



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

DEPARTAMENTO DE INGENIERÍA CIVIL

PRONÓSTICO DE VOLÚMENES DE DESHIELO EN CUENCAS DE LA REGIÓN DEL MAULE, CHILE

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL

CARLA ANTONIA CARMONA ROJAS

PROFESOR GUÍA

JAMES MCPHEE TORRES

PROFESOR CO-GUÍA

MIGUEL LAGOS ZÚÑIGA

MIEMBRO DE LA COMISIÓN

PABLO MENDOZA ZÚÑIGA

SANTIAGO DE CHILE

DICIEMBRE 2019

RESUMEN DE LA MEMORIA PARA OPTAR AL
TÍTULO DE: Ingeniera Civil
POR: Carla Carmona Rojas
FECHA: Diciembre, 2019
PROFESOR GUÍA: James McPhee Torres

PRONÓSTICO DE VOLÚMENES DE DESHIELO EN CUENCAS DE LA REGIÓN DEL MAULE, CHILE

La región del Maule es una de las regiones con mayor participación en la producción agrícola del país. Sin embargo, y pese a la actual sequía a nivel nacional, los puntos en que se desarrollan pronósticos de deshielo son insuficientes para cubrir la región. Este trabajo busca implementar y desarrollar una metodología de pronósticos estacionales (septiembre-marzo) en tres subcuencas de la región: Longaví en el Castillo, Achibueno en la Recova y Maule en Armerillo.

La técnica empleada fue la predicción por conjuntos o ESP, que utiliza series climáticas históricas para forzar un modelo hidrológico, VIC (Variable Infiltration Capacity) en este caso. Tras la calibración, se observaron algunas deficiencias en la modelación. En Achibueno y Longaví, ambas cuencas pluvio-nivales, el modelo tiende a sobreestimar el volumen los primeros meses de deshielo (30% en promedio para octubre y noviembre en Longaví; 20% en Achibueno) y a subestimarlos los siguientes (50% en promedio para febrero en Longaví; 30% en Achibueno), situación que estaría relacionada con un derretimiento anticipado de la nieve. En Maule este sesgo es mucho menor.

El ESP tradicional (forzantes equiprobables) entregó errores prácticamente iguales a utilizar la serie histórica de volúmenes como pronóstico en las cuencas pluvio-nivales (21% aproximadamente la mediana del error en ambas cuencas, pronosticando en septiembre). Es decir, la componente de la condición inicial no aportó la predictibilidad que se esperaba, ya sea porque esta variable conlleva un error elevado o porque otros errores del modelo compensaron el beneficio que se podría haber obtenido de esta condición. En Maule en Armerillo el ESP entregó errores inferiores (12% la mediana del error). Esto se explica por el régimen de la cuenca (nivo-pluvial) y quizá, porque en este caso, la metodología fue aplicada a un periodo menor.

La aplicación de un procesamiento basado en índices climáticos (ONI y MEI) resultó en una disminución significativa de las métricas en las cuencas pluvio-nivales, sobre todo las probabilísticas (aumento de 0,1 en CRPSS de Longaví, por ejemplo). Se esperaba que un conjunto equiprobable no fuese adecuado para estas cuencas debido a la variabilidad y magnitud de la precipitación durante el deshielo. Por otra parte, se obtuvo que es clave la observación de septiembre en la reducción de los errores.

A pesar de los esfuerzos por reducir los errores del pronóstico, los resultados no son aceptables en la realidad (errores superiores al 20%). Sin embargo, estos resultados permitirían agregar mejoras en metodologías futuras. Por ejemplo, la incorporación de los predictores climáticos en técnicas más simples (como modelos estadísticos).

AGRADECIMIENTOS

Primero que todo, quiero agradecer a mi familia por ser el pilar fundamental de mi vida. Gracias a mi papá y mamá por el apoyo incondicional, la dedicación, el esfuerzo y todo el amor que me han entregado. Gracias a mi hermanita linda, por ser la más apañadora del mundo, mi mejor amiga y mi confidente. Gracias al Terry igual, por ser el líder de la manada.

Quiero agradecer a dos grandes amigos que hice en la U. A mi mochis Bonnie por ser tan buena amiga y compartir tantos lindos momentos juntas. Al Pablo, por ser tan bacán conmigo y mostrarme el mundo del pedaleo.

Al grupo de amigas que conocí en handball y que espero se mantenga hasta viejas, porque son el mejor grupo de amigas que podría haber pedido. Mucho amor para la Javi, la Vale, la Cata, la Marti y la baby alpaca (Isi).

Al Sergito por ser tan lindo y apañador, por las conversaciones profundas y por todos los planes que hacemos y no cumplimos (hay que cambiar eso).

A los amigos de hidráulica. Al Mati, por todo el tiempo que compartimos en la u, las conversaciones y porque gracias a él conocí un grupo bacán de amigos. Al Álvaro, (ex gato) por ser el mejor compañero de oficina, proveedor de frutos secos y enseñarme que el fútbol no es tan malo. Al Tomás, por acompañarme a la casa cuando se hacía tarde y apañar a prácticamente todo. A la Cami, por todas las horas que compartimos tomando té y hablando de la vida. A la Fabi, por ayudarnos en las tareas y compartir pichangas. Al Alonso y el Pipe, por ser mis primeros amiguitos de hidráulica. Al Edu, por su forma especial de amistad. Al tercero y a la gente de civil en general, por las conversaciones de pasillo, los favores o simplemente, las sonrisas.

Al team Balance, por la buena disposición a ayudar a todos los que usamos VIC.

A la Jackie, por su amabilidad.

A los amigos de plan común y geología que ya no veo, pero que recuerdo con mucho cariño.

A mis amigos del colegio: José, Pato y la Dani.

A los ciclo-ratas, por los kilómetros recorridos y por los que vendrán.

Por último, agradecer a mis profes de la memoria, al profe James, Miguel y Pablo. Gracias por la disponibilidad para ayudarme y aconsejarme siempre, orientándome mucho más allá de los alcances de este trabajo.

Powered@NLHPC: Esta investigación fue parcialmente apoyada por la infraestructura de supercómputo del NLHPC (ECM-02).

TABLA DE CONTENIDO

1	INTRODUCCIÓN	1
1.1	Motivación	2
1.2	Objetivos	2
1.3	Estructura del informe	3
2	REVISIÓN BIBLIOGRÁFICA.....	3
2.1	Modelación hidrológica.....	3
2.1.1	VIC (variability infiltration capacity)	4
2.1.2	Calibración y validación	6
2.2	Incertidumbre en modelación hidrológica.....	6
2.2.1	Ensemble Streamflow Prediction	8
2.3	Evaluación.....	11
2.3.1	Métricas clásicas de evaluación	11
2.3.2	Evaluación probabilística	11
2.3.3	Fuentes de habilidad	12
2.4	Post procesamiento.....	12
2.4.1	Incorporación de información climática.....	13
3	ZONA DE ESTUDIO	14
3.1	Descripción.....	14
3.2	Caracterización de años.....	17
4	METODOLOGÍA.....	19
4.1	Calibración y evaluación del modelo	19
4.2	Generación de los conjuntos y evaluación del pronóstico	20
4.3	Post Procesamiento	23
4.3.1	Esquema de pesos	23
4.3.2	Índices climáticos.....	26
5	RESULTADOS Y DISCUSIÓN.....	27
5.1	Calibración y evaluación del modelo	27
5.1.1	Longaví en el Castillo (Figura 5.1)	29
5.1.2	Achibueno en la Recova (Figura 5.7)	33
5.1.3	Maule en Armerillo (Figura 5.10)	36
5.2	Generación de los conjuntos y evaluación del pronóstico	37
5.3	Post procesamiento.....	48

5.4	Resumen Longaví y Achibueno.....	53
6	CONCLUSIONES.....	57
6.1	Maule en Armerillo	57
6.2	Longaví y Achibueno.....	57
	BIBLIOGRAFÍA	59
	ANEXO A	63
	ANEXO B	64
	ANEXO C	65
	ANEXO D	66
	ANEXO E	72
	ANEXO F.....	74
	ANEXO G.....	78

ÍNDICE DE FIGURAS

Figura 2.1 Estructura VIC. Fuente: Universidad de Washington.	4
Figura 2.2: Estructura de un modelo de acuerdo con la teoría de sistemas. Fuente: Liu y Gupta, 2007.....	7
Figura 2.3 Izquierda: ESP ilustrado por JC Schaake en 1978, de "Técnicas de predicción de caudal extendido: descripción y aplicaciones durante 1977". Derecha: Esquema ESP, por Wood y Lettenmaier, 2008.	8
Figura 3.1 Ubicación cuencas en estudio.....	14
Figura 3.2 Curvas de variación estacional, cuenca Longaví en el Castillo.	15
Figura 3.3 Curvas de variación estacional, cuenca Achibueno en la Recova.	16
Figura 3.4 Curvas de variación estacional, cuenca Maule en la Recova.....	16
Figura 4.1 Esquema generación del pronóstico.	21
Figura 4.2 Ejemplo de re-muestro con bootstrapping.....	23
Figura 4.3 Esquema de pesos.....	25
Figura 4.4 Obtención del nuevo conjunto.	25
Figura 5.1 Resultados calibración Longaví en el Castillo.	28
Figura 5.2 Acercamiento a la serie de SWE diario en Longaví en el Castillo.	29
Figura 5.3 Razón volumen observado-volumen simulado durante meses de deshielo. Cuenca: Longaví en el Castillo. Periodo: 1979-2014 (36 años).	30
Figura 5.4 Relación error volumen mensual y temperatura media mensual en la cuenca. Cuenca: Longaví en el Castillo. Periodo 1979-2014 (36 años).	30
Figura 5.5 Relación error volumen mensual y precipitación mensual.....	31
Figura 5.6 SSI versus error en el volumen de deshielo. Cuenca: Longaví en el Castillo. Periodo: 1979-2014 (36 años).....	31
Figura 5.7 Resultados calibración Achibueno en la Recova.....	32
Figura 5.8 Razón volumen observado-volumen simulado durante meses de deshielo. Cuenca: Achibueno en la Recova. Periodo: 1979-2014.....	33
Figura 5.9 SSI versus error en el volumen de deshielo. Cuenca: Achibueno en la Recova. Periodo: 1979-2014 (36 años).....	34
Figura 5.10 Resultados calibración Maule en Armerillo.....	35
Figura 5.11 Curva de variación estacional extendida para la validación, en Maule en Armerillo.	36
Figura 5.12 Razón volumen observado-volumen simulado durante meses de deshielo. Cuenca: Maule en Armerillo. Periodo: 1979-2014.....	36
Figura 5.13 Volúmenes de deshielo, para $t_i = 1$ de septiembre.....	37
Figura 5.14 Volúmenes de deshielo, para distintos tiempos de inicialización. Cuenca: Longaví en el Castillo.	39
Figura 5.14 Precipitación media mensual agrupada entre septiembre-octubre (S-O), noviembre-marzo (N-M) y septiembre-marzo (S-M).....	40
Figura 5.15 Volúmenes de deshielo, para distintos tiempos de inicialización. Cuenca: Achibueno en la Recova.....	41
Figura 5.16 Volúmenes de deshielo, para distintos tiempos de inicialización. Cuenca: Maule en Armerillo.	42

Figura 5.17 Métricas evaluación pronóstico en Longaví en el Castillo. Periodo: 1979-2014.	44
Figura 5.18 Métricas evaluación pronóstico en Achibueno en la Recova.	45
Figura 5.19 Errores pronóstico Maule en Armerillo.	47
Figura 5.20 Resumen error porcentual pronóstico en Maule en Armerillo.....	48
Figura 5.21 Boxplot de conjuntos antes (sin color) y después (celeste) de la asignación de pesos. Tiempo de inicialización = 1 de septiembre.	49
Figura 5.22 Métricas evaluación pronóstico en Longaví en el Castillo antes y después del post-procesamiento.	50
Figura 5.23 Métricas evaluación pronóstico en Achibueno en la Recova antes y después del post-procesamiento.	52
Figura 5.24 Resumen error porcentual por año, Longaví en el Castillo.....	54
Figura 5.25 Resumen error porcentual por año, Achibueno en la Recova.	54
Figura 5.26 Resumen error probabilístico por año, normalizado por el volumen observado, Longaví en el Castillo.	55
Figura 5.27 Resumen error probabilístico por año, normalizado por el volumen observado, Achibueno en la Recova.....	56

ÍNDICE DE TABLAS

Tabla 2.1 Actualizaciones modelo VIC.....	5
Tabla 2.2 Trabajos de investigación que incorporan predicción por conjuntos en su metodología, ejemplos.	10
Tabla 3.1 Características físicas e hidroclimáticas de las cuencas.	15
Tabla 3.2 Registro de observaciones y/o productos utilizados.....	17
Tabla 3.3 Caracterización años según SPI y SSI.....	18
Tabla 4.1 Fechas calibración y validación.	19
Tabla 4.2 Métricas y/o índices utilizados en la evaluación de los pronósticos	22
Tabla 5.1 Métricas y/o índices de rendimiento de la calibración.	27
Tabla 5.2 Errores Volúmenes de deshielo simulados.....	31
Tabla 5.3 Errores Volúmenes de deshielo simulados.....	34
Tabla 5.4 Métricas serie de pronósticos en Maule en Armerillo.	47
Tabla 5.5 Correlación entre MEI y SPI durante meses de deshielo. *En el caso de $T_i=1$ de octubre la correlación se realiza con el SPI durante los meses octubre-marzo, para $T_i=1$ de noviembre, se usa el SPI entre noviembre-marzo.....	48
Tabla 5.6 Correlación entre ONI y SPI durante meses de deshielo. *En el caso de $T_i=1$ de octubre la correlación se realiza con el SPI durante los meses octubre-marzo, para $T_i=1$ de noviembre, se usa el SPI entre noviembre-marzo.....	48
Tabla 5.7: índices escogidos para cada tiempo de inicialización y cuenca.	49

1 INTRODUCCIÓN

En noviembre del año 2015, el Centro del Clima y la Resiliencia (CR2) hacía entrega a la comunidad nacional de su primer **Informe a la Nación**, motivado por la persistencia temporal y espacial de la mega-sequía que afectaba a gran parte del país. Históricamente, las grandes sequías han impulsado el desarrollo de herramientas que permitan mejorar la gestión del agua.

Un ejemplo de esto ocurrió en California EEUU a mediados de la década de 1970, donde una severa sequía promovió el desarrollo de nuevas técnicas de pronósticos hidrológicos. De este esfuerzo surgió la predicción de caudales por conjuntos o “ESP” por sus siglas en inglés (“Ensemble Streamflow Prediction”), metodología que es utilizada desde entonces hasta la actualidad por el NWS (“National Weather Service”, EEUU). En Reino Unido ocurrió algo similar, donde la sequía de 2010-2012 motivó la creación del HOUK (“Hydrological Outlook UK”), primer servicio de pronósticos hidrológicos operacionales. Cabe mencionar que esta agencia también utiliza el ESP como una de sus metodologías de pronóstico (Harrigan, 2018).

El enfoque ESP incorpora la incertidumbre del clima futuro a través de secuencias climáticas históricas que son utilizadas como inputs en un modelo hidrológico, que puede ser conceptual o de base física. El resultado es un conjunto de posibles escenarios (o “miembros”), que a priori son equiprobables, pero que pueden ser tratados con algún esquema de post-procesamiento (por ejemplo, Werner et al., 2004; Wood y Schaake, 2008; Mendoza et al., 2017). Desde su formulación hasta la actualidad, la técnica ESP ha sido ampliamente utilizada en distintas agencias del mundo (Wood et al, 2016) siendo uno de los dos principales enfoques para realizar pronósticos hidrológicos, junto a los métodos estadísticos (Moradkhani y Meier, 2010).

De acuerdo con Harrigan et al. (2018, pág. 2023) “los pronósticos hidrológicos a escalas subestacionales y estacionales pueden ser extremadamente beneficiosos para la toma de decisiones en la gestión de los recursos hídricos, las operaciones hidroeléctricas y la agricultura, especialmente durante condiciones de sequía”. No obstante, hay dos aspectos muy importantes que deben ser considerados: (1) el pronóstico debe ser creíble, es decir, capaz de reproducir estados anómalos del sistema (Greuel, 2018) y (2) el pronóstico debe ser entregado de la forma más completa posible. Esto último, con el fin de abordar la incertidumbre futura de la forma correcta y evitar interpretaciones erróneas. A pesar de que tanto meteorólogos e hidrólogos han manifestado la necesidad de utilizar pronósticos probabilísticos en lugar de deterministas, un error común entre los tomadores de decisiones es suponer que los pronósticos probabilísticos aumentan nuestra incertidumbre (Todini, 2018).

1.1 Motivación

La región del Maule es una de las regiones con mayor participación en la producción agrícola del país. Corresponde a la región en la que las actividades silvo-agropecuarias representan la mayor contribución del producto interno bruto regional, llegando a un 17,6% (ODEPA, 2015). Considerando que estas actividades dependen de la disponibilidad de agua y que actualmente existe un déficit de recursos hídricos en la zona, asociado al periodo de sequía que se está viviendo en la región desde hace ya varios años, resulta fundamental contar con la mayor cantidad de herramientas que permitan mejorar la gestión del agua.

Existen dos entidades que realizan pronósticos públicos de caudales de deshielo en la región; la Dirección General de Aguas (DGA) y el Centro Despacho Económico de Carga, del Sistema Interconectado Central (CDEC-SIC). Sin embargo, los puntos en que se desarrollan pronósticos son insuficientes para cubrir espacialmente toda la región. En particular, hay una deficiencia de puntos en el sector sur de la cuenca, donde existe un alto desarrollo de actividades agrícolas.

En este contexto, se aprobó el proyecto “Metodología de pronóstico de caudales de deshielo basada en la observación y modelamiento de la cubierta nival para cuencas hidrográficas de la Región del Maule” como parte de la propuesta de asignación de recursos de la Provisión Fondo de Innovación y Competitividad del F.N.D.R. 2017 (Fondo Nacional de Desarrollo Regional). Esta memoria se realiza como parte del proyecto mencionado, enfocándose en el desarrollo de pronósticos estacionales de deshielo en tres subcuencas de la región: Achibueno en la Recova, Longaví en el Castillo y Maule en Armerillo.

1.2 Objetivos

El objetivo general de este trabajo es desarrollar pronósticos de caudales de deshielo a una escala de tiempo estacional en cuencas de la Región del Maule. Los objetivos específicos son:

OE1: Estudiar el desempeño del modelo hidrológico con el fin de incorporar esta información en la evaluación de los pronósticos.

OE2: Estudiar el error obtenido de aplicar la metodología ESP para desarrollar pronósticos estacionales, y luego, verificar retrospectivamente la calidad del pronóstico.

OE3: Estudiar el desempeño del pronóstico al incorporar un esquema de post procesamiento.

1.3 Estructura del informe

A continuación, este documento se estructura de la siguiente forma:

Capítulo 2: Se presenta una revisión bibliográfica que aborda desde temas generales relacionados con la modelación hidrológica, hasta temas más específicos afines con la técnica ESP.

Capítulo 3: Se describe brevemente la zona de estudio.

Capítulo 4: Se presenta la metodología utilizada separada según tres puntos principales: (1) la calibración y evaluación del modelo, (2) la generación del pronóstico y (3) esquema de post procesamiento.

Capítulo 5: Se presentan los principales resultados y discusiones separados según los mismos puntos en que se dividió la metodología.

Capítulo 6: Se presentan las principales conclusiones de este trabajo y recomendaciones para trabajos futuros.

2 REVISIÓN BIBLIOGRÁFICA

Los centros que realizan pronósticos estacionales han respaldado el manejo de recursos hídricos durante gran parte del siglo pasado y lo que va de este siglo (Mendoza, et al. 2017). Con el paso del tiempo y el avance tecnológico y computacional, las diferentes técnicas han sido mejoradas o directamente, han dado paso a técnicas nuevas. La incorporación de modelos hidrológicos en las técnicas de pronósticos es un ejemplo de esto, más aún, lo es el uso de estos modelos, cuyo grado de complejidad puede ser muy variable, en metodologías de elevado costo computacional.

2.1 Modelación hidrológica

Los modelos son simplificaciones de un sistema real y, por lo tanto, son aproximaciones imperfectas (Liu y Gupta, 2007). En los modelos hidrológicos, el sistema que se busca representar es el ciclo hidrológico o algún proceso de este, en particular.

Los primeros pasos en modelación hidrológica son adjudicados a Mulvaney y su Método Racional (1850), motivado por la construcción de obras hidráulicas, y posteriormente a Sherman (1932), con la introducción del hidrograma unitario (Todini, 2007). A mediados de la década de 1960, con la aparición de la teoría de sistemas y los computadores, surgieron los “modelos conceptuales”. En estos modelos, los componentes del ciclo hidrológico se encontraban representados por elementos conceptuales, como tanques.

Paralelamente, varios autores intentaron mejorar la representación física de los procesos hidrológicos, a través de la integración numérica de los subsistemas de ecuaciones diferenciales parciales que describen el flujo en la zona saturada y no saturada (Todini, 2011). Freeze y Harlan realizaron el primer intento de un modelo físico distribuido en 1969 y desde entonces, muchos modelos distribuidos han sido desarrollados (Refsgaard, 1997).

A continuación, se presenta una descripción del modelo hidrológico utilizado en este trabajo de título.

2.1.1 VIC (variability infiltration capacity)

El modelo de capacidad de infiltración variable o VIC (Liang et al., 1994) es un modelo semi distribuido, de macroescala, que resuelve los balances completos de agua y energía. De acuerdo con Gao et al., (2009, pág. 123) “las características claves de VIC son la representación de la heterogeneidad de la vegetación, las múltiples capas de suelo con infiltración variable y el flujo base no lineal”. En la Figura 2.1 se presenta un esquema de la estructura del modelo.

