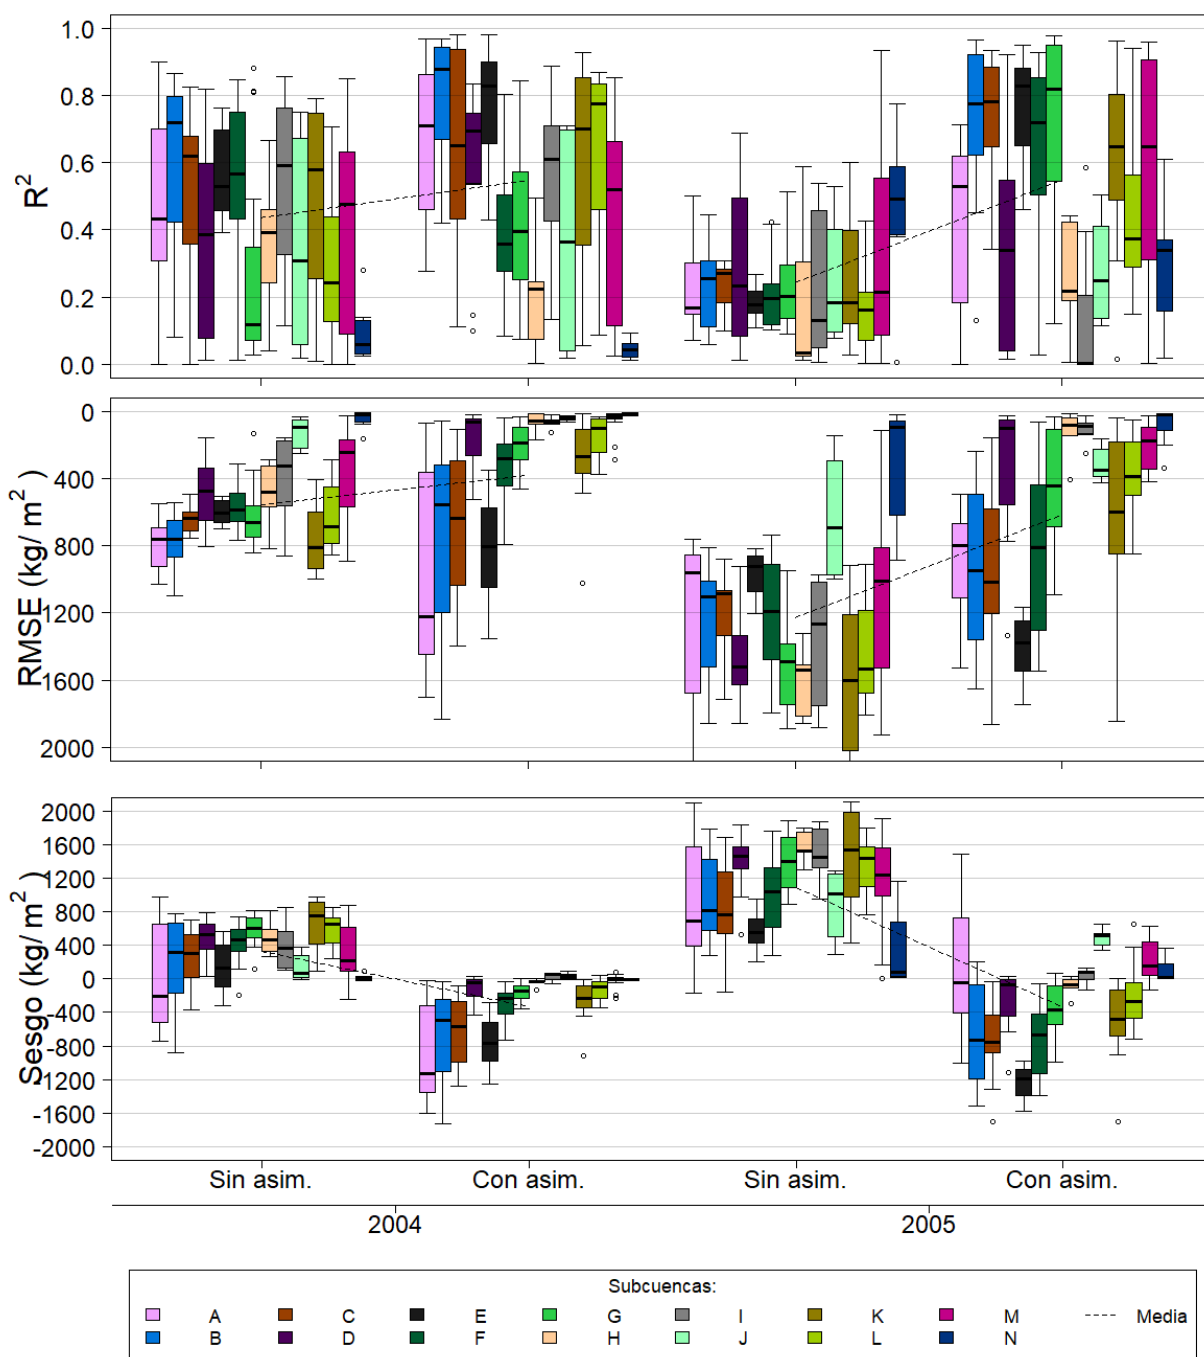


Figura 5-9: Desempeño en cuanto a R^2 , RMSE y Sesgo de las series de SWE con y sin asimilación. Se utiliza la serie Cornwell et al. (2016) como estado verdadero.

Evaluación de incorporar asimilación

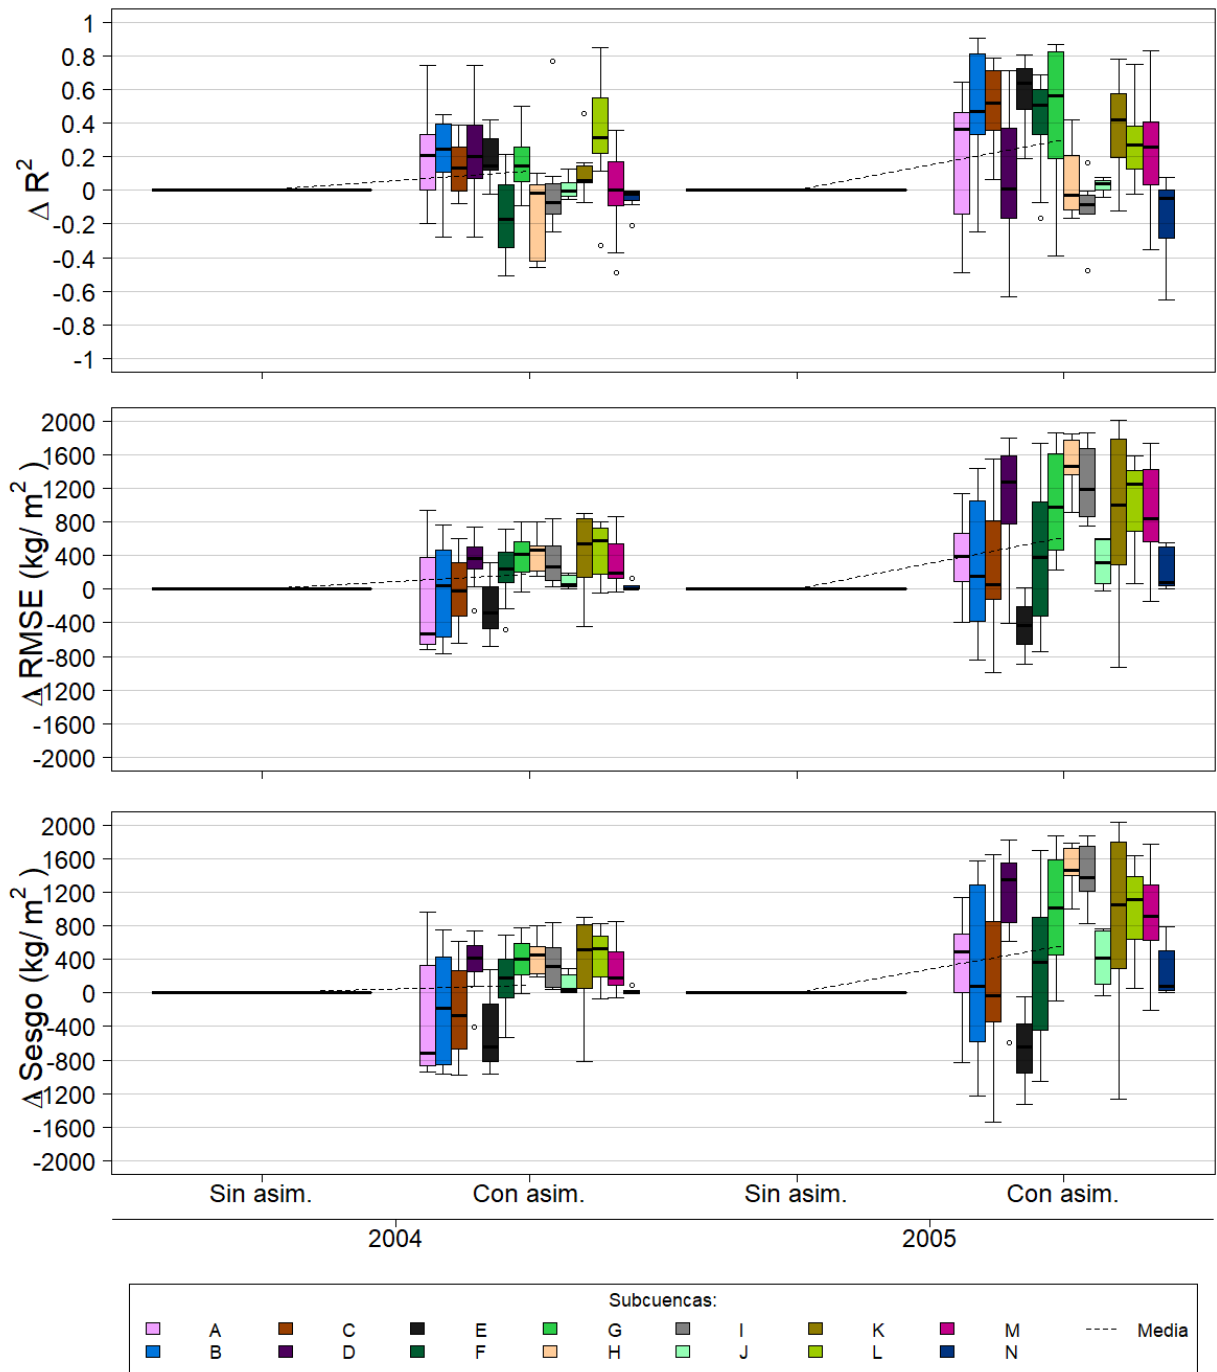


Figura 5-10: Desempeño en cuanto a ΔR^2 , $\Delta RMSE$ y $\Delta Sesgo$ de las series de SWE con asimilación y sin asimilación. Cada serie es comparada con la serie sin asimilación.

5.6. Corrección de pronóstico meteorológico con QDM (Cannon et al., 2015)

En la Figura 5-11 se muestra, a modo de ejemplo, una comparación entre las forzantes utilizadas en DGA (2019) y las forzantes utilizadas para pronosticar el SWE para el año hidrológico 2003. Es posible notar que las magnitudes del pronóstico meteorológico son más bajas que las forzantes de DGA (2019) y que por lo tanto se deben corregir. Las forzantes corregidas presentan magnitudes más similares que sin corrección. No obstante, el pronóstico corregido y las forzantes de DGA (2019) no presentan sincronización y los montos mensuales de precipitación no son similares a partir del mes de noviembre en adelante. Si bien los pronósticos estacionales no buscan la sincronización de la precipitación, si buscan que montos estacionales sean similares, lo que en este caso no se cumple para la temporada deshielo durante precipitaciones ocasionales. Esto afecta el pronóstico de SWE solo si precipita en forma sólida y por ende depende de la meteorología de la temporadas de deshielo, efecto que se corrobora al comparar el pronóstico de SWE con la serie con asimilación que utiliza forzantes verdaderas.




Figura 5-11: Comparación de pronóstico de precipitación escalado con QDM (Cannon et al. 2015) y precipitación utilizada en DGA (2019).

5.7. Pronóstico de SWE

El pronóstico de SWE con CRHM busca analizar si los pronósticos meteorológicos generan series de SWE que se ajusten bien a las series del estado verdadero pero, como se ve en el punto anterior incluso las forzantes de DGA (2019) no generan buenas simulaciones. Por esto es que no se busca como objetivo que la series sean

buenas sino que se tengan desempeño similar a las series con asimilación mostradas en el punto anterior. Además se compara si distintos tiempos de inicio de pronóstico generan mejores series de SWE para obtener la fecha de inicio óptima de pronóstico de SWE.

Si comparamos las métricas de evaluación medias entre las series con asimilación forzadas con forzantes de DGA (2019) con las series con asimilación pero forzadas con las forzantes de los pronósticos meteorológicos, cuyos valores están resumidos en la Tabla 5-4, el pronóstico iniciado el 1 de agosto obtiene una disminución en R^2 y aumento de RMSE y sesgo para los dos años. En particular las pérdidas de desempeño fueron de 0,06 de R^2 , 6 kg/m^2 de RMSE y 39 kg/m^2 de sesgo para el año 2004 y de 0,08 unidades de R^2 , 48 kg/m^2 de RMSE y 19 kg/m^2 de sesgo para el año 2005. Esto significa que el error del pronóstico de SWE aumenta proporcional al monto de precipitación anual.

En la Figura 5-12 se presentan las métricas de evaluación de los pronósticos, en la cual se puede ver que los distintos pronósticos no varían considerablemente, la diferencia de R^2 , $RMSE$ y $Sesgo$ es menor a 0,05, 5 kg/m^2 y 5 kg/m^2 entre pronósticos. Esto se corrobora en la Figura 5-13 en la cual se comparan las diferencias de métricas de evaluación de cada pronóstico con respecto al pronóstico iniciado el 1 de agosto. El pronóstico cuyo inicio es el 1 de agosto tiene mejor sincronización que los otros pronósticos lo que implica que si se quiere realizar pronósticos semanales o diarios de SWE o caudal usando el SWE simulado con pronósticos meteorológicos como forzantes, el pronóstico iniciado el 1 de agosto tendría mayor sincronización con el verdadero estado. En el caso de analizar magnitudes de SWE, ya sean diarias, semanales o mensuales, no influye la fecha de inicio del pronóstico pues todos tienen errores similares.

Tabla 5-4: Comparación de desempeño entre simulación sin pronóstico y con pronóstico meteorológico.

Simulación	2004			2005		
	R^2	RMSE	Sesgo	R^2	RMSE	Sesgo
Con asimilación y forzantes DGA (2019)	0.55	385	-333	0.55	616	-331
Pronóstico inicio 1 de agosto	0.49	391	-294	0.47	664	-312
Pronóstico inicio 1 de septiembre	0.46	392	-291	0.41	666	-303
Pronóstico inicio 1 de octubre	0.46	392	-292	0.44	665	-306
Pronóstico inicio 1 de diciembre	0.46	392	-292	0.44	665	-306

Evaluación de pronósticos




Figura 5-12: Desempeño en cuanto a R^2 , $RMSE$ y $Sesgo$ de las series de SWE forzadas con los distintos pronósticos meteorológicos para cada subcuena para los años 2004 y 2005.