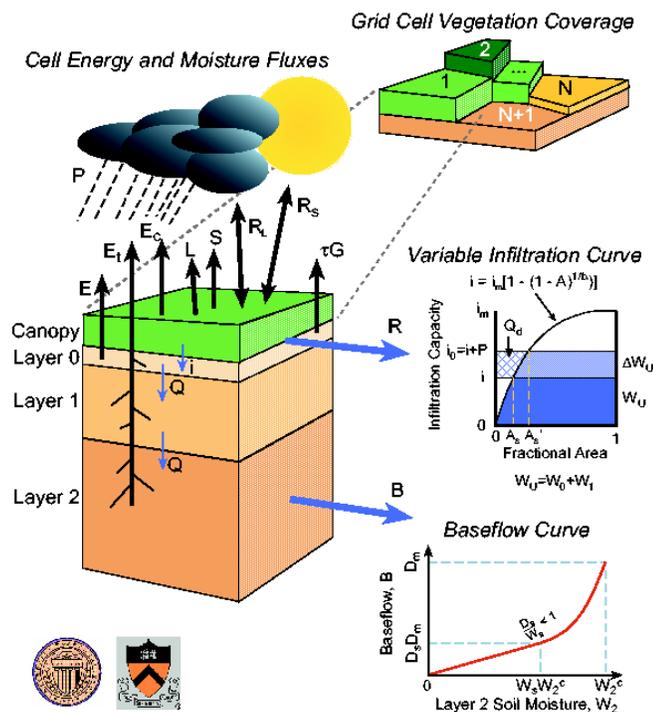


Figura 2.1 Estructura VIC. Fuente: Universidad de Washington.

Este modelo fue desarrollado originalmente por Xu Liang, en la Universidad de Washington, motivado por la necesidad de representar la superficie terrestre en los modelos de circulación general. Corresponde a una generalización del modelo VIC

descrito por Wood et al, en 1992 (Liang et al., 1994) formulado como un modelo de una sola capa.

Posteriormente, Liang et al., (1994) generalizaron el modelo VIC a uno de dos capas (VIC-2L) para poder incluir múltiples capas y variar la vegetación y evaporación dentro de una celda. Procesos como infiltración, drenaje de la capa superior a la inferior, escorrentía superficial y subsuperficial se calculan por cada celda. La escorrentía superficial y el flujo base es representada mediante esquemas conceptuales mientras que procesos como los flujos de calor sensible y latente son determinados a partir de formulaciones físicas (Gao et al., 2009).

Desde entonces, se han realizado varias actualizaciones al modelo. En la Tabla 2.1 se resumen algunas de estas, la mayoría extraídas de la revisión de Gao et al., (2009).

Tabla 2.1 Actualizaciones modelo VIC.

Autor(es)	Año	Actualización
Liang et al.	1996	VIC pasó a tener tres capas (aunque es posible usar más) al incluir una capa de 10 cm sobre las otras dos. Se incluyó un mecanismo de difusión de humedad entre las capas, debido a que la versión anterior, al no permitir esto, subestimaba la evaporación desde la capa más superficial.
Lohmann., et al.	1996 1998	Se agregó un modelo de enrutamiento por separado para simular el caudal, debido a que VIC no considera la geometría de las variaciones dentro de una celda.
Andreadis et al.	1994	Se incluyó un modelo de nieve de balance energético de dos capas.
Wigmosta et al.	1998	
Storck et al.	2009	
Cherkauer et al.	1999 2003	Se agregó un algoritmo de suelos congelados.
Cherkauer y Lettenmaier	2003	
Nijssen et al.	2001	Se introdujeron bandas de elevación que representan la topografía.
Cherkauer et al.	2003	Se agregó modelo de lagos y humedales
Bowling y Lettenmaier	2010	

Desde su creación, VIC ha desempeñado diferentes roles; ha sido aplicado a escalas de cuenca y globales, en evaluación y asimilación de datos, en metodologías de pronósticos, acoplado a modelos climáticos, entre otros (Hamman, et al. 2018). Particularmente, es utilizado en Chile en la actualización del balance hídrico nacional (DGA, 2017).

2.1.2 Calibración y validación

A menudo los modelos deben ser calibrados, ya sea por la incertidumbre asociada a los parámetros, que pueden ser o no medibles, o porque se requiere una mejora del desempeño del modelo.

La similitud entre la respuesta simulada y la observada se cuantifica usando una medida matemática llamada función objetivo o una combinación de funciones, donde los parámetros se ajustan mediante un procedimiento de búsqueda iterativo (algoritmo de optimización). Una función objetivo es una medida del error de la respuesta simulada (con respecto a la observación) y típicamente se expresa en función del hidrograma de flujo (Wagener y Gupta, 2005). En este caso, la función objetivo escogida corresponde al índice de eficiencia de Kling-Gupta o KGE (Gupta et al, 2009), cuya formulación es presentada en la sección de metodología.

El algoritmo de optimización utilizado fue el *Shuffled Complex Evolution* (SCE-UA; Duan et al, 1993, pág. 501). Este algoritmo se basa en cuatro conceptos principales: “(1) combinación de enfoques deterministas y probabilísticos, (2) agrupamiento o *clustering*, (3) evolución de un conjunto de puntos hacia el mejoramiento global y (4) evolución competitiva”.

La validación por otra parte, corresponde al proceso mediante el cual se verifica que el modelo es capaz de realizar predicciones suficientemente precisas en un periodo distinto al de calibración.

2.2 Incertidumbre en modelación hidrológica

Tanto en meteorología como en hidrología, la necesidad de representar los pronósticos en términos probabilísticos en vez de deterministas se ha vuelto más latente en las dos últimas décadas (Todini, 2018). La generación de una visión probabilística se desarrolló inicialmente para predicciones meteorológicas, a principios de la década de 1950. Eric Eady (1915-1966) fue el primer meteorólogo que expresó preocupación por el determinismo estricto, es decir, un futuro que no tiene en cuenta la incertidumbre asociada al estado inicial (Lewis, 2005). Años después, esta inquietud también se extendió a la hidrología.

Wagener y Gupta (2005) reconocen ampliamente que la consideración adecuada de la incertidumbre en los pronósticos hidrológicos es esencial para los fines de investigación y modelado operacional. Liu y Gupta (2007) señalan que, para abordar correctamente la incertidumbre en el modelado hidrológico, hay tres aspectos distintos pero relacionados que se deben considerar: comprensión, cuantificación y reducción de incertidumbre.

La salida de un modelo hidrológico es siempre incierta. Esta incertidumbre proviene de distintas fuentes, como: los datos de observación utilizados para impulsar y evaluar

los modelos, de las condiciones de contorno del sistema y de la selección de los parámetros y estructura del modelo (Beven y Freer, 2001).

Un esquema de la estructura de un modelo según la teoría de sistemas es presentado en la Figura 2.2. Los componentes que se incluyen son: límites del sistema (B), entradas (u), condiciones iniciales (x_0), parámetros (θ), estructura del modelo (M), estados (x) y salidas (y). Las matrices M^x y M^y representan la transición de las condiciones iniciales a estados y de estados a salidas, respectivamente.

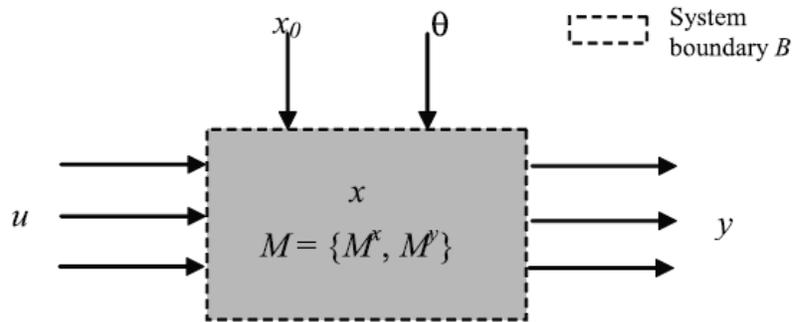


Figura 2.2: Estructura de un modelo de acuerdo con la teoría de sistemas. Fuente: Liu y Gupta, 2007.

En esta estructura, Liu y Gupta (2007) definen las entradas u y las salidas y como flujos de masa y/o energía que entran y salen del sistema a través del límite B del sistema; x como cantidades de masa y/o energía que varían con el tiempo almacenadas dentro del límite B del sistema, y parámetros θ como propiedades características del sistema que se supone son "invariantes en el tiempo".

Los errores estructurales, de parámetros y de datos conducen colectivamente a incertidumbres en las predicciones hidrológicas de las salidas y estados del modelo. Generalmente, los errores estructurales son los que menos se comprenden y los más difíciles de afrontar (Liu y Gupta, 2007).

Una forma clásica y directa presentada en la literatura de cómo cuantificar la incertidumbre es representar los pronósticos en términos de una distribución de probabilidad. Esta distribución puede resultar del ajuste de una función (por ejemplo: normal, Weibull, etc.) o simplemente tratarse como una distribución empírica (Werner et al, 2004). Krzysztofowicz (1999, pág.2) señala que "la toma racional de decisiones (para advertencia de inundaciones, navegación o sistemas de almacenamiento) requiere que la incertidumbre total sobre un registro hidrológico (caudal, volumen de escorrentía, etc.) se cuantifique en términos de una distribución de probabilidad, condicionada a toda la información disponible y conocimiento".

Las técnicas basadas en conjuntos (en contraste con un pronóstico determinista) se han vuelto muy populares en las aplicaciones de pronóstico debido a que proporcionan información probabilística. Un conjunto de predicciones puede ser generado a través de la perturbación de distintos elementos del sistema; entradas, variables de estado, parámetros, estructura, etc.

Por ejemplo, Lane et al (2019) utilizan un muestreo de Monte-Carlo para generar 10.000 conjuntos de parámetros (dentro de un rango previamente establecido) del modelo FUSE (Clark et al, 2008) y así obtener distintas salidas, para una extensa muestra de cuencas en Gran Bretaña. Mendoza et al (2017) por otra parte, comparan distintos métodos enfocados en pronósticos estacionales en cuencas de EEUU, entre los que se encuentra el método de predicción por conjuntos (ESP por sus siglas en inglés). Esta técnica incorpora incertidumbre a través de la información meteorológica histórica.

2.2.1 Ensemble Streamflow Prediction

La predicción por conjuntos o en inglés “Ensemble Streamflow Prediction” (en adelante ESP; Day 1985) es una técnica de pronóstico que combina un modelo hidrológico con la perspectiva climática representada por series meteorológicas históricas. El ESP aplica el supuesto de que estos datos representan la distribución de las posibles condiciones durante el período de pronóstico (Šípek y Daňhelka, 2015). Es decir, a partir de una condición inicial (supuesta perfecta), el modelo es inicializado bajo un conjunto de datos históricos de forzamiento como precipitación y temperatura, por ejemplo (Figura 2.3).

En el ESP tradicional, dado un número N de años con observaciones, el método produce N posibles valores de escorrentía o “miembros” para el año en que se pronostica (año actual). Es decir, el método supone que las secuencias climáticas históricas tienen igual probabilidad de ocurrencia en el año en que se pronostica (Gobena y Gan, 2010).

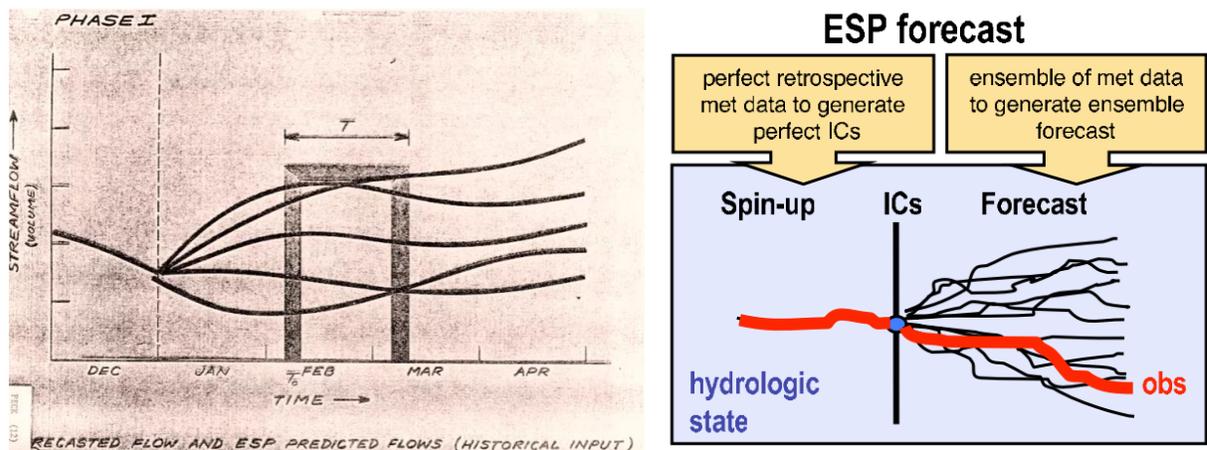


Figura 2.3 Izquierda: ESP ilustrado por JC Schaake en 1978, de "Técnicas de predicción de caudal extendido: descripción y aplicaciones durante 1977". Derecha: Esquema ESP, por Wood y Lettenmaier, 2008.

En la Figura 2.3 (izquierda) se presenta un esquema de la metodología ESP. En la imagen se aprecia la inicialización del pronóstico representada por una línea vertical y el periodo T , durante el cual interesa pronosticar. A la derecha se presenta un esquema similar al anterior. En esta imagen se muestra el periodo de spin-up previo a la

inicialización del pronóstico, durante el cual el modelo es forzado con observaciones con el fin de obtener condiciones iniciales perfectas.

Resumiendo, los dos principales supuestos de la técnica ESP son:

1. La condición inicial (a partir de la cual se inicializa el pronóstico) es perfecta.
2. La meteorología histórica permite representar la incertidumbre (idealizada) del pronóstico.

Las primeras referencias para la técnica ESP, que en un inicio fue denominada "Extended Streamflow Prediction", son una presentación de la Western Snow Conference (Twedt et al., 1977) y un artículo de revista de Day et al. (1985). A pesar de que tanto la formulación como la fecha de la primera aplicación de esta técnica no son claras, es probable que la primera operadora de ESP haya sido Helen Joyce Peters (Wood, 2016).

Los primeros pronósticos hidrológicos con ESP se estaban desarrollando simultáneamente a mediados de la década de 1970 por un centro de operaciones federal-estatal, donde participaba personal del Departamento de Recursos Hídricos del Estado de California (CADWR) y por el Centro de Pronóstico del Río California-Nevada (CNRFC) del Servicio Nacional de Meteorología (NWS), ambos en EEUU. Peters dirigió el lado estatal del programa y de acuerdo con informes históricos, sus pronósticos son anteriores a los del centro del NWS por varias semanas o meses (Wood, 2016).

La motivación original que tuvo el NWS para utilizar el enfoque ESP fue que era flexible, fácil de usar y que podía ejecutarse de manera eficiente utilizando modelos hidrológicos conceptuales simples (Day, 1985).

El ESP tradicional, aunque simple, todavía se utiliza ampliamente en el pronóstico hidrológico estacional operacional. Por ejemplo, aún es usado por el Servicio Nacional de Meteorología en EEUU (US NWS) y el *Hydrological Outlook UK* (HOUK). Este último fue establecido como el primer servicio operacional de pronóstico hidrológico estacional en el Reino Unido, impulsado por la sequía de 2010-2012 en Inglaterra y Gales. En esta agencia, el ESP se utiliza como uno de los tres métodos de pronóstico hidrológico y además se incluye en el "Informe de la situación del agua para Inglaterra" de la Agencia de Medio Ambiente (Harrigan, 2018).

En países como Rusia, Checoslovaquia, Alemania, Suecia, entre otros, el ESP también es considerado un componente clave de la predicción operativa a largo plazo (Wood, 2016). A la fecha existen numerosos estudios (investigación, hidrología operacional, etc.) que utilizan la predicción por conjuntos, ya sea ESP tradicional, o algún enfoque similar. Algunos ejemplos se presentan en la Tabla 2.2

Tabla 2.2 Trabajos de investigación que incorporan predicción por conjuntos en su metodología, ejemplos.

Estudio	Resumen
<p>Franz et al. (2003) Verification of National Weather Service Ensemble Streamflow Predictions for Water Supply Forecasting in the Colorado River Basin.</p>	<p>Se generaron pronósticos probabilísticos históricos simulados para 14 puntos en la cuenca del río Colorado EEUU (dominada por la nieve), y se evaluaron las propiedades estadísticas de los conjuntos. El autor encontró que los pronósticos de ESP fueron, en promedio, hábiles (en comparación con los pronósticos de climatología de referencia) con un tiempo de adelanto de hasta 7 meses.</p>
<p>Wood y Lettenmaier (2008) An ensemble approach for attribution of hydrologic prediction uncertainty.</p>	<p>Los autores evalúan la importancia relativa de la condición inicial y las incertidumbres de forzamiento. Sus resultados sugieren que el énfasis puesto por los pronosticadores en obtener mejor información sobre el clima futuro en comparación con las condiciones iniciales debería variar durante el año y según el plazo de entrega (del pronóstico).</p>
<p>Mendoza et al. (2017) An intercomparison of approaches for improving operational seasonal streamflow forecasts.</p>	<p>El autor estudia los beneficios marginales de distintos métodos que incorporan información climática y/o información de la condición hidrológica inicial, para realizar pronósticos estacionales en 5 cuencas del noroeste de EEUU. Mendoza et al. incluyeron métodos que utilizan información climática desde índices estándar o de variables de reanálisis del clima y algunos enfoques híbridos/jerárquicos que aprovechan tanto la superficie terrestre como la previsibilidad del clima. Los resultados mejoran cuando las señales de teleconexión atmosférica son fuertes.</p>
<p>Harrigan et al. (2018) Benchmarking ensemble streamflow prediction skill in the UK.</p>	<p>El autor utiliza el modelo hidrológico conceptual GR4J para realizar una evaluación comparativa de cuándo y dónde el método ESP es hábil en una muestra diversa de 314 cuencas en el Reino Unido. El modelo fue forzado con secuencias climáticas históricas para producir un conjunto de 51 miembros. Los resultados mostraron que el ESP fue hábil en comparación con un pronóstico de climatología de referencia en la mayoría de las cuencas.</p>
<p>Greuell et al. (2018) Seasonal streamflow forecasts for Europe – Part I: Hindcast verification with pseudo-and real observations.</p>	<p>El autor utiliza el modelo de base física VIC para realizar pronósticos estacionales en múltiples cuencas de Europa. El modelo es forzado con un modelo climático de pronóstico estacional (ECMWF S4) para obtener un total de 15 miembros. Este conjunto se obtiene al combinar un set de 5 miembros del estado inicial del océano con perturbaciones SST (Sea Surface Temperature).</p>

2.3 Evaluación

Numerosos estudios han establecido la habilidad del ESP a través de experimentos de *hindcasting* (por ejemplo, ver Tabla 2.2), es decir, pronósticos realizados para años anteriores, considerando que la meteorología es conocida sólo para los años distintos al que se genera el pronóstico. Este procedimiento es un ejercicio de validación cruzada, específicamente del tipo “dejar uno fuera” (*leave one out*), donde el procedimiento de ajuste se repite n veces, cada vez con una muestra de tamaño $n - 1$ (Wilks, 2011).

Realizar *hindcasting* permite validar la metodología ESP a través de una gran cantidad de métodos de verificación, desde métricas clásicas y simples hasta técnicas más avanzadas orientadas a informar acerca de la calidad del pronóstico.

2.3.1 Métricas clásicas de evaluación

Una primera medida de evaluación corresponde a calcular el promedio o mediana del conjunto y posteriormente, usar este valor para determinar algunos índices o métricas de evaluación clásica, como por ejemplo *RMSE* (raíz del error cuadrático medio), sesgo, coeficiente de correlación, entre otros. Claramente, realizar una evaluación solamente determinista no es lo deseado pues conlleva una pérdida de información considerable. Franz et al (2003) señalan la importancia de realizar verificación probabilística y, además, indican que (en su caso) el cálculo de una métrica determinista como la mediana resultó en una pérdida de información de la incertidumbre que entrega el conjunto de pronósticos.

2.3.2 Evaluación probabilística

Al expresar un pronóstico de forma probabilística, es necesario presentar atributos indicadores de calidad distintos a los utilizados en un análisis determinista.

Existen diversos procedimientos gráficos y métricas de puntuación enfocados en distintas propiedades del pronóstico. No obstante, “hay más de un atributo deseable para los buenos pronósticos probabilísticos, y por lo tanto no hay una sola métrica de puntaje que pueda resumir adecuadamente la calidad del pronóstico” (Mason y Stephenson, 2008, pág. 278). Alfieri et al (2014) indican que, además las métricas y/o índices de verificación deben complementarse con el conocimiento local y la experiencia de los pronosticadores. Incluso señalan que los “skill scores” rara vez se muestran públicamente (al menos en hidrología operacional), para evitar una mala interpretación de los resultados.

Algunas propiedades del pronóstico utilizadas como indicadores de calidad son:

Error probabilístico: Corresponde a la diferencia entre la función de densidad de probabilidad acumulada simulada y las observaciones.

Confiabilidad (*reliability*): Se define como la consistencia entre las probabilidades predichas a priori de un evento y las frecuencias relativas observadas a posteriori de este evento (Mason y Stephenson, 2008). La confiabilidad se puede mejorar mediante la calibración.

Consistencia estadística (*statistical consistency*): Corresponde a la capacidad del sistema de generar pronósticos dentro del rango de observaciones.

Resolución (*resolution*): Se refiere a la habilidad del sistema de distinguir valores específicos estimando la variación de un resultado observado a medida que el pronóstico cambia. Es decir, los pronósticos tienen una buena resolución cuando el resultado está fuertemente condicionado al pronóstico.

Discriminación (*discrimination*): Se define como la capacidad de distinguir escenarios que conducen a la ocurrencia de un evento de aquellos que conducen a la no ocurrencia de este.

2.3.3 Fuentes de habilidad

Comprender las fuentes de habilidad de un pronóstico ha sido durante mucho tiempo un tema de interés en el estudio de los sistemas geofísicos y en ciencias atmosféricas (Harrigan et al, 2018). Esta preocupación también se ha extendido a la hidrología.

Edward Lorenz (1975, pág. 132), matemático y meteorólogo estadounidense conocido como el “padre de la teoría del caos” identifica dos fuentes principales de predictibilidad. Por una parte, las relacionadas con las condiciones iniciales (“primer tipo”) y por otro, las fuentes relacionadas con las forzantes futuras (“segundo tipo”) que “no están directamente relacionadas con el orden cronológico en el que ocurren los estados atmosféricos”.

Greuel et al (2019), estudia las fuentes de habilidad del *hindcasting* realizado en un estudio anterior (Greuel et al, 2018, ver en Tabla 2.2). Los autores estudian fuentes de habilidad en las forzantes (como temperatura y precipitación) así como en los estados. Los experimentos realizados demostraron que las condiciones iniciales de humedad del suelo constituían la fuente de habilidad dominante en la escorrentía. Además, entre los meses de abril y julio las condiciones iniciales de nieve contribuían significativamente a la habilidad.

2.4 Post procesamiento

Cuando se usa un modelo para ESP, las incertidumbres en la modelación (modelo, inputs, parámetros, etc.) se manifiestan típicamente como sesgos en la media y la propagación (*spread*) de los conjuntos de pronósticos (Wood y Schaake, 2007). Un post-procesamiento típico corresponde a la corrección por sesgo. Esta corrección puede

llevarse a cabo mediante una transformación que ajusta los miembros del conjunto con los cuales se genera una nueva distribución de probabilidad.

Por otra parte, de acuerdo con Mendoza et al (2017, pág. 3915), “trabajos recientes sugieren que las dos vías principales para avanzar en la predictibilidad estacional son las mejoras en la estimación de las condiciones hidrológicas iniciales (IHC) y la incorporación de información climática”.

2.4.1 Incorporación de información climática

El interés en mejorar los pronósticos hidrológicos incorporando predicciones del clima se ha visto impulsado por los avances en la predicción del tiempo en las últimas décadas. Sin embargo, de acuerdo con Wood y Lettenmaier (2008, pág. 2) “la influencia estacional y geográfica de las condiciones iniciales de la superficie terrestre es variable, y establece límites al valor potencial de las mejoras en la habilidad de pronóstico del tiempo en relación con los forzamientos climáticos en la predictibilidad hidrológica.

En relación con este último punto, una forma típica de reducir la incertidumbre en metodologías como ESP, corresponde a utilizar información climática (como índices climáticos) para asignar distintos pesos a los miembros del conjunto. Por lo tanto, estos miembros que a priori fueron supuestos equiprobables, podrían resultar en una distribución de probabilidad más acotada y cercana a las observaciones, que la original.

Hamlet y Lettenmaier (1999) aplicaron el enfoque ESP centrándose en años que fuesen similares en términos de la fase de ENSO (El Niño-Oscilación del Sur) y fase de PDO (Oscilación Decadal del Pacífico). Para esto, los autores crearon 6 categorías (para los años) que resultaron de la combinación de PDO (cálido y frío) y ENSO (cálido, neutro, frío). Este enfoque permitió obtener un conjunto más estrecho y cercano a las observaciones que el conjunto original.

Werner et al (2004) por otra parte, presentan un método de asignación de pesos para los miembros del conjunto en base a información climática. Los autores trabajaron con la metodología ESP en tres subcuencas del río Colorado en EEUU y examinaron 16 índices climáticos distintos, de los cuales el Niño 3-4 resultó ser el mejor candidato. Como se esperaba, los autores obtuvieron mayores beneficios en la cuenca con una correlación más fuerte.

Otro intento por integrar información climática al ESP fue presentado por Gobena y Gan (2010). En este caso, los autores desarrollan una técnica que les permitió integrar pronósticos de temperatura y precipitación (con un tiempo de adelanto de 0 a 3 meses) proveniente de dos modelos de predicción numérica del tiempo.

3 ZONA DE ESTUDIO

3.1 Descripción

La Figura 3.1 muestra la ubicación y extensión de las tres cuencas que conforman la zona de estudio. Además, se presentan los puntos en que actualmente se realizan pronósticos de deshielo.

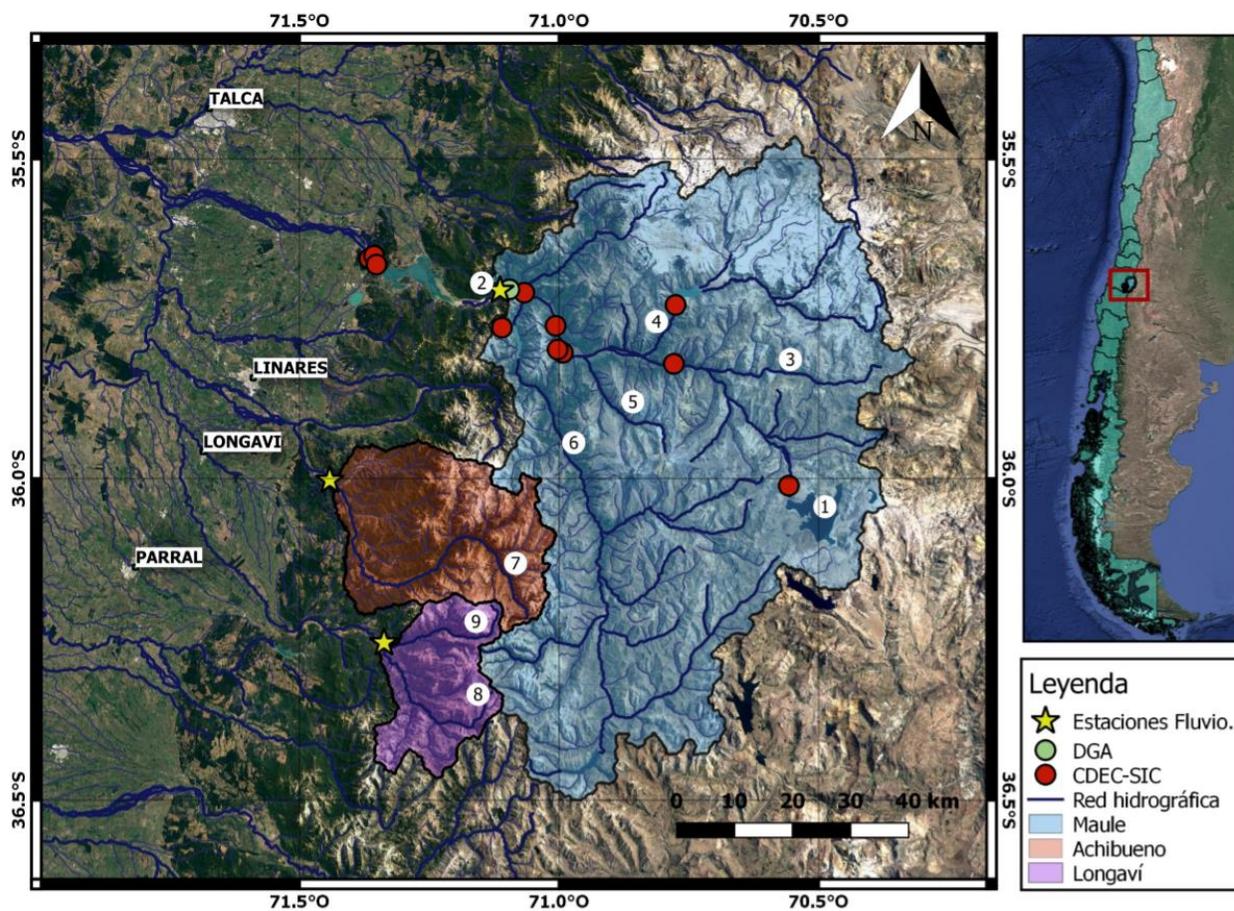


Figura 3.1 Ubicación cuencas en estudio.

El río Maule nace en el extremo norponiente de la laguna del mismo nombre (1) a 2163 m s.n.m. Hasta la estación fluviométrica Maule en Armerillo (2), este río recibe importantes aportes del río Puelche (3), río los Cipreses (4), río Colorado (5) y río Melado (6), entre otros.

Por otra parte, al occidente del río Melado se desarrolla el curso superior del río Achibueno (7), confinado por elevadas montañas de los Andes. Más al sur, el río Longaví (8) nace de un cordón andino de unos 2000 m de altura media. A 24 km de su origen recibe el aporte de su principal afluente, el río Blanco (9), que nace desde el Nevado Longaví o Lonquén (3230 m) (DGA, 1980).

En la Tabla 3.1 se presentan algunas características hidroclimáticas de las tres cuencas.

Tabla 3.1 Características físicas e hidroclimáticas de las cuencas.

Característica	Unidad	Longaví en el Castillo	Achibueno en la Recova	Maule en Armerillo
Área	km ²	457	875	5350
Elevación media de la cuenca	m s.n.m.	1564	1329	2047
Precipitación media anual	mm/año	2398	2105	2140
Caudal medio anual	m ³ /s	35,7	44,3	250
	mm/año	2474	1603	1480

Nota: Los promedios se realizaron en el periodo 1979-2014. La elevación media de las cuencas fue extraída desde la base de datos de CAMELS-CL.

La Figura 3.2 muestra las (a) curvas de variación estacional del caudal observado y (b) las curvas medias de precipitación, caudal y SWE (equivalente de nieve en agua) medio sobre la cuenca obtenido del reanálisis de Cortés (2016) para Longaví en el Castillo. La Figura 3.3 y Figura 3.4 muestran estas curvas para la cuenca Achibueno en la Recova y Maule en Armerillo, respectivamente.

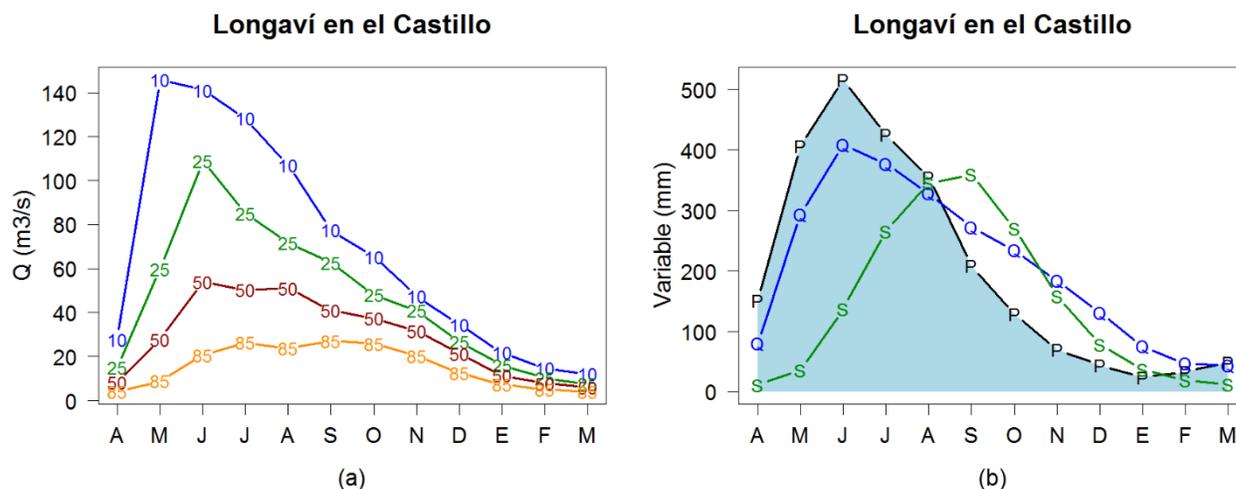


Figura 3.2 Curvas de variación estacional, cuenca Longaví en el Castillo.

P: precipitación media periodo 1979-2014. Q: caudal medio periodo 1979-2014. S: SWE medio 1984-2014.

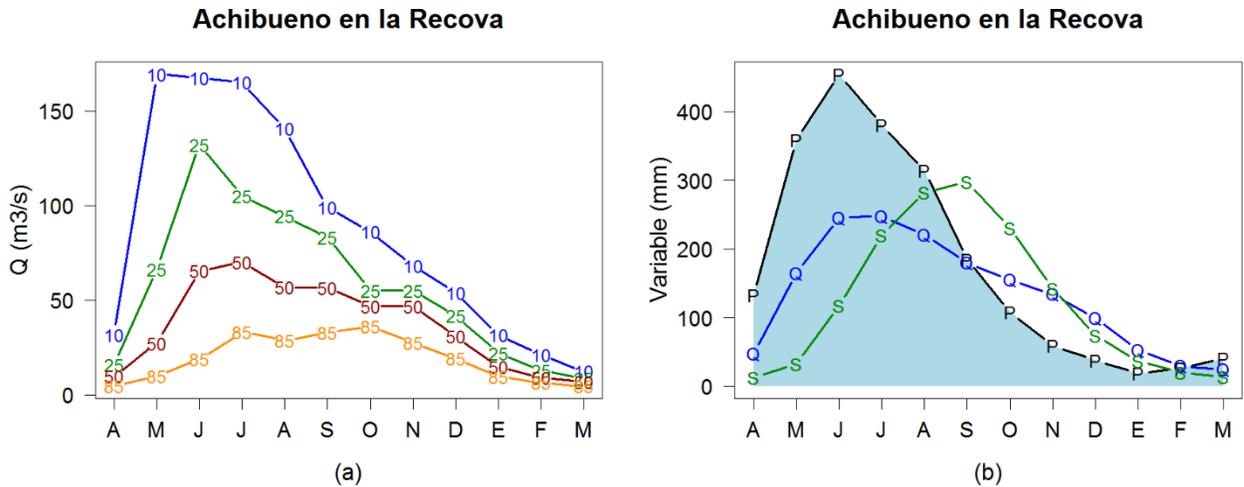


Figura 3.3 Curvas de variación estacional, cuenca Achibueno en la Recova.
P: precipitación media periodo 1979-2014. **Q:** caudal medio periodo 1979-2014. **S:** SWE medio 1984-2014.

Mientras que la cuenca del Maule presenta un régimen nivo-pluvial (Figura 3.4), con máximos en los meses de noviembre y diciembre, las cuencas de Achibueno y Longaví son más bien pluvio-nivales, y con regímenes bastante parecidos entre sí.

Tanto Longaví en el Castillo como Achibueno en la Recova son consideradas como cuencas en régimen natural (DGA, 2017), Maule en Armerillo en cambio, corresponde a una cuenca altamente intervenida. Teniendo en cuenta esto, para la calibración del modelo se trabaja con los caudales (diarios) reconstruidos facilitados por las juntas de vigilancia para esta última cuenca, disponibles entre 2009 y la actualidad. Para el resto del periodo (1979-2009) sólo se cuenta con reconstrucciones a nivel mensual.

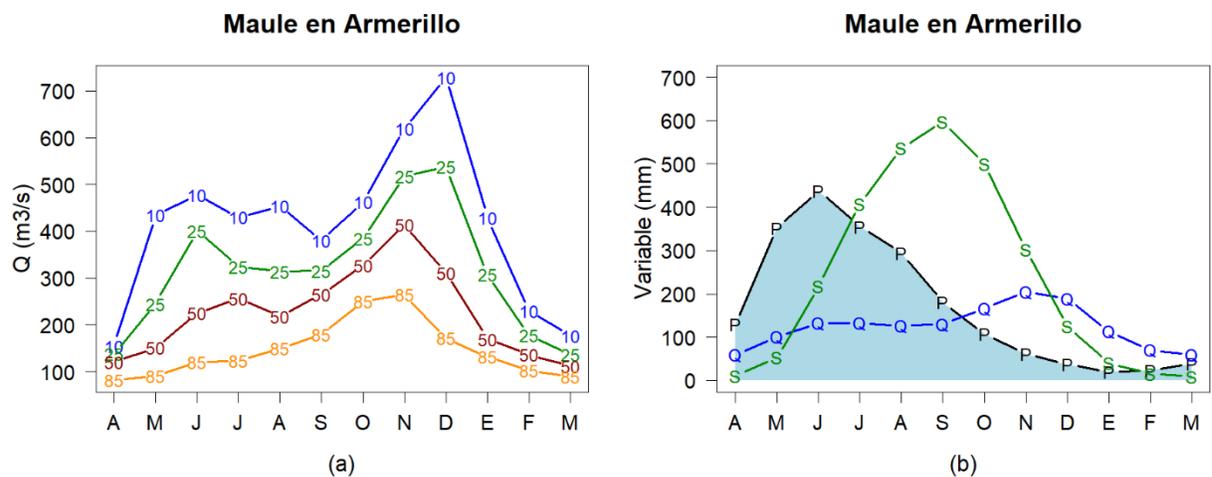


Figura 3.4 Curvas de variación estacional, cuenca Maule en la Recova.
P: precipitación media periodo 1979-2014. **Q:** caudal medio periodo 1979-2014 (reconstruido). **S:** SWE medio 1984-2014.

El registro de observaciones para el caudal, forzantes (por ej. Precipitación, temperatura) y SWE (reanálisis), se indica en la Tabla 3.2.

Tabla 3.2 Registro de observaciones y/o productos utilizados.

Variable	Longaví	Achibueno	Maule
Q (m ³ /s)	1979-actual	1986-actual	2009-actual
Forzantes (Precipitación y temperatura)	1979-2015	1979-2015	1979-2015
SWE (mm)	1984-2014	1984-2014	1984-2014

Nota: Para el periodo 1979-2009, en Maule en Armerillo se cuenta con los caudales reconstruidos a nivel mensual.

El periodo de simulación (pronósticos) corresponde a 1979-2014 para las cuencas de Longaví y Achibueno. Los años faltantes (de Q) de esta última cuenca fueron rellenados utilizando correlaciones mensuales con la cuenca de Longaví (para verificar volumen de deshielo). En el caso de Maule en Armerillo, el periodo de simulación (pronósticos) sólo se consideró entre 2005 y 2014, debido a límites de recursos computacionales. De este periodo, entre 2009-2014 se utilizó la información de caudales diarios, y entre 2005-2009 las reconstrucciones mensuales, para la verificación de los volúmenes estacionales.

Tanto los modelos como las forzantes fueron facilitados por el equipo a cargo de la modelación hidrológica en el proyecto de Actualización del Balance hídrico Nacional (DGA, 2017). Las forzantes se encuentran distribuidas en celdas con una resolución horizontal aproximada de 5 km para el periodo 1979-2014. El producto de precipitación se realizó en base a una regionalización estadística de datos del reanálisis atmosférico ERA5. Los modelos estadísticos utilizados en esta técnica consideran información de topografía y observaciones locales de precipitación. El producto de temperatura por otra parte incorpora además, información de imágenes satelitales.

3.2 Caracterización de años

En distintas secciones de este trabajo se hace referencia a años “húmedos”, “normales” o “secos”. Estas categorías obedecen a distintos criterios, como por ejemplo la precipitación o el caudal durante los meses de deshielo (septiembre-marzo) o invierno (abril-agosto).

A continuación, se presenta la Tabla 3.3, donde los años húmedos se encuentran destacados en azul, los secos en naranja y los normales, en gris. Esta caracterización se realizó en base al índice de precipitación estandarizado (“Standard Precipitation Index” o SPI, McKee, 1993) y a al índice de escorrentía estandarizado (“Standard Streamflow Index” o SSI). Se estableció un rango entre -0,75 y 0,75 para clasificar un año como normal, mayor a 0,75 como húmedo y menor a -0,75 como seco. La formulación de estos índices se encuentra en el ANEXO B.

Tabla 3.3 Caracterización años según SPI y SSI.