Evaluación de pronósticos con respecto a pronóstico 08-01

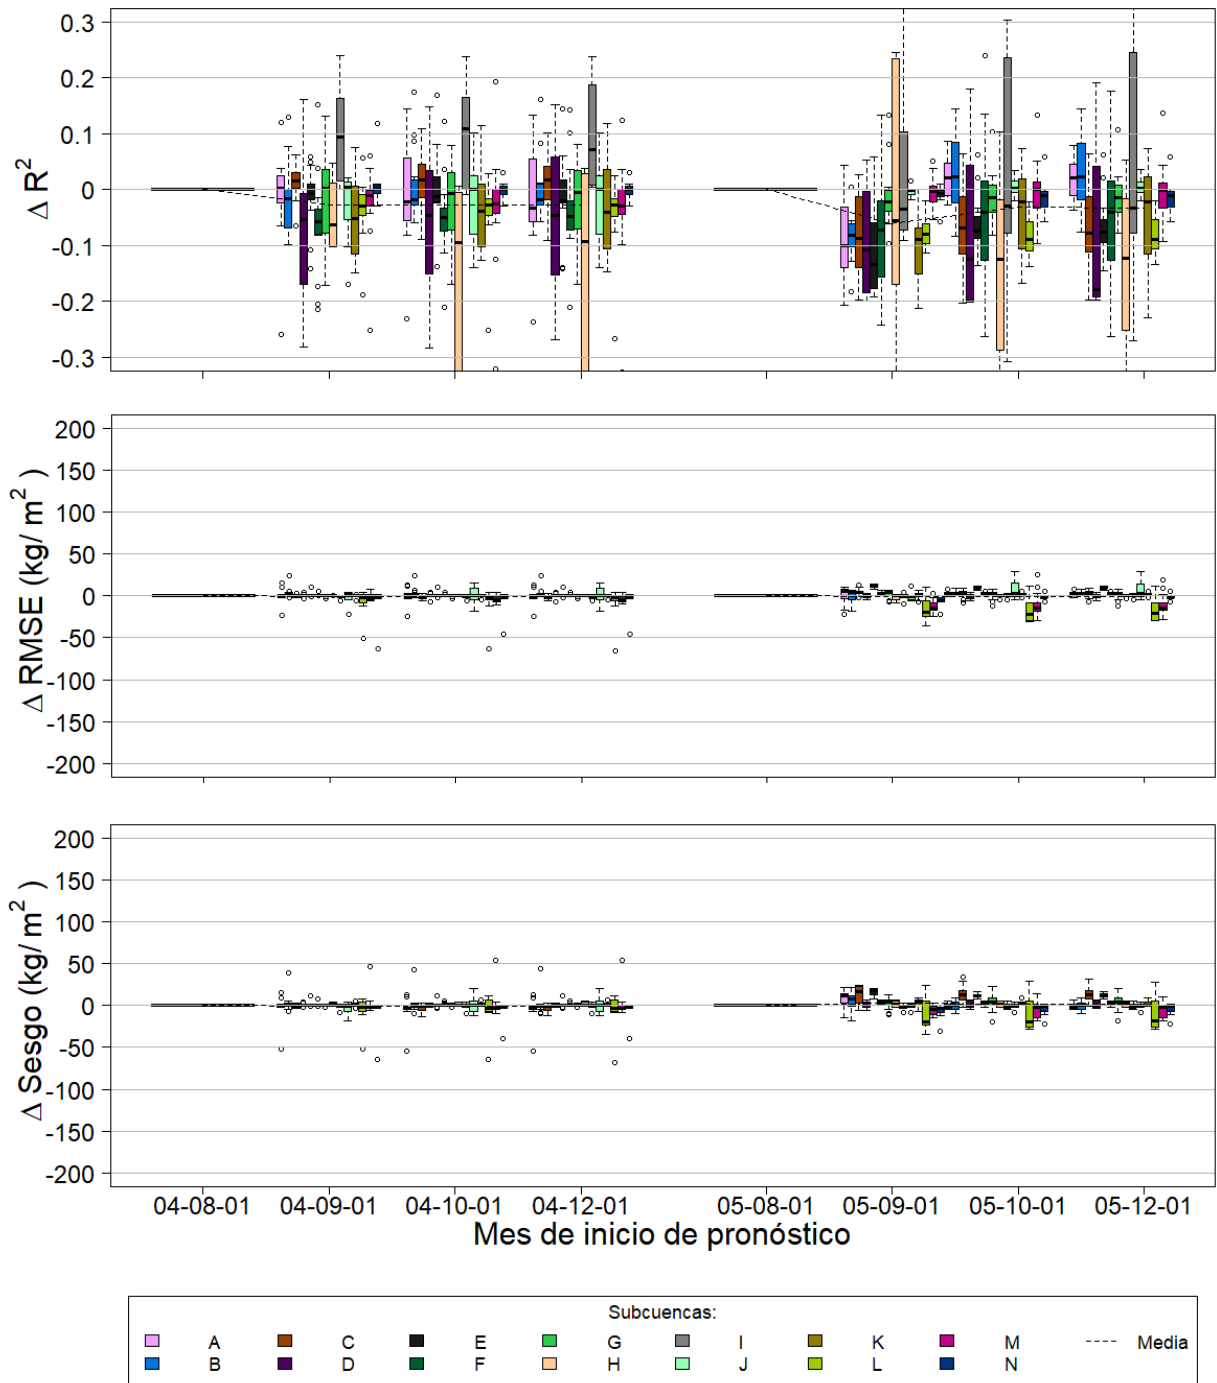


Figura 5-13: Desempeño en cuanto a ΔR^2 , $\Delta RMSE$ y $\Delta Sesgo$ de las series de SWE forzadas con pronósticos meteorológicos. El desempeño de cada serie forzada con cada pronóstico meteorológico es comparado con la serie forzada con el pronóstico meteorológico cuyo inicio es el 1° de agosto para cada subcuenca para los años 2004 y 2005.

Capítulo 6: Conclusiones

Determinar la cantidad de nieve que estará disponible para el período de deshielo es importante para determinar caudales de deshielo y programar la operación de las centrales hidroeléctricas, programas de agua potable, minería y otras actividades productivas. Esto motiva el análisis de pronósticos de SWE utilizando pronósticos meteorológicos estacionales y un método de asimilación de fSCA en la cuenca alta del río Tinguiririca.

6.1. Comentarios generales

El método de remoción de nubes de Parajka and Blöschl (2008) presenta un RMSE de 8% de la fSCA del pixel pero, a pesar de la utilización del método, la incertidumbre que sigue existiendo en la temporada de precipitación es grande. El método de estimación de datos faltantes que no pudieron ser corregidos como valor más probable de 0,5 no es la mejor estimación debido a la falta de ajuste entre la simulación y observación. Esto afecta el método de asimilación variacional porque entrega más peso a las observaciones que tienen menos incertidumbre y puede errar los montos de fSCA máxima que se obtienen durante el período de precipitación.

La precipitación que se utiliza presenta diferencias en la variabilidad temporal (R^2 de 0,24) con respecto a la observada lo que impacta en la variabilidad temporal del SWE. No obstante, los montos mensuales tienen bajo RMSE y sesgo (< 15 mm; subestimación) y por lo tanto la serie no se ve afectada en cuanto a magnitud por la precipitación. En el caso de la temperatura, la serie utilizada presenta un sesgo de -2.1 °C (subestimación) lo que extendería la permanencia del SWE cuando el verdadero SWE es nulo.

La serie de SWE es sensible a los parámetros de los módulos de interceptación vegetal (CanopyClearing), de nieves (SnobalCRHM) y albedo (Albedo). Los parámetros que mayor espacio de parámetros con sensibilidad mayor a 0,2 que son determinantes para disminuir problemas de equifinalidad son "hru_T_g", "Sbar", "LAI". Estos parámetros no fueron bien calibrados ya que el parámetro "hru_T_g" presenta valores de aproximadamente 30°C más bajos que los presentados en estudios en cuencas más frías. Por lo tanto el esquema de asimilación presenta problemas de equifinalidad.

El modelo con asimilación presenta 0,55 de R^2 , 500 kg/m² de RMSE y -330 kg/m² de sesgo promedio espacio-temporal, que equivale a 1 m de altura de nieve si se supone densidad de nieve de 495 kg/m³ que es el promedio de los parámetros calibrados, lo que no es suficiente para ser un buen pronóstico de SWE según los estándares de la DGA ($R^2 > 0,8$). La asimilación de fSCA mejora las métricas de evaluación en 0,21 de R^2 , 390 kg/m² de RMSE y 325 kg/m² de sesgo promedio espacio-temporal. Las mejoras tienen relación directa con el monto de precipitación anual del año sin embargo no se puede determinar si es lineal o de otro tipo. El modelo no representa de buena manera

el comportamiento del sistema debido a los parámetros que distan de la realidad. Sin embargo, el modelo con parámetros adecuados podría representar mejor el comportamiento. Además, no es posible aseverar que la falta de calibración del módulo de transporte por viento sea importante o no.

6.2. Resultados de la asimilación variacional

Los parámetros obtenidos al calibrar los años 2005 y 2009 no presentan una relación con respecto a la altura o tipo año de año hidrológico. Estos parámetros tienen una distribución amplia en el espacio de parámetros lo que sugiere que la regularización de parámetros que se utiliza (parámetros iguales para una subcuenca agrupada por elevación) no es buena y se deben usar métodos de agrupación de URH distintos.

La serie de fSCA que se simula de la cuenca alcanza los *peaks* de la fSCA observada por MODIS y los valles cuando la fSCA es casi nula. También subestima la fSCA observada por MODIS durante la temporada de deshielo y no puede simular los *peaks* de fSCA que ocurren durante la temporada de deshielo. Se obtiene un desempeño de la media de los miembros del conjunto equivalente a 0,42 de R^2 , 0,14 de RMSE y -0,12 de sesgo, lo cual es mayor que el desempeño en calibración y validación de cada miembro por separado e indica que ambos miembros son complementarios para obtener una simulación de fSCA.

La serie con parámetros por *default* que entrega el modelo no satisface el comportamiento del sistema lo cual no es sorprendente ya que se debe calibrar el modelo, lo que no se busca como objetivo en este trabajo. Al aplicar el marco de asimilación de fSCA, la serie con asimilación presenta una tasa de acumulación más lenta y una tasa de derretimiento más rápida que coincide de mejor manera en cuanto a forma con la serie verdadera que la serie sin asimilación.

Las series con asimilación tiene defectos en comparación con la serie verdadera y es que los montos máximos no se alcanzan, tiene menor dispersión de valores de SWE dentro de una subcuenca, existe SWE cuando el estado verdadero presenta SWE nulo y existe desfase en la sincronización entre las series que se nota en los *peaks* de SWE. Los montos máximos no se alcanzan debido a que existen muchas series de SWE que satisfacen el modelo de Liston (2004). Por esto es que se debe utilizar variables que no fueron consideradas en el presente trabajo como la atenuación de radiación por nubes, la obstrucción de radiación de onda corta por topografía y la reflectancia de radiación por topografía cubierta de nieve. Así se puede dejar de subestimar el SWE y obtener mayores magnitudes de SWE. Las series tienen menor dispersión debido a dos posibles razones, la falta de modelación de forzantes radiativas dichas anteriormente que incluyan los efectos que también influirían en la falta de ajuste de montos máximos y/o la técnica de regularización que se emplea para URH agrupadas por elevación y no variables hidrológicamente más importantes para el sistema criósfera. La permanencia de SWE durante la temporada de deshielo se debe a la subestimación de la temperatura en la forzante utilizada en el presente trabajo de 2.1 °C de RMSE, a que la serie fSCA se mantiene durante todo el año incluyendo el final de la temporada de

deshielo y/o que la máscara de glaciación no sea la adecuada para suprimir la influencia glaciación dentro de la serie de SWE y que si es adecuada en el caso de la serie verdadera. El desfase en la sincronización de las series de SWE se debe a que el modelo no representa bien la época de acumulación, lo que no es sorprendente pues, en efecto no fue considerada en la asimilación.

6.3. Pronóstico meteorológico de SWE

El pronóstico meteorológico SEAS5 (Johnson et al., 2019) empeora la variabilidad temporal y en menor medida la magnitud del RMSE y sesgo, defectos que tienen relación directa con el monto de precipitación anual. La disminución de las métricas corresponde a 0,07 de R^2 , 27 kg/m^2 y 29 kg/m^2 de R^2 , RMSE y sesgo respectivamente. Al ser baja la magnitud del error, el pronóstico sirve para ser utilizado pero para montos semanales o mensuales, series que no exigen un alto ajuste de variabilidad temporal.

Se destaca que el pronóstico SEAS5 no puede representar las precipitaciones ocasionales que ocurren durante la temporada de deshielo, muchas de las cuales ocurren en enero, febrero y marzo. Estas precipitaciones tienen un efecto menor en la acumulación de SWE debido a las temperaturas de la temporada y tendrían mayor efecto en los montos de escorrentía, por lo que su efecto en el pronóstico de SWE es insignificante. Sin embargo, esta conclusión es particular para la cuenca y para el pronóstico meteorológico y puede no cumplirse siempre, más aún, no se cumple si se utiliza para pronósticos de caudal de deshielo.

La fecha de inicio de pronóstico óptima se determina que es el 1 de agosto porque la disminución de RMSE entre esta fecha de inicio de pronóstico y otras más tardías es menor a 40 kg/m^2 . También el pronóstico iniciado el 1 de agosto tiene mayor R^2 y por lo tanto un mayor ajuste de variabilidad temporal. El uso de otras fechas de inicio de pronóstico no mejora el desempeño de los pronósticos de SWE y más aún disminuye el desempeño de su variabilidad temporal. Por lo tanto, basta con pronosticar el SWE una sola vez utilizando el pronóstico SEAS5.

6.4. Sobre el marco de asimilación

El modelo de Liston (2004) funciona bien para la temporada de deshielo pero, la utilización de forzantes radiativas sin los efectos previamente dichos y la utilización de regionalización genera poca variabilidad espacial de SWE. Los valores del parámetro ajustado ξ indica que la forma de la curva de SDC se ajusta bien y valores bajos implican que la fSCA tiene una alta sensibilidad al derretimiento. Pero, se deben considerar los valores del parámetro ajustado λ que tiene mucha incertidumbre lo que se puede deber a que la serie de SWE que se simula no coincide con el verdadero SWE. Si el SWE simulado tuviese menor error puede que exista una distribución de menor incertidumbre de parámetros. El efecto de precipitación ocasional sobre manto de nieve

somero que modifica la función de distribución $f(D)$, que en el presente trabajo se considera constante para la temporada de deshielo, también puede afectar el ajuste de los parámetros de Liston (2004). Por lo tanto, no se puede afirmar que el modelo no funcione en cuencas de Chile. No obstante, el modelo no funcionaría debido a tener distintos valores de SWE para un único valor de fSCA en el caso de subcuencas que se ubiquen en la parte baja de la cuenca y donde la nieve cubra ocasionalmente y en forma heterogénea (con parches de nieve)

A pesar de que el marco de asimilación no haya obtenido un desempeño mínimo para los estándares de la DGA, no se puede excluir como método para pronosticar el SWE. El marco de asimilación tiene fortalezas como disminuir la tasa de acumulación, aumentar la tasa de derretimiento y puede mejorar series de SWE en relación directa con el monto de precipitación anual. También se deben considerar las debilidades, que no representa la temporada de acumulación, no representa acumulación de SWE debido a precipitaciones en la temporada de deshielo, no puede representar el comportamiento de $\Gamma(D_m)$ en zonas donde existe influencia glaciar y tampoco en la parte baja de la cuenca donde existe heterogeneidad de fSCA.