Año	Achibueno en la Recova			Longaví en el Castillo			Maule en Armerillo		
	SPI invierno	SPI deshielo	SSI deshielo	SPI invierno	SPI deshielo	SSI deshielo	SPI invierno	SPI deshielo	SSI deshielo
1979	0,3	1,7	1,0	0,3	1,8	1,3	0,4	1,5	1,0
1980	1,8	0,2	-0,9	1,9	0,1	-0,9	1,6	0,0	0,4
1981	0,6	0,2	-0,9	0,7	0,1	-0,9	0,6	0,0	-0,3
1982	1,9	1,8	1,8	1,8	1,8	2,2	2,0	1,8	2,2
1983	0,1	-0,8	-0,3	0,0	-0,6	-0,1	-0,1	-0,8	-0,1
1984	1,3	1,0	1,9	0,9	1,2	2,2	0,8	1,3	1,8
1985	-0,6	0,8	-0,2	-0,5	0,8	0,0	-0,6	0,7	-0,7
1986	1,6	0,8	-0,2	1,6	0,7	0,1	1,6	0,7	0,9
1987	0,2	0,7	0,6	0,1	0,6	0,5	0,5	0,7	0,7
1988	-0,1	-0,8	-0,4	-0,1	-1,0	-0,5	-0,1	-0,9	-0,4
1989	-0,8	0,1	-0,8	-0,9	0,0	-0,6	-0,7	0,0	-0,7
1990	-1,4	0,7	-0,6	-1,5	0,7	-0,6	-1,5	0,6	-1,0
1991	0,7	1,3	0,0	0,6	1,3	0,3	0,8	1,3	0,2
1992	0,9	-0,9	0,3	1,0	-0,7	0,5	1,0	-0,8	0,9
1993	0,6	-0,8	-0,3	0,7	-0,8	-0,4	0,6	-0,7	0,0
1994	-0,3	-0,1	-0,3	-0,4	0,0	-0,1	-0,1	0,1	-0,1
1995	0,4	-1,4	0,4	0,6	-1,3	0,5	0,5	-1,5	0,6
1996	-1,4	-1,6	-1,9	-1,4	-1,6	-2,0	-1,4	-1,4	-1,8
1997	0,6	1,5	1,7	0,6	1,5	1,7	0,8	1,7	1,4
1998	-2,0	-1,8	-2,6	-2,0	-1,9	-2,4	-2,1	-1,7	-2,5
1999	-1,0	0,7	0,8	-0,9	0,5	0,9	-0,8	0,6	0,1
2000	-0,2	1,0	0,8	-0,1	1,1	0,8	-0,2	0,8	0,9
2001	1,1	-0,1	-0,2	1,3	-0,1	-0,2	0,7	-0,3	0,1
2002	0,9	0,9	1,9	0,7	1,0	1,3	0,8	0,9	1,6
2003	-1,3	0,5	-0,8	-1,2	0,5	-1,1	-1,2	0,5	-1,0
2004	-0,8	0,6	0,0	-0,8	0,5	0,2	-0,9	0,7	-0,7
2005	1,6	-0,4	1,3	1,5	-0,5	0,0	1,6	-0,4	1,0
2006	0,8	0,5	1,2	0,9	0,5	0,8	0,7	0,6	0,6
2007	-1,3	-2,0	-0,5	-1,4	-1,8	-0,7	-1,4	-1,6	-1,1
2008	0,6	-2,0	-0,6	0,5	-2,0	-1,3	0,6	-2,4	-0,1
2009	-0,3	0,2	0,3	-0,1	0,2	0,3	-0,3	0,4	0,1
2010	-1,1	-0,6	-0,9	-1,1	-0,6	-0,7	-1,2	-0,3	-0,9
2011	-0,3	-1,0	0,2	-0,3	-0,9	0,3	-0,5	-1,2	-0,6
2012	-1,1	0,0	-1,2	-1,1	-0,1	-1,1	-0,9	0,1	-1,3
2013	-1,1	-0,5	-0,5	-1,0	-0,5	-0,4	-1,0	-0,6	-0,7
2014	-0,4	-0,4	-0,3	-0,4	-0,5	0,0	-0,5	-0,1	-0,3

En la Tabla 3.3, se aprecia la baja relación que presenta Longaví y Achibueno con respecto a la precipitación observada durante el invierno. Años húmedos durante el invierno pueden resultar en deshielos secos o normales, si la precipitación es baja durante los meses estivales (por ejemplo, 1980 o 1992). En Maule en cambio, existe una mayor relación (es esperable debido a que es una cuenca nivo-pluvial) entre precipitación durante invierno y volumen de deshielo.

4 METODOLOGÍA

4.1 Calibración y evaluación del modelo

Se calibraron 14 parámetros del modelo VIC. La definición y valor calibrado de cada parámetro se presenta en el ANEXO A. Tal como fue mencionado en la sección anterior, el algoritmo de optimización utilizado fue el SCE-UA.

La configuración final de la calibración para cada cuenca se escogió luego de una serie de pruebas en las que se variaron distintas decisiones metodológicas (periodo de calibración, función objetivo, límites de parámetros, etc.). El desempeño del modelo en cada prueba se evaluó utilizando métricas clásicas de evaluación como los índices de eficiencia de Kling-Gupta “KGE” (Gupta et al, 2009) y de Nash Sutcliffe “NSE” (Nash y Sutcliffe, 1970) por ejemplo, y otras métricas relacionadas con la curva de duración conocidas como “*hydrological signatures*” (Yilmaz, 2008). Finalmente, se escogió la calibración más adecuada para cada caso.

A continuación, se presenta la formulación del KGE, que es utilizado como función objetivo en la calibración. En el ANEXO C se encuentra la formulación de las otras métricas y/o índices utilizados en la evaluación del modelo.

$$KGE = 1 - ED \quad (1)$$

$$ED = \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (2)$$

$$\alpha = \frac{\sigma_s}{\sigma_o} \quad , \quad \beta = \frac{\mu_s}{\mu_o} \quad (3)$$

Donde:

r: Coeficiente de correlación de Pearson, entre la variable simulada y observada.

σ_s : desviación estándar de la variable simulada.

σ_o : desviación estándar de la variable observada.

μ_s : media de la variable simulada.

μ_o : media de la variable observada.

En la Tabla 4.1 se indican los periodos considerados para la calibración y validación en cada cuenca.

Tabla 4.1 Fechas calibración y validación.

Cuenca	Inicio calibración	Fin calibración	Inicio validación	Fin validación
Longaví en el Castillo	01/04/1990	31/03/2001	01/04/2001	31/03/2015
Achibueno en la Recova	01/04/1990	31/03/2003	01/04/2003	31/03/2015
Maule en Armerillo	01/04/2011	31/03/2015	01/04/2009	31/03/2011

A pesar de que la función objetivo fue la misma para las tres cuencas, se optó por otorgar un mayor peso en la calibración al periodo de deshielo (septiembre-marzo) en el caso de las cuencas Longaví en el Castillo y Achibueno en la Recova. Esto con el fin de mejorar el desempeño del modelo en este periodo. Para Longaví en el Castillo, la calibración se realizó maximizando el KGE en el periodo de deshielo, mientras que para Achibueno en la Recova, se maximizó un promedio ponderado del KGE entre el periodo de invierno y deshielo (pesos 0,2 y 0,8 respectivamente). En el caso de Maule en Armerillo se maximizó el KGE en el año completo. Por lo tanto, las funciones objetivo (FO_{Cuenca}) utilizadas son las siguientes:

$$FO_{Longaví} = KGE_{sep-mar} \quad (4)$$

$$FO_{Achibueno} = 0,8 \cdot KGE_{sep-mar} + 0,2 \cdot KGE_{abr-ago} \quad (5)$$

$$FO_{maule} = KGE_{abr-mar} \quad (6)$$

Tal como fue señalado en un comienzo, tanto los periodos escogidos (Tabla 4.1) como las funciones objetivo (Ecuaciones 4, 5 y 6) fueron el resultado de una serie de pruebas en las que se escogió la configuración más adecuada para la calibración y validación.

4.2 Generación de los conjuntos y evaluación del pronóstico

La metodología ESP fue aplicada de forma retrospectiva, es decir, se realizaron pronósticos para años pasados (“hindcasting”). Los pasos seguidos fueron:

- Para cada año y_j (de un total de N), se forzó el modelo hasta un tiempo de inicialización t_i (instante en que se realiza el pronóstico) con las forzantes f_j de ese año (forzantes “observadas”).
- Para $t > t_i$, se forzó el modelo con las forzantes históricas f_k de todos los años distintos a y_j , generando N-1 miembros de series de salida (Q_k con $k \neq j$).
- A priori, se calculó el pronóstico de volumen estacional para el año y_j como la mediana de los volúmenes asociados a los N-1 miembros. La incertidumbre (idealizada) se representa como el boxplot de los N-1 miembros.
- Se repiten los pasos anteriores para todos los años, y para distintos tiempos de inicialización. Para inicializaciones anteriores o iguales al 1 de septiembre, las distintas métricas de evaluación se aplican al volumen pronosticado entre el inicio y fin del deshielo (1 de septiembre y 31 de marzo). **Para inicializaciones posteriores, las métricas se aplican al volumen pronosticado entre el tiempo de inicialización y el fin del deshielo.**

Los tiempos de inicialización utilizados fueron 5: 1 de julio, 1 de agosto, 1 de septiembre, 1 de octubre y 1 de noviembre. En la Figura 4.1 se presenta un esquema de los pasos descritos.

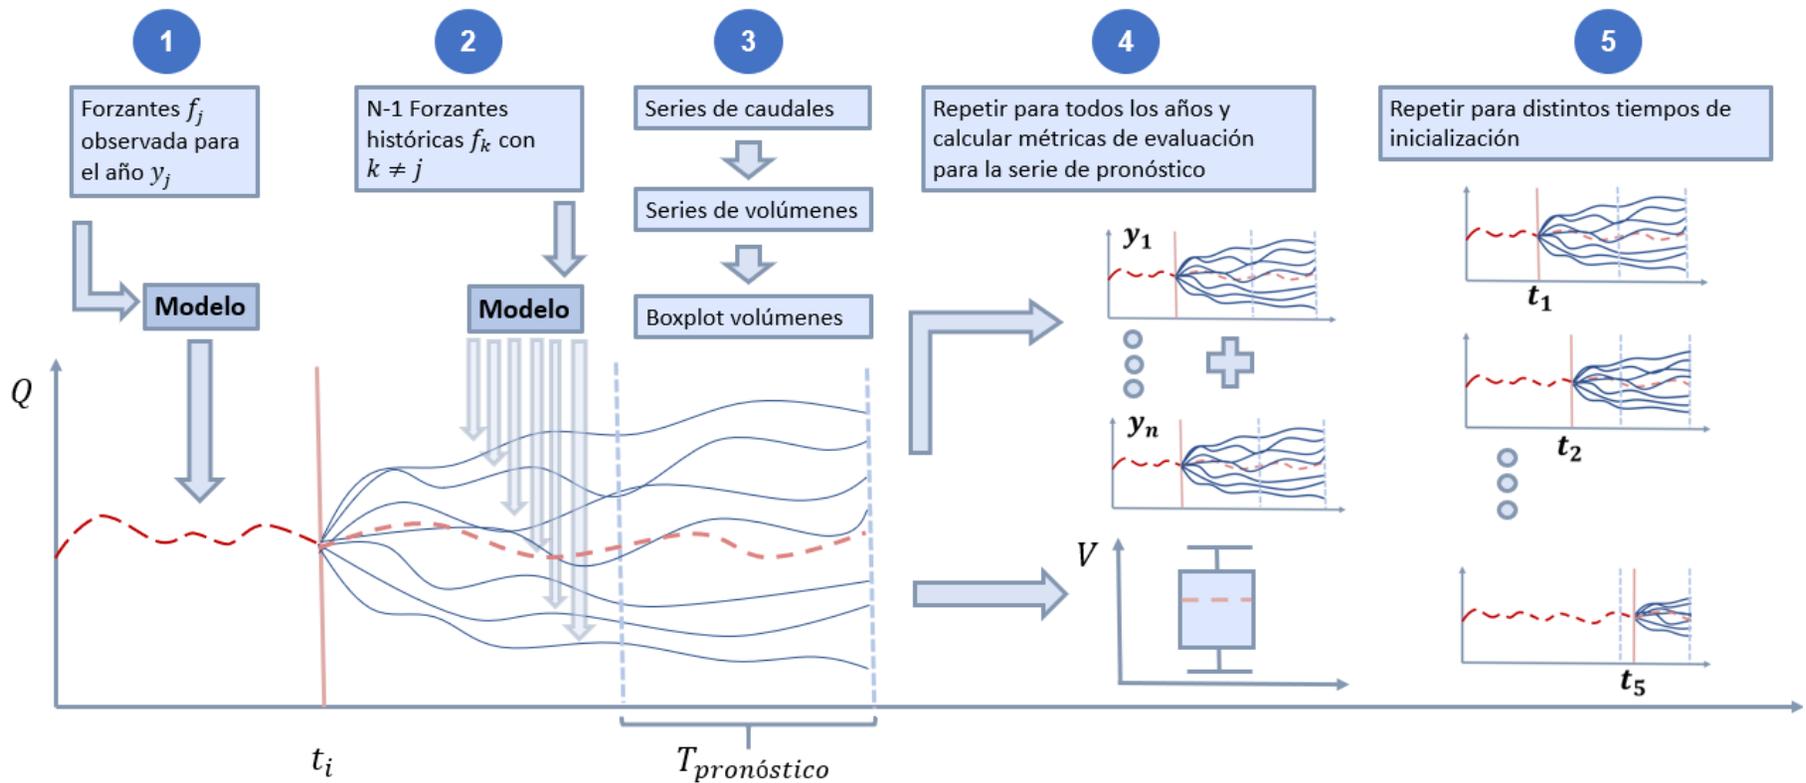


Figura 4.1 Esquema generación del pronóstico.

La evaluación de los pronósticos se realizó de forma determinista y probabilística. La Tabla 4.2 presenta las principales métricas utilizadas para evaluar distintos atributos del pronóstico. Este resumen corresponde a una adaptación de la tabla presentada por Mendoza et al (2017).

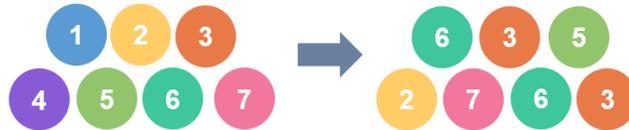
Tabla 4.2 Métricas y/o índices utilizados en la evaluación de los pronósticos

Notación	Nombre	Fórmula	Descripción	Tipo
e	Error porcentual	$e_i = \frac{q_{m,i} - o_i}{o_i}$	Varía entre $(-\infty, +\infty)$ con un valor ideal de 0. Es el porcentaje de error del pronóstico en cada año.	Det.
r	Coefficiente de correlación lineal o de Pearson	$r = \frac{1}{\sqrt{\sum_{i=1}^N (q_{m,i} - \bar{q}_m)^2} \sqrt{\sum_{i=1}^N (o_i - \bar{o})^2}}$	Varía entre $[-1, 1]$ con un valor perfecto de 1. Mide la correlación lineal entre los pronósticos y las observaciones.	Det.
$\%Bias$	Porcentaje de sesgo	$\%Bias = \frac{\sum_{i=1}^N (q_{m,i} - o_i)}{\sum_{i=1}^N o_i} \times 100$ $\%abs(Bias) = \frac{\sum_{i=1}^N q_{m,i} - o_i }{\sum_{i=1}^N o_i} \times 100$	Varía entre $(-\infty, +\infty)$ con un valor perfecto de 0. Mide la diferencia entre la media de los pronósticos y la media de las observaciones.	Det.
$RMSE$	Error cuadrático medio	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (q_{m,i} - o_i)^2}$	Varía entre $[0, +\infty)$ con un valor perfecto de 0.	Det.
α	Índice de confiabilidad	$\alpha = 1 - 2 \left[\frac{1}{N} \sum_{i=1}^N P_i(o_i) - U(o_i) \right]$	Varía entre $[0, 1]$ con un valor perfecto de 1. Cuantifica la diferencia entre la CDF del conjunto de miembros y la CDF de una distribución uniforme $U [0, 1]$.	Prob.
$CRPS$	Error probabilístico	$CRPS_i = \int_{-\infty}^{\infty} (P_{fct}(x) - P_{obs}(x))^2 dx$	Varía entre $[0, +\infty)$. Mide la diferencia entre la función de distribución acumulada pronosticada (CDF conjunto) y la observada para cada año.	Prob.
$CRPSS$	Continuous ranked probability skill score	$\overline{CRPS} = \frac{1}{N} \sum_{i=1}^N \int_{-\infty}^{\infty} (P_{fct}(x) - P_{obs}(x))^2 dx$ $CRPSS = 1 - \frac{\overline{CRPS}_{fct}}{\overline{CRPS}_{ref}}$	Varía entre $(-\infty, 1)$ con un valor perfecto de 1. Mide la habilidad del pronóstico en relación con un pronóstico de referencia (clima histórico, por ejemplo). Se calcula en base al CRPS promedio de la serie histórica de pronósticos.	Prob.

q_{mi} : mediana del conjunto de miembros en el año i . o_i : observación en el año i . N : número de años en que se pronostica.
 \bar{q}_m : promedio temporal de los q_{mi} . \bar{o}_m : promedio temporal de los o_{mi} .

También se evaluó la sensibilidad de la métrica o índice con respecto al tamaño de la muestra (N-1 miembros). Esto se realizó usando una técnica de re-muestro llamada *bootstrapping*. Este enfoque permite construir datos artificiales a partir de una colección dada de datos reales (Wilks, 2011). El procedimiento fue el siguiente:

- Del total de años (N) en que se realiza el pronóstico, se extrae una muestra de N años, con posibilidad de repetir. Por ejemplo, si el primer año extraído es 1990, este valor es reingresado a la muestra original antes de extraer el segundo año. En la Figura 4.2 se presenta un ejemplo de bootstrapping.



*Figura 4.2 Ejemplo de re-muestro con bootstrapping.
A la izquierda se presenta la muestra original y a la derecha una muestra producto del re-muestreo.*

- Con la nueva muestra de años (que probablemente es distinta a la original) y sus valores respectivos de volumen observado y pronóstico, se determina la métrica o índice deseado.
- El paso anterior se repite 1000 veces.
- Se ordenan los 1000 valores de la métrica y se calcula el rango del 95% de confianza.
- Se utiliza este nuevo conjunto (95% de confianza) de valores para graficar la distribución de la métrica.

4.3 Post Procesamiento

4.3.1 Esquema de pesos

Se realizó un post procesamiento en base a la incorporación de información climática. Cada miembro del conjunto se ponderó con un peso que depende de la similitud con respecto a las forzantes del año en que se pronostica.

Antes de realizar la ponderación de los miembros, se estudió la correlación entre distintos índices climáticos (durante meses previos al deshielo) y las forzantes durante el periodo deshielo (representadas por la precipitación) con el fin de encontrar el predictor más adecuado. Tras escoger el mejor predictor, se dio paso al cálculo de los pesos.

El esquema de asignación de pesos utilizado corresponde al descrito por Werner et al (2004) y es explicado a continuación. Para cada año:

- Se genera un vector X de distancias absolutas entre el índice climático del año y los índices del resto de los años. El largo de X será igual a los años de información disponible menos 1, en este caso:

$$n = N - 1 = 35 \quad (7)$$

$$X = (x_1, x_2, \dots, x_n) \quad (8)$$

En el caso de considerar más de un índice climático como predictor, se definió la distancia x_i como:

$$x_i = \sqrt{\sum_{h=1}^M f_h \cdot m_i^2} \quad (9)$$

Donde M es el número de predictores utilizados, m_i es la distancia absoluta de cada índice con respecto al año en que se pronostica y f_h representa un ponderador (para dar pesos distintos a los predictores).

- El vector X es ordenado de menor a mayor, generando un vector X' , es decir ordenado desde los años más similares a los más distintos, con respecto al año en que se pronostica.

$$X' = (x_{(1)}, x_{(2)}, \dots, x_{(n)}) \quad x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)} \quad (10)$$

- Se crea un vector de pesos W a partir del vector X'

$$W = (w_1, w_2, \dots, w_n) \quad (11)$$

donde:

$$w_i = \left(1 - \frac{x_{(i)}}{x_{(k)}}\right)^{\lambda-1} \quad \text{si} \quad x_{(i)} \leq x_{(k)} \quad (12)$$

$$w_i = 0 \quad \text{si} \quad x_{(i)} > x_{(k)} \quad (13)$$

$$k = \left(\frac{n}{\alpha}\right) \quad (14)$$

- Luego, se calculan los pesos de cada miembro

$$p_i = \frac{w_i}{\sum_{j=1}^n w_j} \quad (15)$$

En la Ecuación (14), α es un parámetro que define los k miembros más cercanos que serán considerados, es decir, que tendrán un peso mayor a cero. Para valores altos de α se consideran menos miembros cercanos. Por otra parte, λ (Ecuación (12)) define la magnitud del peso que se da a cada miembro. Altos valores de λ darán más peso a los años que son similares al año en que se pronostica. Ambos parámetros pueden

considerarse constantes en cada tiempo de inicialización, es decir, iguales para todos los miembros, o variable para cada año, es decir, variables en relación con el predictor. En la Figura 4.3 se presenta un esquema con el fin de ejemplificar el significado de los parámetros α y λ .

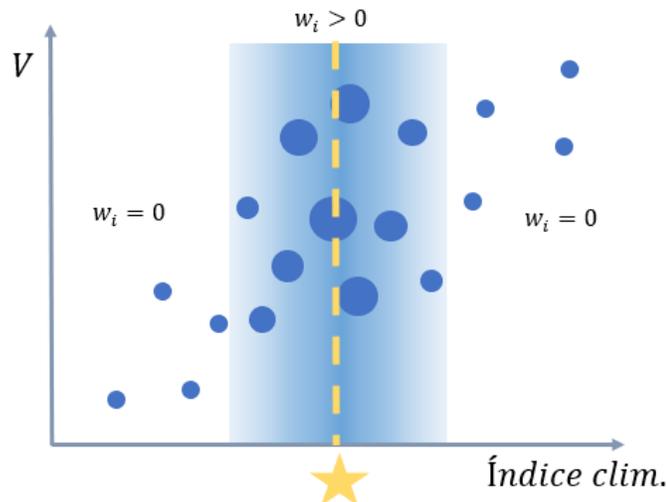


Figura 4.3 Esquema de pesos.

El año en que se pronostica es simbolizado por una estrella (sólo es conocido el índice climático); la banda de colores representa el límite de los k miembros considerados en la ponderación (en la imagen $k=10$) y el tamaño de cada punto representa la magnitud de la ponderación para cada año (que depende de λ).

Con el fin de encontrar la mejor combinación de α y λ , se estudia el comportamiento de distintas métricas de desempeño (Tabla 4.2) al variar estos parámetros de forma manual. Luego, se escogen los parámetros (α y λ) que permitan mejorar en conjunto las distintas métricas. La elección de los parámetros se realiza para cada tiempo de inicialización.