6.5. Sugerencias para el futuro trabajo

Para aplicar este marco de asimilación se debe considerar las sugerencias que se concluyen en el presente trabajo y que son necesarias para un correcto funcionamiento y que son las siguientes:

- Utilizar métodos de remoción de nubes que consideren una ventana temporal, información de píxeles adyacentes o modelos basados en alguna otra variable hidrológica o fisiográfica. Rellenar espacio-temporalmente los datos para asimilar toda la temporada de deshielo.
- Corregir las forzantes radiativas para considerar efectos de nubosidad, obstrucción por topografía y reflectancia de pendientes adyacentes con alto albedo.
- Utilizar información complementaria de albedo presente en productos satelitales de MODIS (i.e. MCD43A3, Strahler et al., 1999), mapas de cobertura vegetal de suelo y tipo de suelo y el uso de modelos de estimación de temperatura de suelo (Rankinen et al., 2004) para restringir los valores de los parámetros calibrados.
- Agrupar URH en función radiación neta incidente, topografía, vegetación y/o de un punto de vista más estadístico respuesta hidrológica del SWE y no en función de cercanía o elevación.
- Utilizar el marco de asimilación para determinar el SWE en áreas donde no existe influencia glaciar, además de utilizar otro método para delimitar las áreas

glaciares que puede ser basado en la respuesta hidrológica como presencia de SWE durante el año, tampoco en áreas donde exista heterogeneidad de fSCA.

- Utilizar información complementaria tal como series de caudal y/o montos de SWE distribuidos en determinados instantes que la función $\Gamma(D_m)$ se ajuste a los montos máximos y no tenga problemas de equifinalidad. Utilizar la información complementaria en la temporada de acumulación debido a que el modelo no asimila la fSCA en esta temporada.
- Considerar el efecto que tienen las precipitaciones ocasionales sobre mantos de nieve someros mediante cambios en la función de distribución $f(D)$ (λ y ξ) mediante algún algoritmo de convergencia de parámetros como usa Liston (2004) para mejorar el ajuste durante precipitaciones ocasionales.
- Corregir los sesgos que posea la forzante precipitación del pronóstico meteorológico. Sin embargo, debe estar sujeto al objetivo y condiciones particulares de la modelación. En este caso particular el pronóstico SEAS5 no se debe corregir debido a su baja influencia para el pronóstico de SWE.

BIBLIOGRAFÍA

- Aalstad, K., Westermann, S., Schuler, T. V., Boike, J., & Bertino, L. (2018). Ensemble-based assimilation of fractional snow-covered area satellite retrievals to estimate the snow distribution at Arctic sites. *Cryosphere*, 12(1), 247–270. <https://doi.org/10.5194/tc-12-247-2018>
- Ajai. (2010). *Snow and Glaciers of the HIMALAYAS: Inventory and Monitoring Space Applications Centre ISRO, Ahmedabad FOREWORD*.
- Anderson, E. A. (1976). *A Point Energy and Mass Balance Model of a Snow Cover*. NOAA Technical Report NWS 19.
- Barría, P. (2010). *Pronóstico de caudales medios mensuales en las cuencas de los ríos Baker y Pascua*.
- Bravo Liberona, C. (2018). *Estimación de las pérdidas del manto nival en la cuenca de la quebrada el teniente, vi región, Chile*.
- Busetto, L., & Ranghetti, L. (2016). MODISstp: An R package for automatic preprocessing of MODIS Land Products time series. *Computers and Geosciences*, 97, 40–48. <https://doi.org/10.1016/j.cageo.2016.08.020>
- 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. <https://doi.org/10.1175/JCLI-D-14-00754.1>
- Cartes Valdivia, M. (2009). *Pronóstico de volúmenes de deshielos mediante redes neuronales recurrentes e imágenes satelitales MODIS*.
- Chang, A. T. C., Foster, J. L., Hall, D. K., Goodison, B. E., Walker, A. E., Metcalfe, J. R., & Harby, A. (1997). Snow parameters derived from microwave measurements during the BOREAS winter field campaign. *Journal of Geophysical Research Atmospheres*, 102(24), 29663–29671. <https://doi.org/10.1029/96jd03327>
- Charrois, L., Cosme, E., Dumont, M., Lafaysse, M., Morin, S., Libois, Q., & Picard, G. (2016). On the assimilation of optical reflectances and snow depth observations into a detailed snowpack model. *Cryosphere*, 10(3), 1021–1038. <https://doi.org/10.5194/tc-10-1021-2016>
- Cherkauer, K. A., & Lettenmaier, D. P. (2003). Simulation of spatial variability in snow and frozen soil. *Journal of Geophysical Research: Atmospheres*, 108(22). <https://doi.org/10.1029/2003jd003575>
- Cline, D. W. (1997). Snow surface energy exchanges and snowmelt at a continental, midlatitude Alpine site. *Water Resources Research*, 33(4), 689–701. <https://doi.org/10.1029/97WR00026>

- Comte, M. (2017). *Modelación hidrológica de la cuenca del río Mapocho en Los Almendros usando el modelo Cold Regions Hydrological Model.*
- Cornwell, E., Molotch, N. P., & 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. <https://doi.org/10.5194/hess-20-411-2016>*
- Déry, S. J., & Yau, M. K. (1999). *A bulk blowing snow model.*
- DeWalle, D. R., & Rango, A. (2008). *Principles of snow hydrology.*
- DGA. (2014). *Análisis de la red nival necesaria para cuantificar los recursos hídricos, etapa ii. S.I.T. N° 353. In S.I.T. N° 353.*
- DGA. (2017). *Actualización del Balance Hídrico Nacional. Informe final. Resumen ejecutivo. S.I.T. N° 417.*
- DGA. (2019). *Aplicación de la metodología de actualización del Balance Hídrico Nacional en las cuencas de la macrozona sur y parte norte de la macrozona austral. S.I.T. N°441.*
- Donald, J. R., Soulis, E. D., Kouwen, N., & Pietroniro, A. (1995). *A land cover-based snow cover representation for distributed hydrologic models. In WATER RESOURCES RESEARCH (Vol. 31, Issue 4).*
- Dozier, J., & Painter, T. H. (2004). *Multispectral and hyperspectral remote sensing of alpine snow properties. In Annual Review of Earth and Planetary Sciences (Vol. 32, pp. 465–494). <https://doi.org/10.1146/annurev.earth.32.101802.120404>*
- Duan, Q., Sorooshian, S., & Gupta, V. (1992). *Effective and Efficient Global Optimization for Conceptual Rainfall-Runoff Models. Water Resources Research, 28(4), 1015–1031.*
- Erxleben, J., Elder, K., & Davis, R. (2002). *Comparison of spatial interpolation methods for estimating snow distribution in the Colorado Rocky Mountains. Hydrological Processes, 16(18), 3627–3649. <https://doi.org/10.1002/hyp.1239>*
- Evensen, G. (1994). *Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics. Journal of Geophysical Research, 99.*
- Gómez, F. (2019). *Evaluación de pronósticos meteorológicos para la modelación hidrológica del manto nival, en estación Valle Nevado.*
- Gray, D. M., & Landine, P. G. (1987). *Albedo model for shallow prairie snow covers. In Can. J. Earth Sci (Vol. 24).*

- Hall, D. K., Chang, A. T. C., & Foster, L. (1986). Detection of the depth-hoar layer in the snow-pack of the arctic coastal plain of Alaska, U.S.A., using satellite data. *Journal of Glaciology*, 32(110). <https://www.cambridge.org/core>.
- Hall, D. K., & G. A. Riggs. (2021). MODIS/Terra Snow Cover Daily L3 Global 500m SIN Grid, Version 61 USER GUIDE. Boulder, Colorado USA. NASA National Snow and Ice Data Center Distributed Active Archive Center. <https://doi.org/10.5067/MODIS/MOD10A1.061>
- Hong, M. A., & Yifeng, L. (1992). Energy balance of a snow cover and simulation of snowrn.elt in the western Tien Shan mountains, China. In *Annals of Glaciology* (Vol. 16). <https://www.cambridge.org/core>.
- Jazwinski, A. H. (1970). *Stochastic Processes and Filtering Theory*. *Matgematics in Science and Engineering*, 64.
- Johnson, S. J., Stockdale, T. N., Ferranti, L., Balmaseda, M. A., Molteni, F., Magnusson, L., Tietsche, S., Decremmer, D., Weisheimer, A., Balsamo, G., Keeley, S. P. E., Mogensen, K., Zuo, H., & Monge-Sanz, B. M. (2019). SEAS5: The new ECMWF seasonal forecast system. *Geoscientific Model Development*, 12(3), 1087–1117. <https://doi.org/10.5194/gmd-12-1087-2019>
- Kalman, R. E. (1960). A New Approach to Linear Filtering and Predictions Problems. *Journal of Basic Engineering*, 82 (Series D): 35-45, 82 (Series D), 35–45.
- Kumar, S. v., Reichle, R. H., Harrison, K. W., Peters-Lidard, C. D., Yatheendradas, S., & Santanello, J. A. (2012). A comparison of methods for a priori bias correction in soil moisture data assimilation. *Water Resources Research*, 48(3). <https://doi.org/10.1029/2010WR010261>
- Lagos Zúñiga, M. Á., & Jara, F. (2017). Estimación de la línea de nieves utilizando técnicas de precepción remota, entre-28° y-36° de latitud ¿qué ha pasado desde Peña y Vidal? <https://www.researchgate.net/publication/337196120>
- Lahoz, W., Khattatov, B., & Ménard, R. (2010). Data assimilation: Making sense of observations. In *Data Assimilation: Making Sense of Observations*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-540-74703-1>
- Larue, F., Royer, A., de Sève, D., Roy, A., & Cosme, E. (2018). Assimilation of passive microwave AMSR-2 satellite observations in a snowpack evolution model over northeastern Canada. *Hydrology and Earth System Sciences*, 22(11), 5711–5734. <https://doi.org/10.5194/hess-22-5711-2018>
- Liston, G. E. (2004). *Representing Subgrid Snow Cover Heterogeneities in Regional and Global Models*.
- Liu, Y., & Gupta, H. v. (2007). Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework. In *Water Resources Research* (Vol. 43, Issue 7). <https://doi.org/10.1029/2006WR005756>

- Male, D. H., & Granger, R. J. (1981). Snow Surface Energy Exchange. In *WATER RESOURCES RESEARCH* (Vol. 17, Issue 3).
- Margulis, S. A., Cortés, G., Giroto, M., & Durand, M. (2016). A landsat-era Sierra Nevada snow reanalysis (1985-2015). *Journal of Hydrometeorology*, 17(4), 1203–1221. <https://doi.org/10.1175/JHM-D-15-0177.1>
- McKay, G., & Gray, D. (1981). *Handbook of Snow*. Chapter 5: The distribution of snowcover.
- Moeser, D., Stähli, M., & Jonas, T. (2015). Improved snow interception modeling using canopy parameters derived from airborne LiDAR data. *Water Resources Research*, 51(7), 5041–5059. <https://doi.org/10.1002/2014WR016724>
- Montecinos, A., & Aceituno, P. (2003). Seasonality of the ENSO-Related Rainfall Variability in Central Chile and Associated Circulation Anomalies.
- Oaida, C. M., Reager, J. T., Andreadis, K. M., David, C. H., Levoe, S. R., Painter, T. H., Bormann, K. J., Trangsrud, A. R., Giroto, M., & Famiglietti, J. S. (2019). A high-resolution data assimilation framework for snow water equivalent estimation across the Western United States and validation with the Airborne Snow Observatory. *Journal of Hydrometeorology*, 20(3), 357–378. <https://doi.org/10.1175/JHM-D-18-0009.1>
- Parajka, J., & Blöschl, G. (2008). Spatio-temporal combination of MODIS images - Potential for snow cover mapping. *Water Resources Research*, 44(3). <https://doi.org/10.1029/2007WR006204>
- Pomeroy, J., Hedstrom, N., & Gray, D. (1998). Coupled Modelling of Forest Snow Interception and Sublimation.
- Pomeroy, J. W., Gray, D. M., Brown, T., Hedstrom, N. R., Quinton, W. L., Granger, R. J., & Carey, S. K. (2007). The cold regions hydrological model: A platform for basing process representation and model structure on physical evidence. *Hydrological Processes*, 21(19), 2650–2667. <https://doi.org/10.1002/hyp.6787>
- Pomeroy, J. W., Gray, D. M., Hedstrom, N. R., & Janowicz, J. R. (2002). Prediction of seasonal snow accumulation in cold climate forests. *Hydrological Processes*, 16(18), 3543–3558. <https://doi.org/10.1002/hyp.1228>
- Prowse, T. D., & Owens, I. F. (1982). Energy balance over melting snow, Craigieburn Range, New Zealand. In *Source: Journal of Hydrology* (Vol. 21, Issue 2). <https://about.jstor.org/terms>
- Rankinen, K., Karvonen, T., & Butterfield, D. (2004). A simple model for predicting soil temperature in snow-covered and seasonally frozen soil: model description and testing. In *Hydrology and Earth System Sciences* (Vol. 8, Issue 4).

- Rohrer, M., & Braun, L. (1994). Long-Term Records of Snow Cover Water Equivalent in the Swiss Alps. 2. Simulation Data climatica View project Indian Himalayas Climate Adaptation Program View project. <https://www.researchgate.net/publication/263397958>
- Rott, H., Sturm, K., & Miller, H. (1993). Active and passive microwave signatures of Antarctic firn by means of field measurements and satellite data. In *Annals of Glaciology* (Vol. 17). <https://www.cambridge.org/core>.
- Smyth, E. J., Raleigh, M. S., & Small, E. E. (2019). Particle Filter Data Assimilation of Monthly Snow Depth Observations Improves Estimation of Snow Density and SWE. *Water Resources Research*, 4, 1296–1311. <https://doi.org/10.1029/2018WR023400>
- Stewart, R. E., Szeto, K. K., Reinking, R. F., Clough, S. A., & Ballard, S. P. (1998). Midlatitude cyclonic cloud systems and their features affecting large scales and climate. *Reviews of Geophysics*, 36(2), 245–273. <https://doi.org/10.1029/97RG03573>
- Stigter, E. M., Wanders, N., Saloranta, T. M., Shea, J. M., Bierkens, M. F. P., & Immerzeel, W. W. (2017). Assimilation of snow cover and snow depth into a snow model to estimate snow water equivalent and snowmelt runoff in a Himalayan catchment. *Cryosphere*, 11(4), 1647–1664. <https://doi.org/10.5194/tc-11-1647-2017>
- Thirel, G., Salamon, P., Burek, P., & Kalas, M. (2013). Assimilation of MODIS snow cover area data in a distributed hydrological model using the particle filter. *Remote Sensing*, 5(11), 5825–5850. <https://doi.org/10.3390/rs5115825>
- U.S. Army Corps of Engineers. (1956). *Snow hydrology*.
- Vásquez, N. A. (2018). *Incorporación de información de percepción remota para mejorar la representación de procesos del ciclo hidrológico usando el modelo CRHM. aplicación en la cuenca del río Elqui, Chile*.
- Xiao, J., Bintanja, R., Déry, S. J., Mann, G. W., & Taylor, P. A. (2000). An intercomparison among four models of blowing snow. In *Boundary-Layer Meteorology* (Vol. 97).