Finalmente, la función de distribución acumulada modificada se calcula en base a las probabilidades p_i . De esta nueva función se puede extraer el volumen asociado a cada probabilidad de excedencia original (distribución empírica) y obtener un conjunto de miembros modificado. La Figura 4.4 esquematiza este procedimiento.

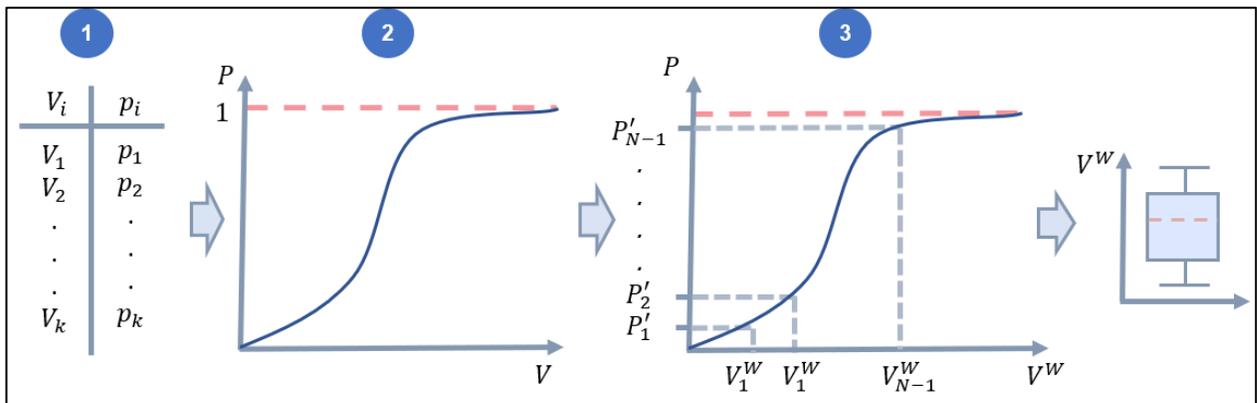


Figura 4.4 Obtención del nuevo conjunto.

(1) Usando las probabilidades p_i (obtenidas a partir de los pesos w_i) se obtiene una función de probabilidad acumulada (2). Mediante esta función y el conjunto de probabilidades acumuladas empíricas P'_i se obtiene la nueva muestra de volúmenes (3).

El post-procesamiento sólo fue aplicado a las cuencas de Longaví y Achibueno.

4.3.2 Índices climáticos

Los predictores escogidos para la asignación de pesos de los miembros, fueron el índice ENSO multivariante o MEI y el ONI, debido a que fueron los índices que presentaron una mayor correlación con el volumen a pronosticar. Se descartó utilizar el índice de precipitación estandarizado (SPI) durante invierno, debido a la baja relación con respecto al volumen de deshielo en las cuencas pluvio-nivales (Tabla 3.3).

El MEI es una función de componentes meteorológicos y oceanográficos sobre la región tropical del Pacífico (30 ° S-30 ° N y 100 ° E-70 ° W). Estos componentes son: (1) presión a nivel del mar, (2) temperatura de la superficie del mar, (3) componentes zonales y (4) meridionales del viento en la superficie y (5) radiación saliente de onda larga. El ONI por otra parte, es el promedio de las anomalías de la temperatura de la superficie del mar en un área del Océano Pacífico ecuatorial centro-este conocida como “Niño-3.4”.

El MEI se calcula a escala bimensual y se encuentra disponible un par de días luego de que finaliza cada mes en la página del NOAA (National Oceanic and Atmospheric Administration) de EEUU. El ONI se encuentra disponible a escala tri-mensual en la misma página. Es por esto que, para cada tiempo de inicialización se utilizó el MEI y ONI de los dos y tres meses anteriores, respectivamente.

5 RESULTADOS Y DISCUSIÓN

5.1 Calibración y evaluación del modelo

La Tabla 5.1 muestra las métricas y/o índices obtenidos de la calibración de las tres cuencas. Se presentan métricas de evaluación tanto del periodo completo (por ejemplo, “KGE”) como durante los meses de deshielo (por ejemplo, “KGE (sep-mar)”). La formulación de las métricas que no se encuentran definidas en la sección 4 se presenta en el ANEXO C.

Tabla 5.1 Métricas y/o índices de rendimiento de la calibración.

Índice/métrica	Longaví		Achibueno		Maule	
	Calib.	Valid.	Calib.	Valid.	Calib.	Valid.
KGE	0,54	0,57	0,79	0,79	0,76	0,83
α	0,63	0,62	1,02	0,90	0,99	0,97
β	0,88	0,87	1,00	0,91	1,04	0,95
rPearson	0,75	0,84	0,89	0,84	0,76	0,84
NSE	0,54	0,66	0,72	0,78	0,52	0,68
KGE (sep-mar)	0,84	0,77	0,88	0,79	0,81	0,90
α (sep-mar)	0,99	1,01	0,86	0,82	1,06	0,99
β (sep-mar)	0,93	1,00	1,05	0,98	1,04	0,97
rPearson (sep-mar)	0,86	0,77	0,85	0,89	0,83	0,91
NSE (sep-mar)	0,71	0,53	0,77	0,69	0,63	0,81
KGE SWE	0,91	0,65	0,94	0,69	0,75	0,77
%BiasRR	-11,81	-12,79	5,09	-1,75	3,70	-4,54

A continuación, se presentan los resultados gráficos de la calibración para las tres cuencas. Cada figura de las tres siguientes (Figura 5.1, Figura 5.7 y Figura 5.10) contiene gráficos de: la curva de duración de caudales medios diarios (a y b), caudales mensuales promedio (c y d), serie de caudales mensuales (e), serie de SWE diario (f) y serie de volúmenes de deshielo, es decir, volumen entre septiembre y marzo (g).

En los paneles (a) y (b) se incluyen algunos índices (en porcentaje) de desempeño enfocados en distintos tramos de la curva de duración (caudales altos, medios o bajos). La formulación de estos índices se encuentra en el ANEXO C.

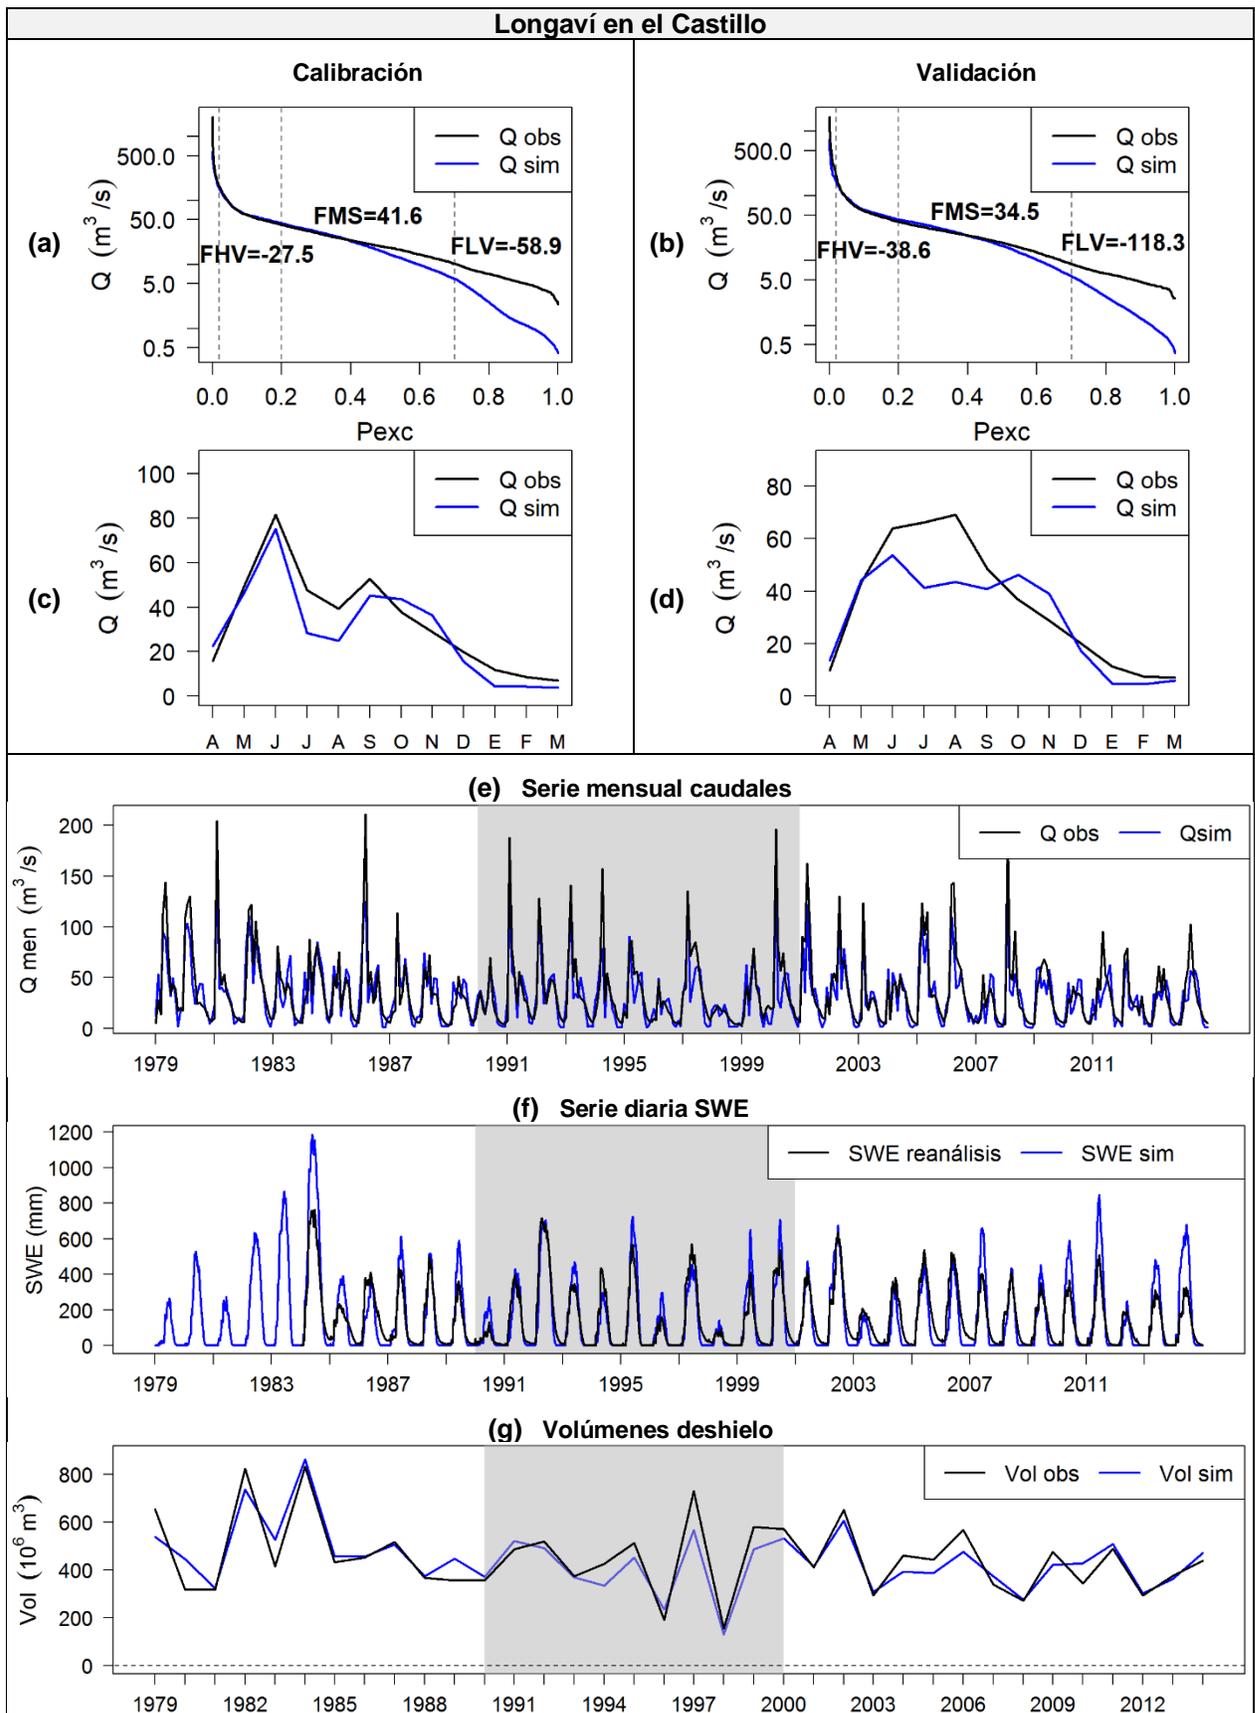


Figura 5.1 Resultados calibración Longaví en el Castillo.

5.1.1 Longaví en el Castillo (Figura 5.1)

Durante el periodo de deshielo se obtienen índices KGE de 0,84 y 0,77 en calibración y validación, respectivamente. Debido a que la calibración fue realizada optimizando el rendimiento en el periodo deshielo, el desempeño en el resto del año se ve disminuido. Esto se traduce en una subestimación del caudal durante el periodo de invierno, más notorio aún, durante la validación (Figura 5.1 c y d). No obstante, es importante mencionar que el rendimiento utilizando una calibración durante el periodo completo arrojaba valores de KGE de 0,59 y 0,62, para la calibración y validación respectivamente.

Durante el deshielo, se observa un comportamiento del caudal medio que se repite en prácticamente todos los años caracterizado por una sobreestimación del volumen (o caudal medio Figura 5.1 c y d) en los primeros meses de deshielo seguido por una subestimación en los meses finales. Esto último también se evidencia en las curvas de duración, donde los caudales más bajos (que ocurren en los meses de verano) son subestimados.

Los componentes del KGE (deshielo), muestran que, durante el deshielo, el coeficiente de correlación de Pearson es el elemento que aporta más error. Los otros dos componentes se acercan bastante al valor ideal ($=1$). No obstante, el valor α (razón entre volúmenes) se explica por la compensación de volúmenes sobre y subestimados. La correlación por otra parte se realiza a nivel diario por lo que evidencia el comportamiento descrito anteriormente (sobre y subestimación).

La Figura 5.1.f muestra que el SWE simulado comienza a disminuir anticipadamente con respecto al SWE obtenido del reanálisis de Cortés (2016). Esto podría relacionarse con la sobreestimación del caudal durante octubre-noviembre, y con la consecuente subestimación en los meses posteriores. En la Figura 5.2 se presenta un acercamiento de la serie de SWE.

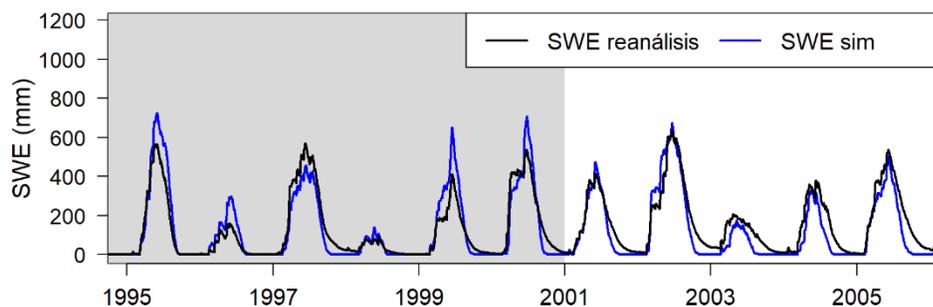


Figura 5.2 Acercamiento a la serie de SWE diario en Longaví en el Castillo.

Al graficar la razón entre volúmenes mensuales observados y simulados se aprecia el sesgo mensual del modelo, que se compensa en el volumen total. La Figura 5.3 muestra esta razón, separando el gráfico en tres grupos: los primeros meses de deshielo, que representan en promedio la mayor parte del volumen estacional (70%) y en los que

claramente se tiende a sobre estimar el volumen mensual (a excepción de septiembre); los meses posteriores, que en promedio representan un menor porcentaje del volumen estacional y en los que se tiende a sub estimar el volumen mensual, y finalmente, el volumen total durante el deshielo.

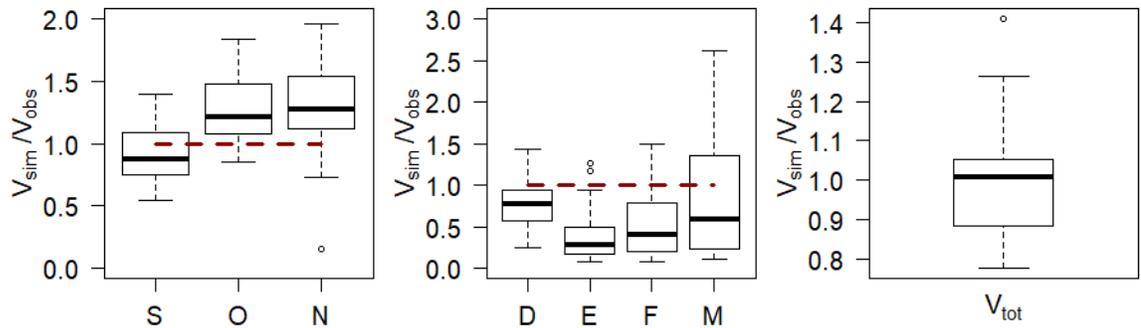


Figura 5.3 Razón volumen observado-volumen simulado durante meses de deshielo. Cuenca: Longaví en el Castillo. Periodo: 1979-2014 (36 años).

Sería útil conocer las causas de este sesgo mensual, sobre todo considerando que al aplicar la metodología ESP es probable que este comportamiento se repita. Aplicar un factor de corrección constante a cada mes, del tipo:

$$Factor = \frac{mediana(Volúmenes obs.)}{mediana(Volúmenes sim.)}$$

tiende a perjudicar el valor del volumen total de deshielo, ya que altera la compensación (sobre-subestimación) que realiza internamente el modelo.

La magnitud del error mensual estaría relacionada con el tipo de mes (cálido o frío). Al graficar la razón V_{sim}/V_{obs} versus la temperatura media mensual (Figura 5.4) se obtiene un comportamiento variable a lo largo de los meses de deshielo. Por ejemplo, en los primeros meses, como septiembre y octubre, el volumen tiende a sobreestimarse cuando el mes es cálido y a subestimarse cuando es frío. En los meses finales del deshielo este comportamiento se invierte. Esto último podría estar relacionado con el derretimiento anticipado.

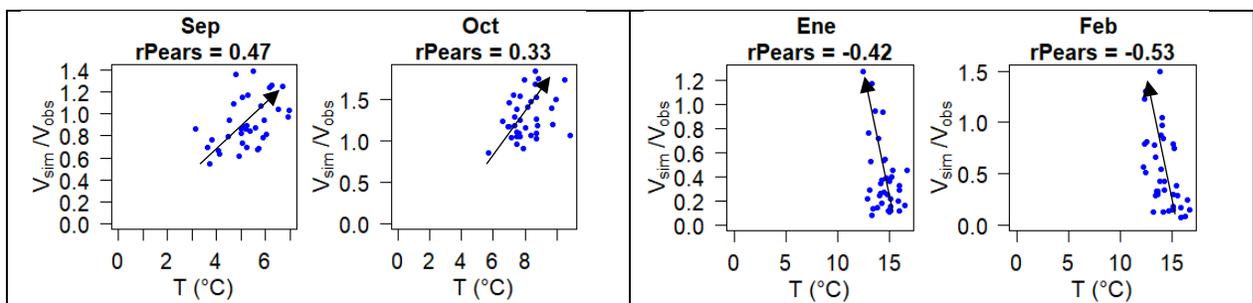


Figura 5.4 Relación error volumen mensual y temperatura media mensual en la cuenca. Cuenca: Longaví en el Castillo. Periodo 1979-2014 (36 años).

En general, los puntos que se alejan de la correlación anterior corresponden a meses fríos con baja precipitación o cálidos con alta precipitación. Por lo tanto, también

habría una dependencia de la precipitación. Sin embargo, esta correlación sólo es más clara en los meses finales (Figura 5.5).

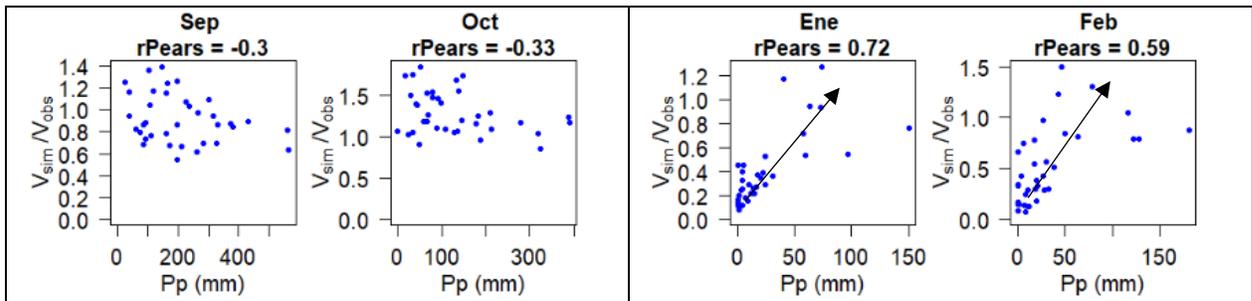


Figura 5.5 Relación error volumen mensual y precipitación mensual.

Con respecto al volumen total de deshielo (Figura 5.1 g), la Tabla 5.2 muestra algunos indicadores de la serie de errores porcentuales absolutos.