ANEXOS

ANEXO A: Parámetros usados en la calibración

La Tabla A-1 presenta los límites inferiores, y superiores y por defecto que entrega el modelo CRHM. Estos límites se utilizan en la calibración de parámetros al asimilar la fSCA.

La Tabla A-2 presenta los límites de los parámetros del modelo de parametrización subgrilla de Liston (2004) usados en este trabajo.

La Tabla A-3 presenta los parámetros calibrados resultantes de la asimilación de fSCA para los dos años.

Tabla A-1: Valores inferiores y superiores de los parámetros a determinar en el método variacional y utilizados como serie sin asimilación.

Parámetro	Límite inferior	Límite superior	Valor sugerido (Serie sin asimilación)
Albedo_bare	0.00	0.30	0.17
Albedo_snow	0.70	1.00	0.8
LAI	0.10	20.00	0.1
Sbar	0.00	100.00	0.1
unload_t_water	1.00	20.00	1
hru_rho_snow	50.00	1000.00	300
max_h2o_vol	0.00	0.20	0.2
KT_sand	0.01	3.00	0.55
max_z_s_0	0.00	0.35	0.1
z_0	0.00	0.10	0.001
hru_T_g	-50.00	0.00	0

Tabla A-2: Límites de parámetros de Liston (2004).

Parámetro	mínimo	máximo
λ	0	8,3
ε	0	3,3

Tabla A-3: Resultados de calibración para las 14 subcuencas para los dos años de calibración 2005 y 2009. Filas coloreadas en gris corresponde a subcuencas o calibradas debido a no contar con suficientes observaciones de fSCA con incertidumbre menor a 0,1 para realizar el ajuste del modelo de Liston (2004).

Año	Subcuenca	Albedo_bare (-)	Albedo_snow (-)	LAI (-)	Sbar (kg/m ²)	unload_t_water (°C)	hru_rho_snow (kg/m ³)	max_h2o_vo l (-)	KT_sand (J/m/seg/K)	max_z_s_0 (m)	z_0 (m)	hru_T_g (K)
2005	A	0.11	0.88	19.9	85.1	6.4	495	0.08	2.00	0.17	0.05	-32.0
2005	B	0.21	0.89	18.1	89.5	7.1	287	0.20	2.34	0.19	0.05	-30.8
2005	C	0.21	0.89	19.2	83.2	12.1	101	0.03	2.65	0.04	0.05	-34.3
2005	D	0.07	0.74	12.6	90.9	3.1	389	0.15	2.69	0.31	0.06	-24.3
2005	E	0.06	0.71	18.2	95.6	3.4	226	0.14	1.29	0.17	0.04	-32.3
2005	F	0.17	0.88	16.1	81.0	12.1	329	0.08	0.75	0.20	0.07	-26.2
2005	G	0.17	0.96	18.3	90.8	8.7	780	0.10	2.09	0.15	0.06	-20.6
2005	H	0.23	0.92	13.7	55.0	10.7	734	0.10	1.80	0.02	0.06	-42.2
2005	I	0.06	0.99	15.9	51.7	1.5	595	0.13	2.20	0.04	0.10	-42.3
2005	J	0.09	0.72	18.6	55.7	19.0	205	0.19	2.97	0.17	0.06	-1.6
2005	K	0.25	0.80	12.6	62.4	14.8	172	0.20	2.52	0.05	0.06	-28.7
2005	L	0.17	0.81	12.6	14.3	5.0	467	0.11	1.07	0.14	0.06	-29.0
2005	M	0.22	0.86	1.9	84.2	12.7	419	0.08	1.17	0.18	0.06	-37.9
2005	N	0.17	0.85	2.2	6.6	4.0	100	0.05	0.03	0.05	0.10	0.0
2009	A	0.20	0.83	12.7	41.0	10.5	266	0.17	0.49	0.19	0.06	-9.4
2009	B	0.25	0.87	6.3	64.2	4.1	275	0.16	0.57	0.20	0.06	-28.1
2009	C	0.14	0.72	7.0	62.5	13.2	639	0.04	0.19	0.17	0.07	-3.2
2009	D	0.05	0.73	17.4	73.7	17.8	975	0.06	1.04	0.29	0.05	-33.5
2009	E	0.27	0.99	16.2	88.4	13.5	658	0.05	1.88	0.02	0.02	-34.2
2009	F	0.25	0.99	18.3	98.6	17.5	183	0.09	1.50	0.00	0.09	-38.2
2009	G	0.08	0.77	15.2	34.8	1.8	50	0.09	2.29	0.27	0.10	-0.8
2009	H	0.09	0.74	14.6	71.8	1.6	120	0.11	1.96	0.23	0.05	-46.3
2009	I	0.08	0.88	14.5	58.1	19.8	386	0.18	1.25	0.24	0.05	-42.7
2009	J	0.17	0.85	2.2	6.6	4.0	100	0.05	0.03	0.05	0.10	0.0
2009	K	0.06	0.95	15.1	95.4	6.0	360	0.08	2.35	0.11	0.09	-48.8
2009	L	0.01	0.93	1.1	0.6	12.1	251	0.11	0.65	0.25	0.08	-5.5
2009	M	0.23	0.96	0.5	29.1	13.4	590	0.08	0.23	0.02	0.06	-47.3
2009	N	0.17	0.85	2.2	6.6	4.0	100	0.05	0.03	0.05	0.10	0.0

ANEXO B: Resultados de modelo de distribución subgrilla de Liston (2004)

Los valores de los parámetros del modelo de distribución subgrilla de Liston (2004) se presentan en *boxplots*, de los cuales un *boxplot* agrupa la información de una subcuenca y cada par cajas del mismo color agrupa la información de los 10 años de una URH, en la Figura B-1, ..., Figura B-14




Figura B-1: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca A. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-2: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca B. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-3: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca C. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-4: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca D. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-5: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca E. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-6: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca F. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-7: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca G. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .

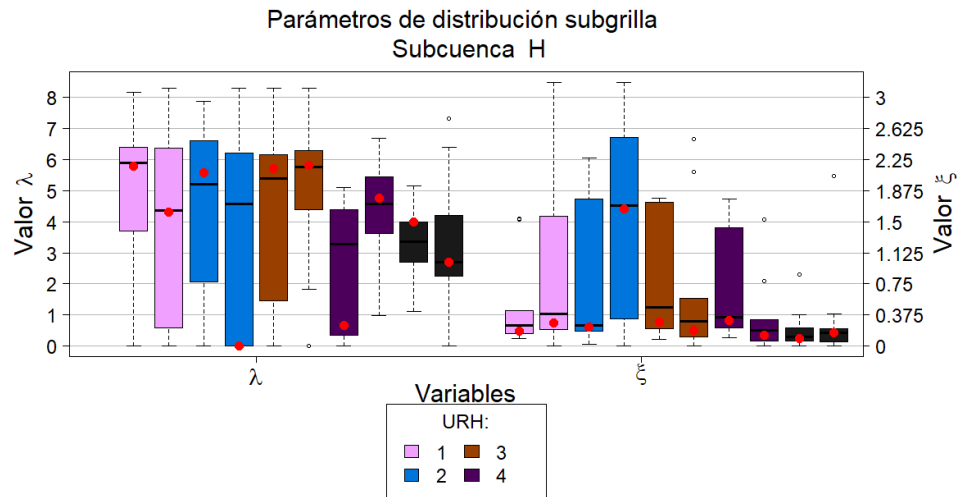


Figura B-8: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca H. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .

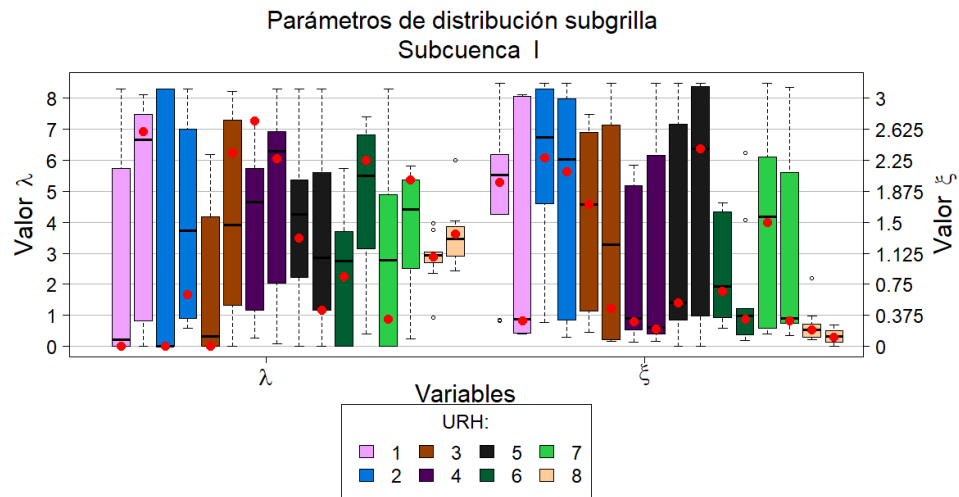


Figura B-9: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca I. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-10: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca J. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-11: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca K. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-12: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca L. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .




Figura B-13: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca M. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .

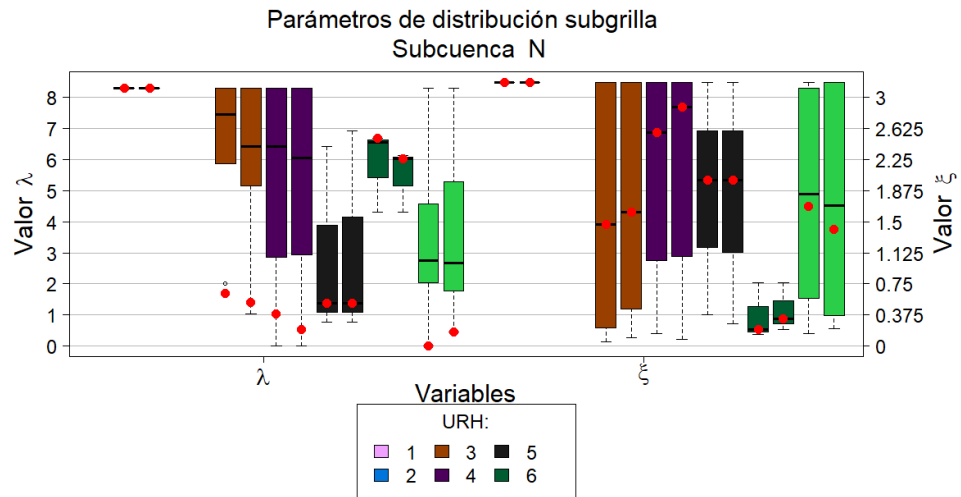


Figura B-14: Variables de distribución subgrilla de SWE del modelo de Liston (2004) para cada URH para la subcuenca N. Cada caja agrupa los valores de λ o ξ ajustados para cada uno de los 10 años simulados con los parámetros calibrados. Además, cada URH posee dos cajas en cada parámetro correspondientes a los parámetros ajustados con cada miembro calibrado en 2005 y 2009 respectivamente. Los puntos rojos son los valores del set de parámetros representativos determinados por la mediana del parámetro ξ .

ANEXO C: Resultados asimilación de fSCA

La Figura C-1, ..., Figura C-14 presentan las series de SWE del modelo con asimilación y sin asimilación, además de, la serie de Cornwell et al., (2016) y los miembros del conjunto.




Figura C-1: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2014) para la subcuenca A para los años 2004 y 2005.




Figura C-2: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca B para los años 2004 y 2005.




Figura C-3: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca C para los años 2004 y 2005.




Figura C-4: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca D para los años 2004 y 2005.




Figura C-5: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca E para los años 2004 y 2005.




Figura C-6: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca F para los años 2004 y 2005.




Figura C-7: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca G para los años 2004 y 2005.




Figura C-8: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca H para los años 2004 y 2005.




Figura C-9: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca I para los años 2004 y 2005.




Figura C-10: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca J para los años 2004 y 2005.




Figura C-11: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca K para los años 2004 y 2005.

Comparación de SWE con y sin asimilación Subcuenca L




Figura C-12: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca L para los años 2004 y 2005.

Comparación de SWE con y sin asimilación Subcuenca M

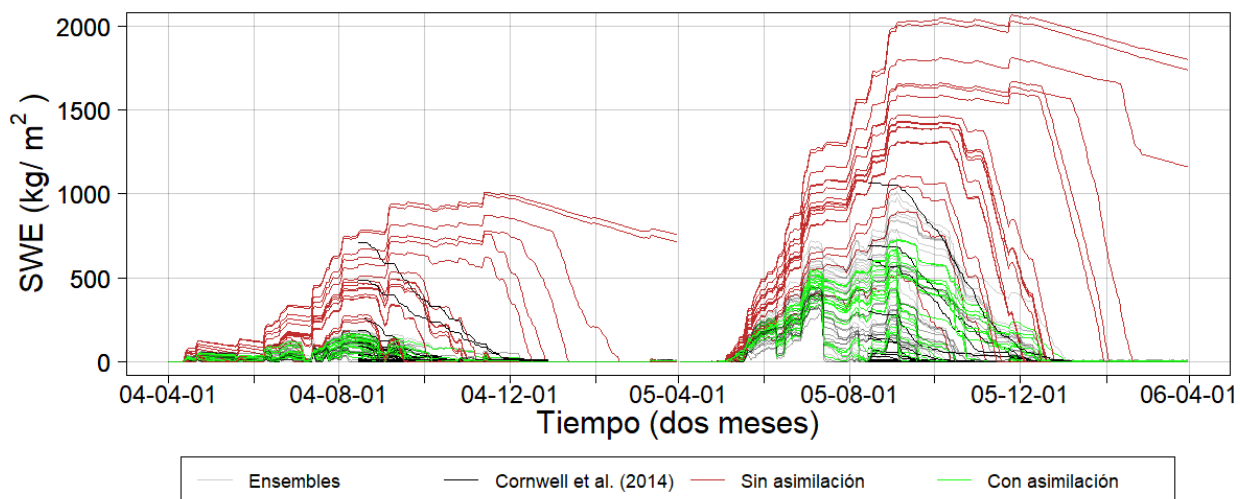


Figura C-13: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca M para los años 2004 y 2005.




Figura C-14: Comparación de SWE entre modelación sin asimilación, con asimilación y Cornwell et al. (2016) para la subcuenca N para los años 2004 y 2005.