Tabla 5.2 Errores Volúmenes de deshielo simulados

Estadístico	Valor (%)
Máximo	41,0
Mediana (abs)	7,4
Promedio (abs)	10,9

En general, se observa que el error del volumen de deshielo es menor en los años “normales” (normales en términos de volumen de deshielo). Al graficar el SSI de cada año (entre meses sep-marzo) versus el error del volumen de deshielo (Figura 5.6), se observa que en general, el modelo subestima el volumen en años húmedos (azules) y sobreestima en años secos (rojos).

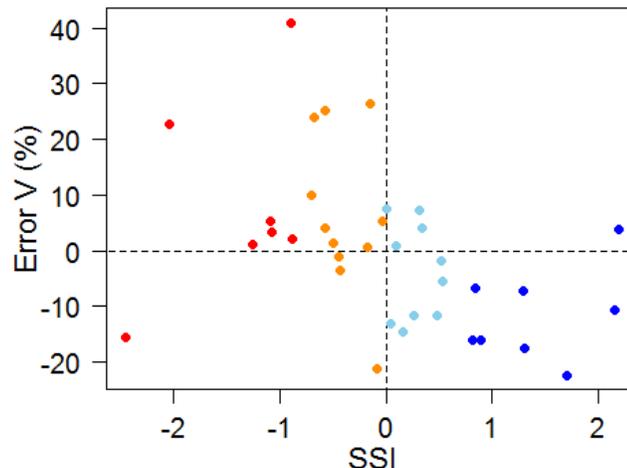


Figura 5.6 SSI versus error en el volumen de deshielo. Cuenca: Longaví en el Castillo. Periodo: 1979-2014 (36 años).

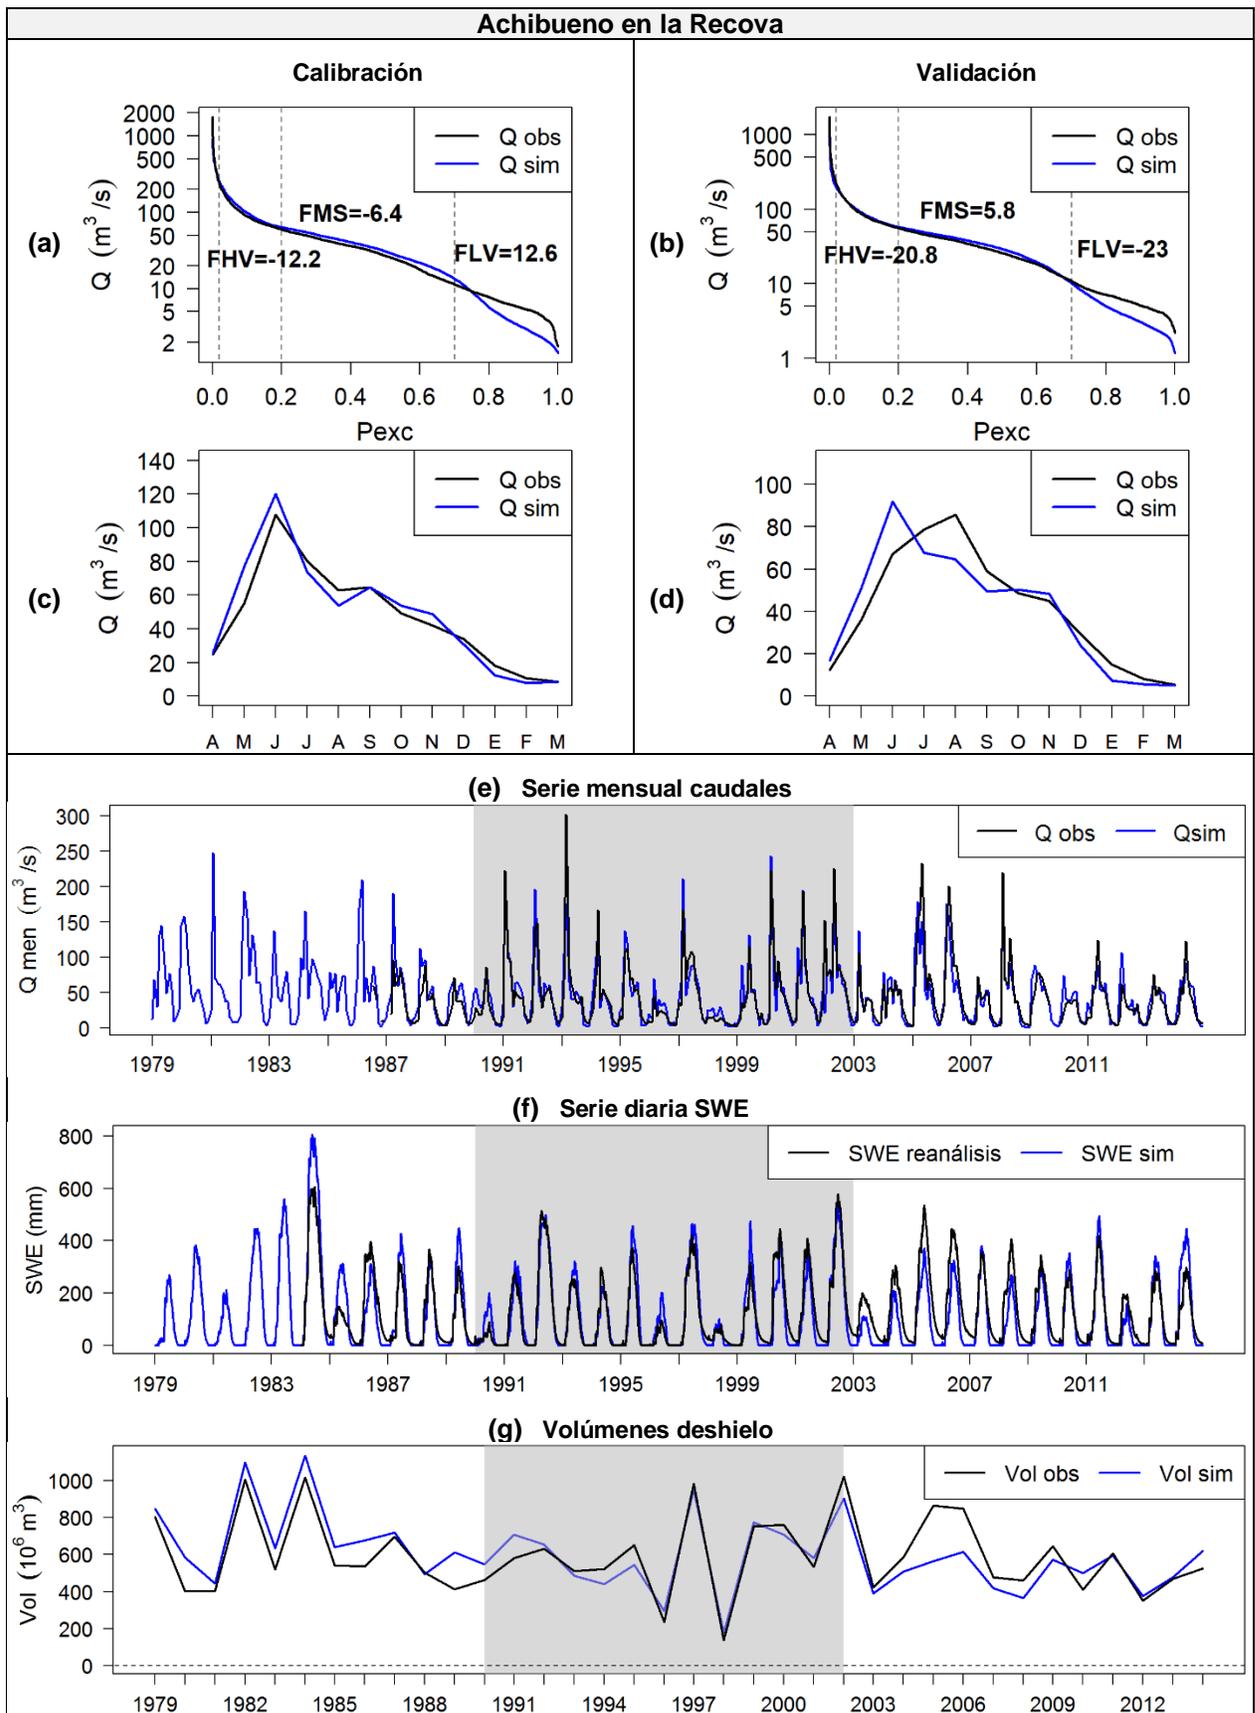


Figura 5.7 Resultados calibración Achibueno en la Recova.

5.1.2 Achibueno en la Recova (Figura 5.7)

En el caso de esta cuenca, el desempeño del modelo durante el año completo no se ve tan afectado al priorizar el desempeño durante el deshielo, como ocurrió con Longaví en el Castillo.

La curva de variación estacional (Figura 5.7 c y d) muestra una mayor similitud entre la observación y la simulación durante el deshielo en comparación con la cuenca anterior. No obstante, esta curva resulta del promedio de varios años, y en este caso, los errores de cada año se han compensado. Analizando cada año, se observa que se repite el comportamiento durante el deshielo descrito para Longaví en el Castillo, es decir una sobreestimación del volumen durante los primeros meses, seguido por una subestimación. Para esta cuenca, también se observa una subestimación de los caudales bajos (Figura 5.7 a y b) aunque con un error menor que la cuenca anterior; el índice FLV (indicador del error de la pendiente en la curva de duración para el segmento de caudales bajos) para Achibueno es 13% mientras que para Longaví es 59%, en la calibración.

De la misma forma que en Longaví, la curva de SWE suele decaer antes que lo indicado por el reanálisis de Cortés, lo que revelaría un derretimiento anticipado.

En la Figura 5.8 se presenta la relación entre los volúmenes mensuales simulados y observados durante el deshielo. A pesar de que estas razones son más próximas a 1 que, en Longaví, el volumen total no necesariamente es más cercano al real.

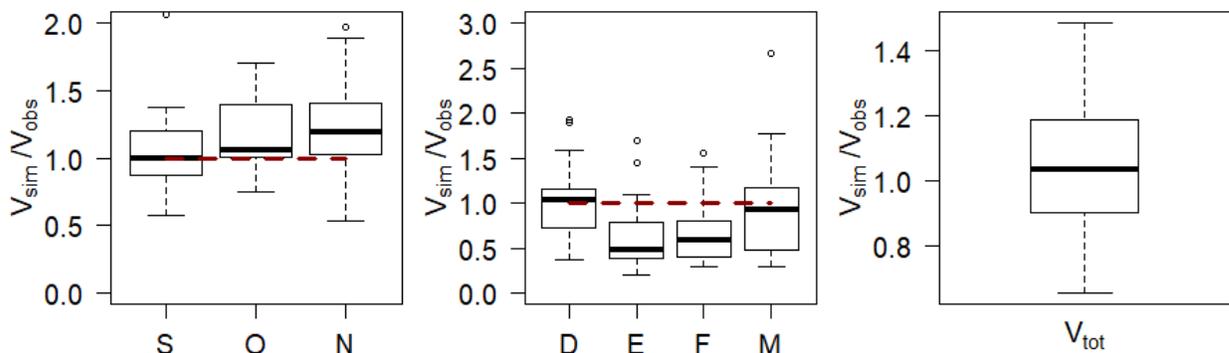


Figura 5.8 Razón volumen observado-volumen simulado durante meses de deshielo. Cuenca: Achibueno en la Recova. Periodo: 1979-2014.

Además del coeficiente de correlación, el componente α (razón entre medias) del KGE (deshielo) también aporta un error significativo, que repercute en el error del volumen estacional.

La Tabla 5.3 muestra algunos indicadores de los volúmenes de deshielo obtenidos. Se observa que los errores son levemente mayores que para Longaví.

Tabla 5.3 Errores Volúmenes de deshielo simulados

Estadístico	Valor (%)
Máximo	48,2
Mediana (abs)	12,0
Promedio (abs)	15,2

En la Figura 5.9 se observa que, al igual que en Longaví, el modelo tiende a subestimar el volumen en años húmedos y a sobreestimar en años secos.

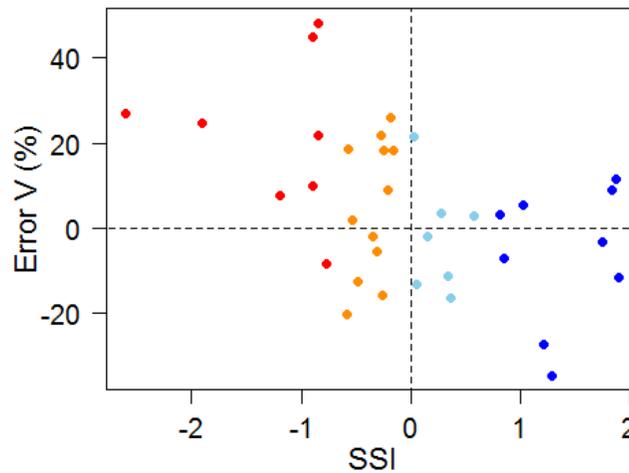


Figura 5.9 SSI versus error en el volumen de deshielo. Cuenca: Achibueno en la Recova. Periodo: 1979-2014 (36 años).

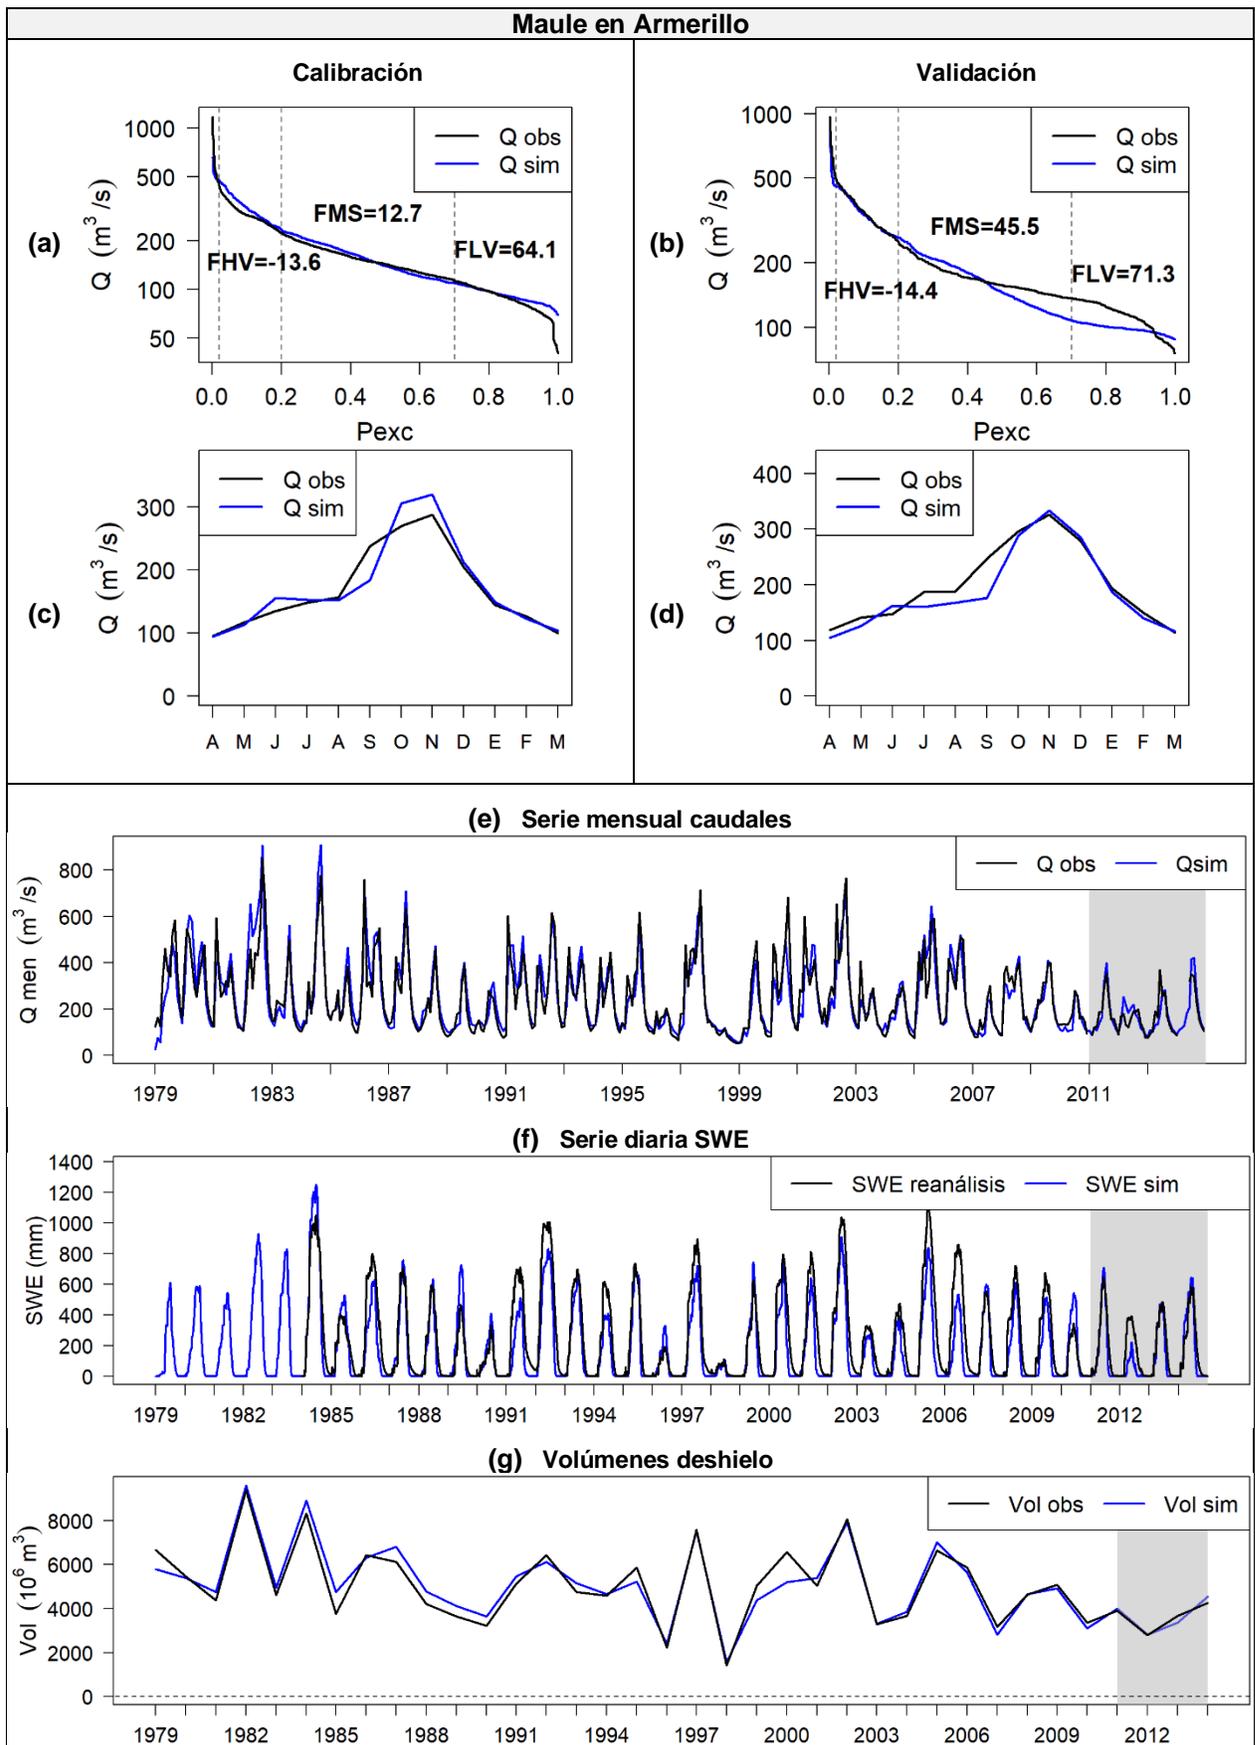


Figura 5.10 Resultados calibración Maule en Armerillo.

5.1.3 Maule en Armerillo (Figura 5.10)

Esta cuenca es un caso muy distinto a las dos cuencas vistas anteriormente. A diferencia de las otras cuencas, para Maule en Armerillo se cuenta con un registro de “observaciones” mucho menor (6 años de caudales diarios). Además, estas observaciones en realidad son reconstrucciones del régimen natural de la cuenca, lo que agrega otra fuente de error. Debido a la corta extensión de observaciones (Q diarios), la calibración no necesariamente logra ajustar el modelo a escenarios muy diferentes al periodo de calibración. No obstante, se obtienen índices KGE (en el periodo completo) aceptables (0,76 y 0,83 para calibración y validación, respectivamente), mayores incluso que para Longaví. Por otra parte, el error en el cálculo del volumen (en los 36 años) es inferior a las otras cuencas, con un máximo de 26% y promedio (y mediana) de 7%.

Para esta cuenca no fue necesario optimizar el KGE durante el periodo de deshielo, ya que, al calibrar durante el año completo, el modelo se desempeñó mejor (considerando KGE) durante los meses septiembre a marzo que para el resto del año. Las curvas de variación estacional graficadas (Figura 5.10 c y d) representan periodos cortos; 4 y 2 años, respectivamente. Debido a que se dispone de una serie más extensa de caudales mensuales reconstruidos, es posible verificar que la curva se ajusta mejor al utilizar más años como validación. En la Figura 5.11 se extiende la validación entre 2005-2011.

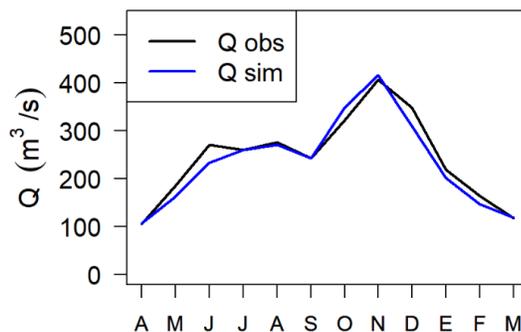


Figura 5.11 Curva de variación estacional extendida para la validación, en Maule en Armerillo.

En relación al error de sobre y subestimación observado en las otras cuencas, en este caso, no existe un sesgo marcado (Figura 5.12).

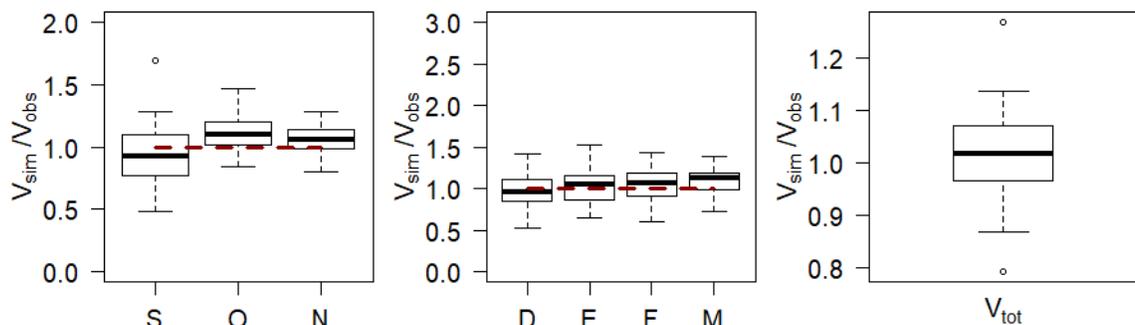


Figura 5.12 Razón volumen observado-volumen simulado durante meses de deshielo. Cuenca: Maule en Armerillo. Periodo: 1979-2014.

Error volúmenes

Como se observó (especialmente en Longaví y Achibueno), el error en la estimación del volumen estacional alcanza valores elevados, sobre todo en años más extremos (en términos de volumen). Se debe tener en cuenta que este error inevitablemente afectará el pronóstico. No se puede predecir en qué medida el error de la modelación perturbará cada simulación del conjunto de miembros, pero es importante tener presente que existe un error considerable previo a la aplicación de la metodología ESP.

5.2 Generación de los conjuntos y evaluación del pronóstico

La Figura 5.13 muestra los volúmenes obtenidos usando como tiempo de inicialización el 1 de septiembre. En el ANEXO D se encuentran los volúmenes obtenidos para el resto de las inicializaciones y una descripción de los elementos de un boxplot.

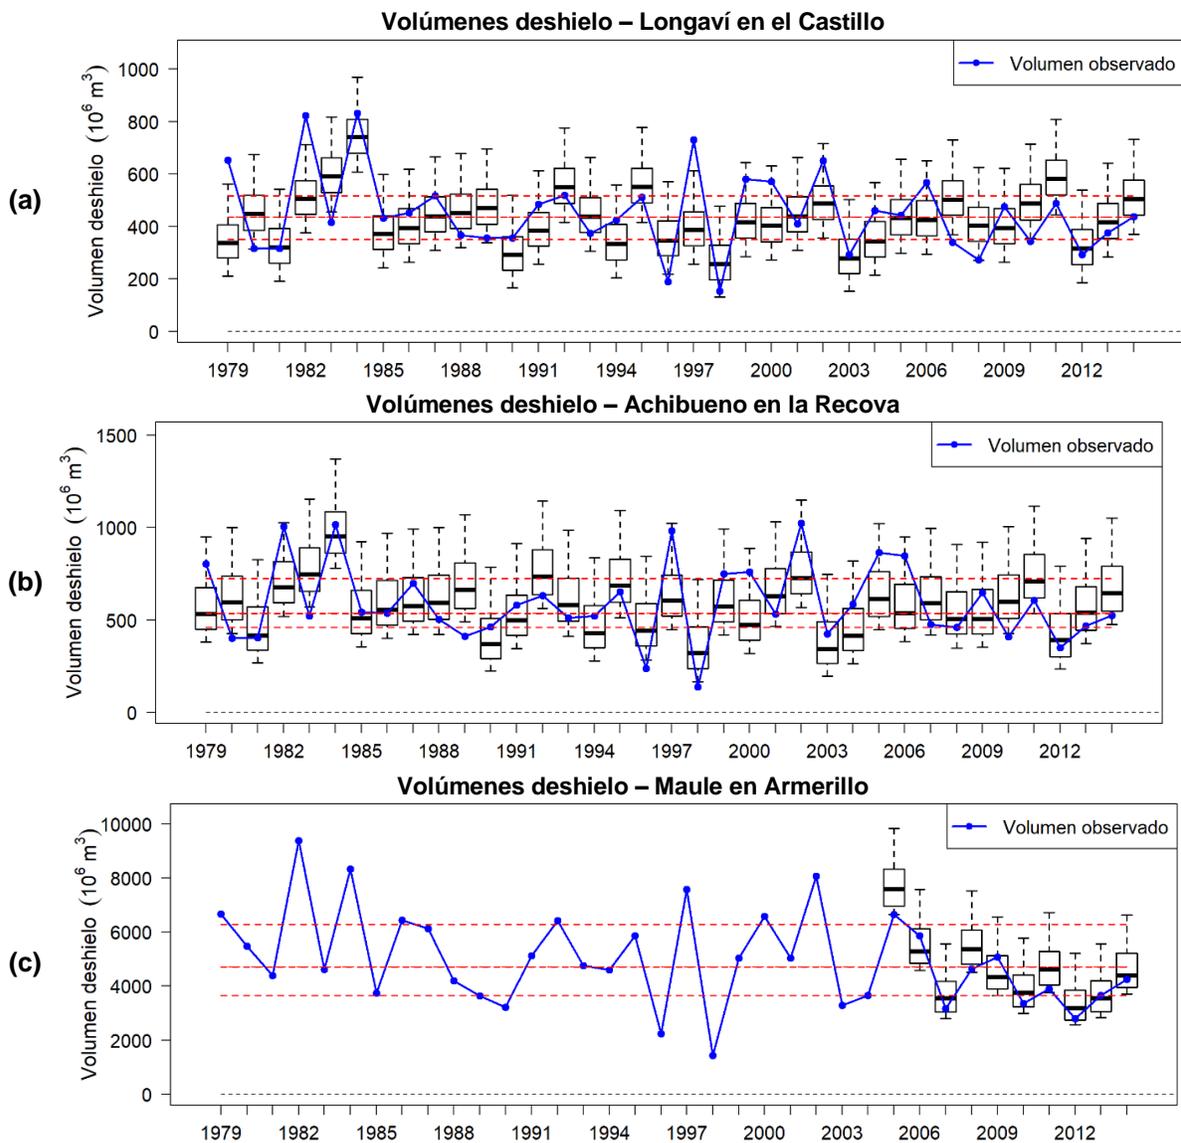


Figura 5.13 Volúmenes de deshielo, para $t_i = 1$ de septiembre. Las líneas rojas segmentadas indican los valores para el 1° cuartil, 2° cuartil (mediana) y 3° cuartil de los volúmenes observados entre 1979-2014.

Con el fin de comparar el conjunto a medida que la inicialización avanza, se presentan la Figura 5.14, Figura 5.16 y Figura 5.17. Para cada año se muestran 5 boxplots asociados a cada tiempo de inicialización. El color se vuelve azul a medida que el tiempo de inicialización es más tardío y la observación se presenta en rojo.

En estas figuras el volumen pronosticado para los tiempos de inicialización de octubre y noviembre se presenta como la suma entre el volumen observado y el volumen pronosticado para los meses siguientes (por motivos gráficos). Esto se decidió así, debido a que el boxplot para estas inicializaciones sólo se desplaza (al sumar el volumen observado), es decir, la caja no se deforma ni su cercanía con la observación correspondiente. Es importante recordar que **las métricas de evaluación en cambio, se aplican al volumen restante** (entre 1 de octubre o 1 de noviembre y 31 de marzo).

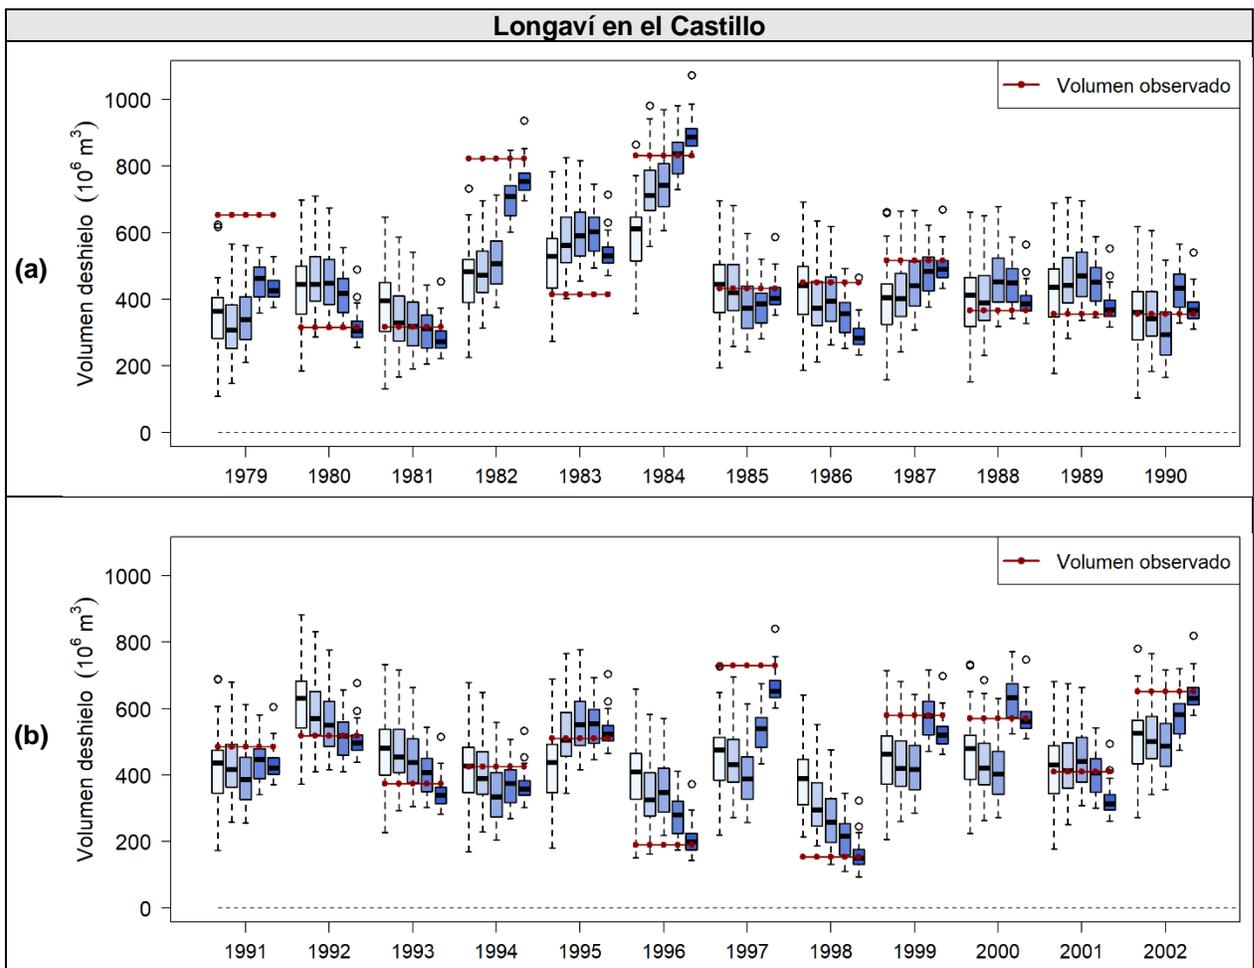


Figura 5.14 Volúmenes de deshielo, para distintos tiempos de inicialización. Cuenca: Longaví en el Castillo.

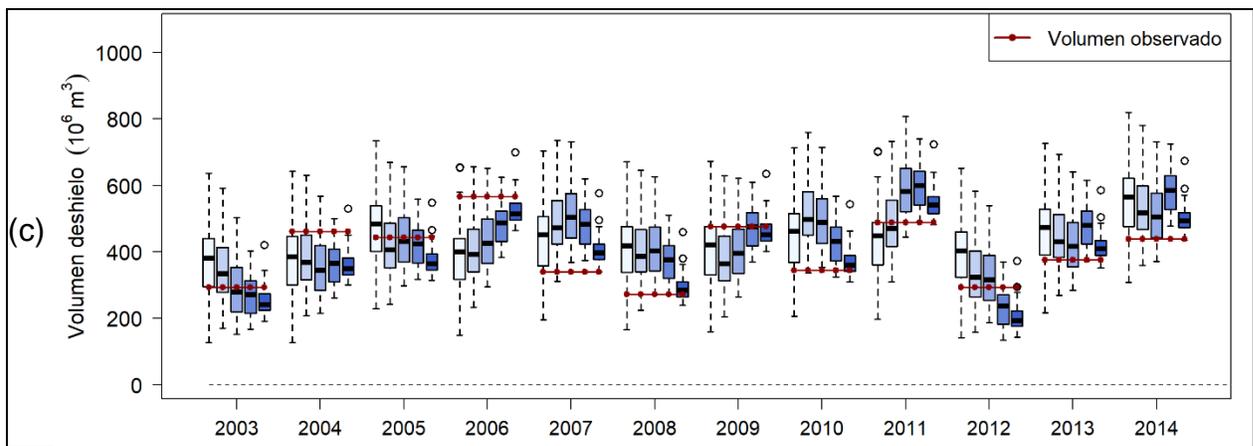


Figura 5.14 Volúmenes de deshielo, para distintos tiempos de inicialización. Cuenca: Longaví en el Castillo.

Longaví en el Castillo

En la Figura 5.13 se aprecia que la observación tiende a caer fuera de la caja (1° y 3° cuartil); sólo en 15 de los 36 años la observación se encuentra dentro. Existen años en que la observación se encuentra incluso fuera de los valores máximo y mínimo (o “corchetes”, en adelante “valores máx-mín”). Estos casos (por ejemplo, años 1979, 1982, 1996 o 1997) corresponden a años extremos en términos del SPI_{deshielo} (precipitación durante deshielo). Ya que el año es extremo (seco o húmedo), el conjunto de forzantes históricas no es representativo. Este hecho, sumado al error del modelo podría explicar esta situación.

En la Figura 5.14 se aprecia el comportamiento del conjunto a medida que el tiempo de inicialización avanza. En general, se observa cómo la incertidumbre (proveniente de la metodología) se reduce con el paso de los meses, sin embargo, el conjunto no necesariamente se acerca a la observación. Es interesante lo que ocurre entre los tiempos de inicialización 1 de julio y 1 de septiembre (1° y 3° caja, respectivamente) donde la incertidumbre sólo se ve reducida en los valores máx-mín manteniendo prácticamente igual el largo intercuartílico (largo de la caja). Entre estos meses, además, gran parte de los años se aleja de la observación u oscila.

Esta situación cambia tras la observación de septiembre. Durante el paso del tiempo de inicialización 1 de septiembre al 1 de octubre (3° y 4° caja, respectivamente) se reduce notoriamente la incertidumbre y en la mayoría de los años, el conjunto se acerca a la observación. Esto se relaciona directamente con la observación de septiembre (que en promedio representa el 28% del volumen total de deshielo, pero que varía entre el 15% y 50%). Por una parte, al observar septiembre, la incertidumbre estará asociada sólo a 6 meses (en vez de los 7 originales). Pero también podría deberse a que efectivamente septiembre tiene asociada una incertidumbre mayor que los otros meses. Esto podría relacionarse con la variable que es la precipitación durante este mes (Figura 5.15).

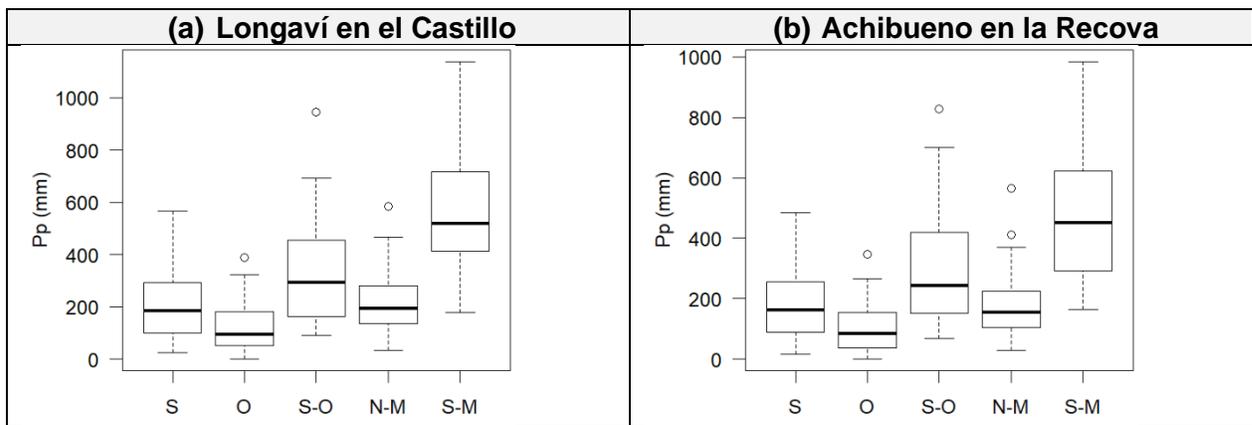


Figura 5.15 Precipitación media mensual agrupada entre septiembre-octubre (S-O), noviembre-marzo (N-M) y septiembre-marzo (S-M).

Por otra parte, para el último tiempo de inicialización (1 de noviembre), en que se cuenta con la observación de septiembre y octubre, en la mayoría de los años la observación se encuentra bajo el 1° cuartil o sobre el 3°. Incluso en algunos casos la observación se escapa de los valores máx-mín. Durante estos meses (noviembre-marzo) la precipitación es menor que en septiembre y octubre (representa en promedio el 40% versus el 60%) y no es tan variable (Figura 5.15). Esto, sumado al hecho de que son menos los meses simulados, explica que el rango de caudales simulados también sea acotado (ver la disminución del largo intercuartílico al pasar de la penúltima a la última caja en la Figura 5.14).

Considerando que la condición inicial no es perfecta, era esperable que en esta fecha (1 de noviembre) el pronóstico se acercara a la observación, pero no que necesariamente fuese contenido dentro del largo intercuartílico.

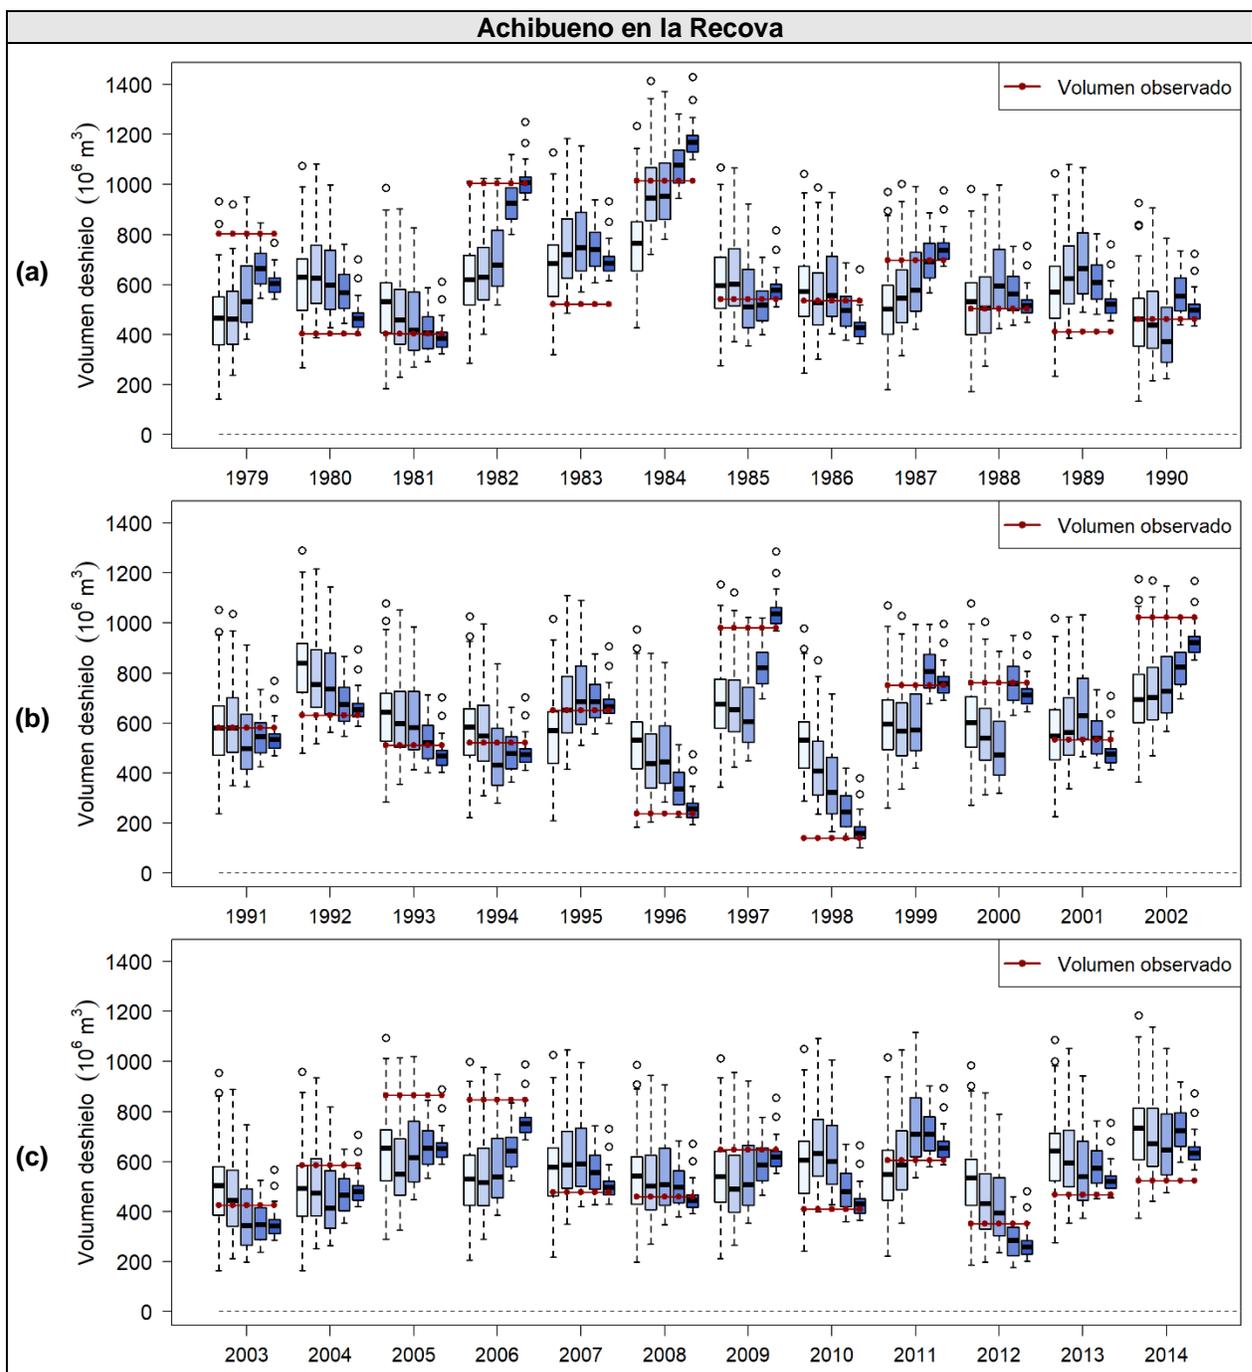


Figura 5.16 Volúmenes de deshielo, para distintos tiempos de inicialización. Cuenca: Achibueno en la Recova.

Achibueno en La Recova

Los resultados (Figura 5.13.b) muestran que el comportamiento del conjunto en Achibueno en la Recova es bastante similar a lo que ocurre en Longaví en el Castillo. Sin embargo, en esta cuenca (y tiempo de inicialización 1 de septiembre) existen menos casos en que la observación se escapa de los valores máximo y mínimo (como ocurría en 1979 o 1982 en Longaví en el Castillo, por ejemplo).

En relación con el avance en el tiempo de inicialización (Figura 5.16) se repiten algunas apreciaciones hechas para Longaví en el Castillo. La incertidumbre tiende a mantenerse constante entre la inicialización en julio y septiembre, situación que cambia cuando se inicializa en octubre.

Al igual que en Longaví, para la inicialización en noviembre, la observación tiende a escaparse del rango comprendido entre el 1° y 3° cuartil.

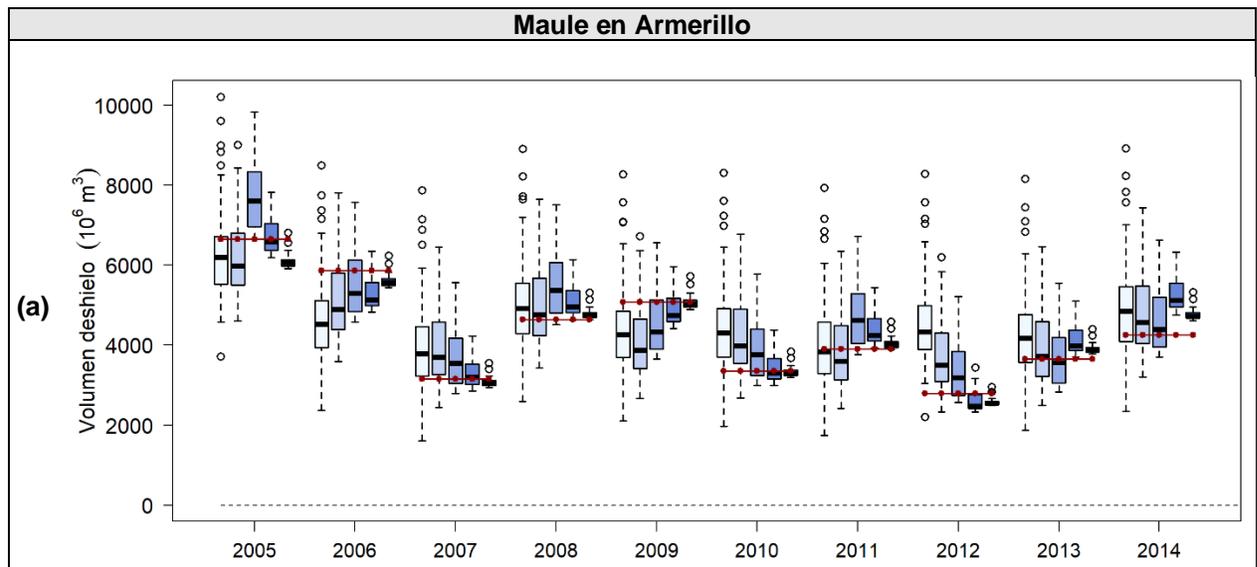


Figura 5.17 Volúmenes de deshielo, para distintos tiempos de inicialización. Cuenca: Maule en Armerillo.

Maule en Armerillo

En esta cuenca (Figura 5.17) se observa que en general, entre la 1° y 2° inicialización, desaparecen los puntos atípicos (es decir, *outliers*). Sin embargo, el largo intercuartílico tiende a aumentar levemente. En la mayoría de los años, a medida que avanza el tiempo de inicialización (entre julio y septiembre), el conjunto se acerca a la observación.

La observación de septiembre (al inicializar en octubre) reduce significativamente el largo intercuartílico (y el rango de valores máx-mín), sin embargo, la observación tiende a caer fuera de los límites del 1° u 3° cuartil.

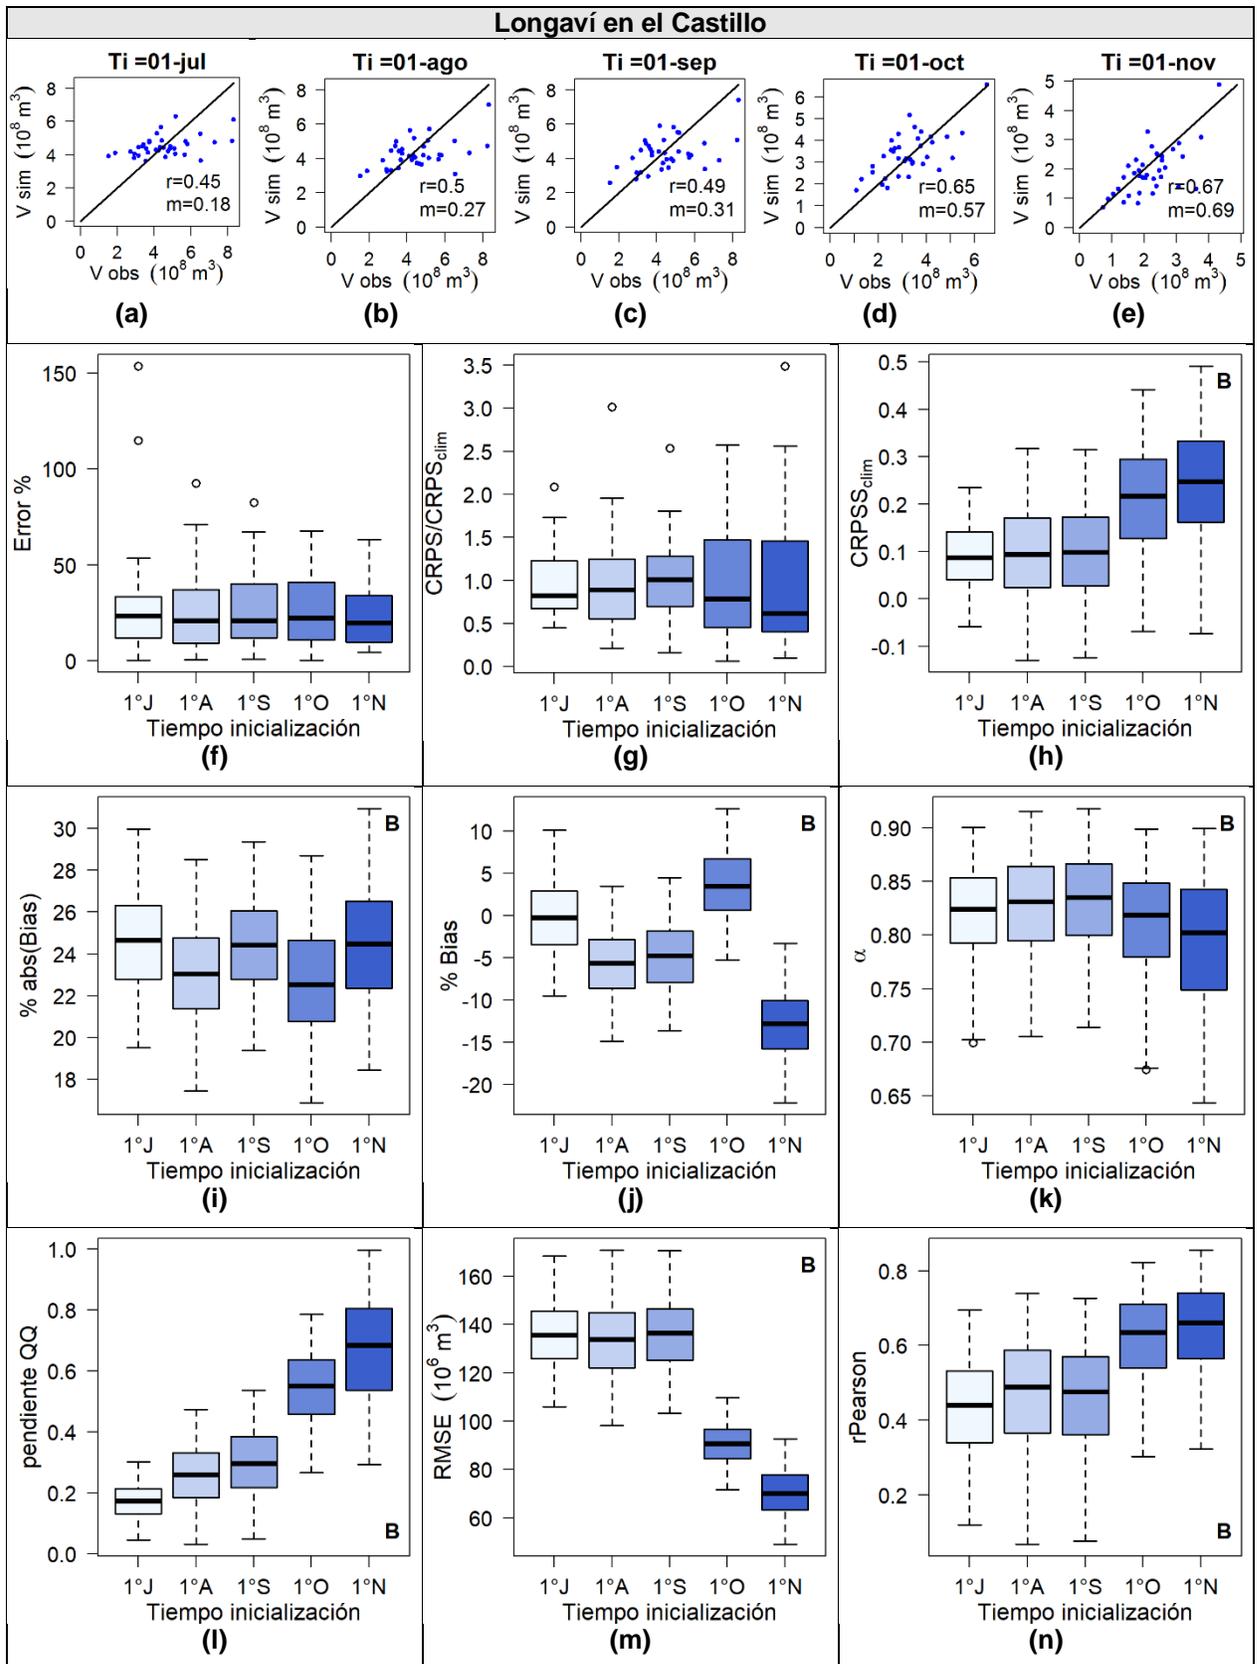
Lamentablemente, para esta cuenca sólo se cuenta con observaciones (de caudal) en años similares en términos de precipitaciones, por lo que no se puede concluir acerca del comportamiento del conjunto bajo condiciones diferentes.

Las siguientes figuras (Figura 5.18 para Longaví en el Castillo y Figura 5.19 para Achibueno en la Recova) presentan una serie de métricas e índices orientados a evaluar distintos atributos del pronóstico en cada cuenca.

Cada figura cuenta con:

- (a)-(e): correlación entre el volumen observado y pronosticado (mediana del conjunto) en los distintos tiempos de inicialización, donde además del coeficiente de correlación de Pearson r se presenta la pendiente m del ajuste lineal.
- (f): Error porcentual del volumen pronosticado, donde cada valor del boxplot es el error porcentual del pronóstico (mediana del conjunto) de un año.
- (g): Razón entre el error probabilístico del pronóstico (CDF miembros) y el error probabilístico de la meteorología histórica (CDF volúmenes históricos), donde cada valor del boxplot es el dato de un año.
- (h)-(n): Serie de métricas descritas en la Tabla 4.2, donde cada valor del boxplot fue obtenido realizando Bootstrapping (denotado por una **B** dentro de cada gráfico). Es decir, a diferencia de las figuras (f) y (g), estas métricas contienen información **agrupada** de la serie de pronósticos. Es decir, cada punto del boxplot **no** corresponde a un año.

Para Maule en Armerillo sólo se graficaron métricas por año (error porcentual y CRPS/CRPS_{clim}). No se realizó *bootstrapping* con métricas asociadas a la serie de pronósticos. Esto se decidió así a causa del tamaño reducido de la muestra (10 años con pronóstico, entre 2005-2014). No obstante, se determinaron algunas métricas de la serie de pronóstico como CRPSS_{clim} o índice de confiabilidad α , entre otros, sin *bootstrapping*, es decir, utilizando una única serie de pronósticos y observaciones (“serie real”).



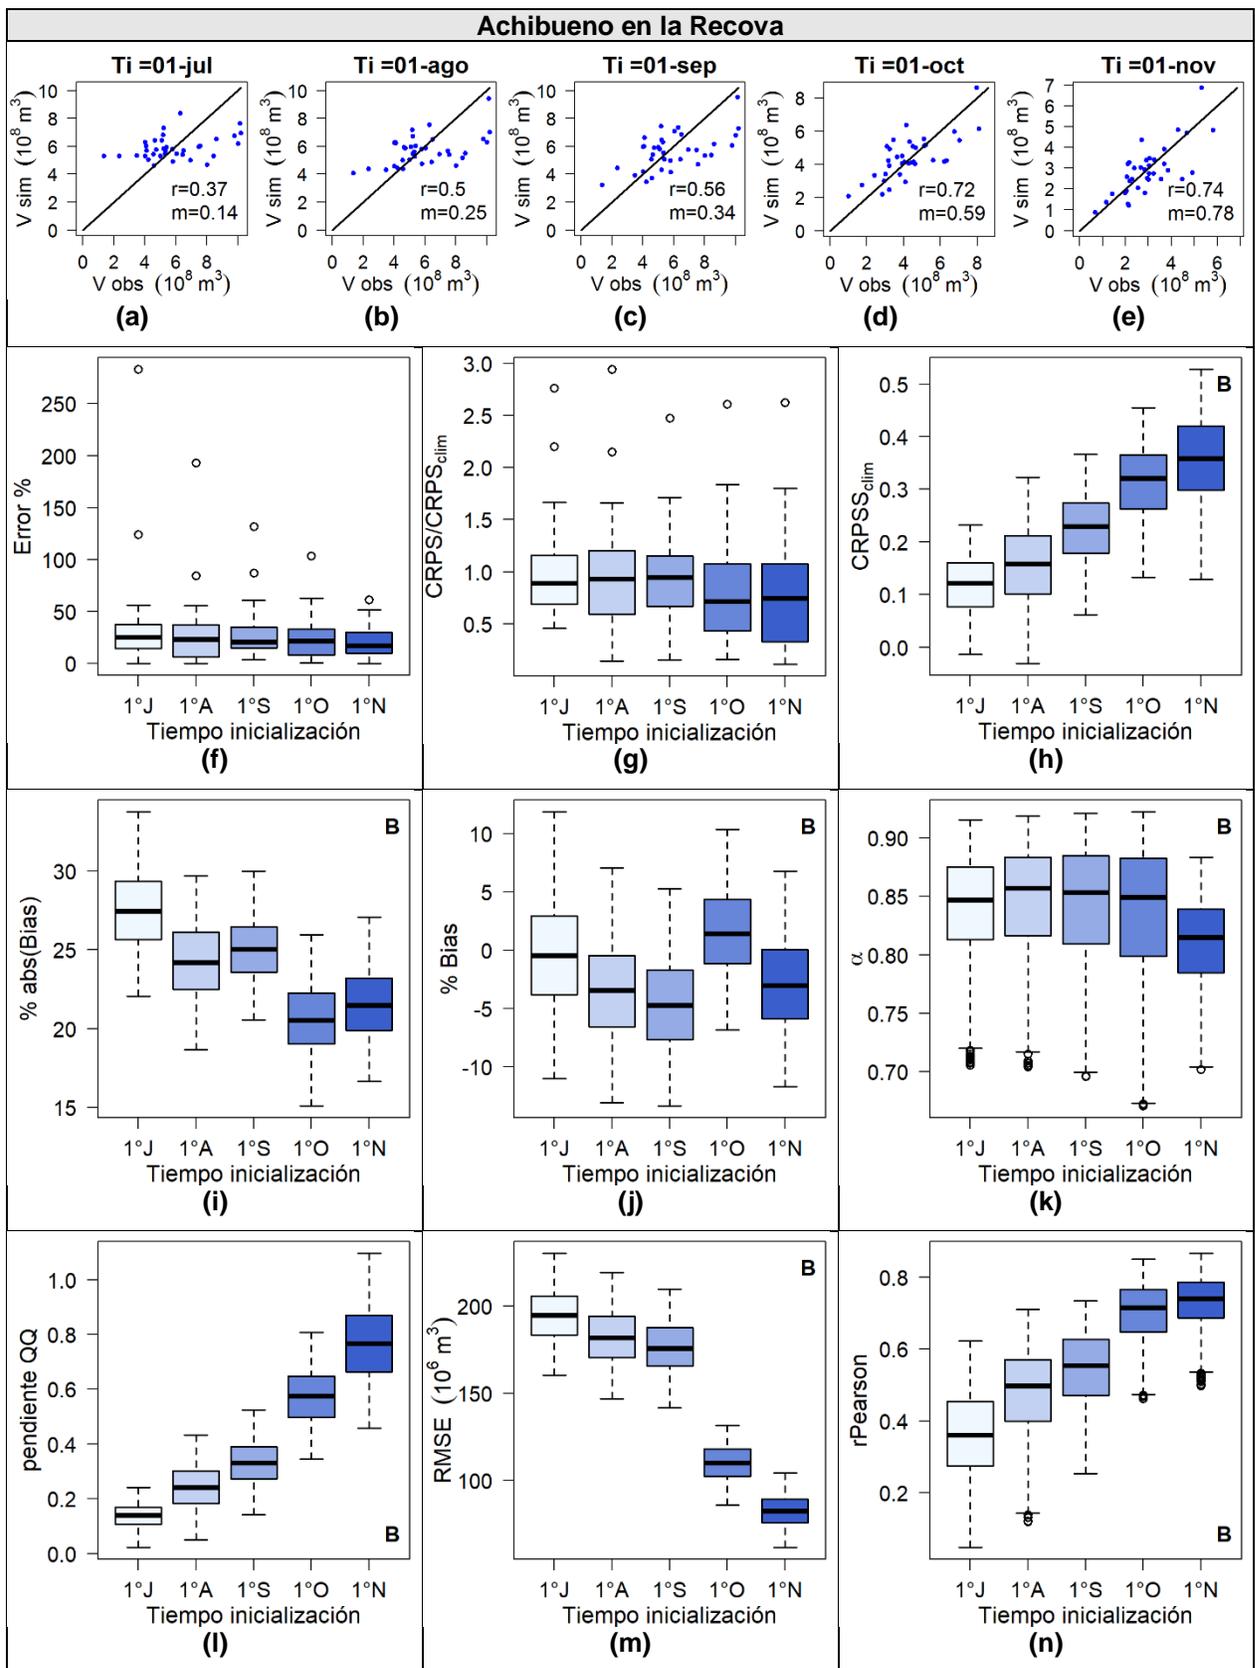


Figura 5.19 Métricas evaluación pronóstico en Achibueno en la Recova.

Longaví en el Castillo

La correlación y pendiente en los gráficos (a)-(e) de la Figura 5.18 muestran que el volumen pronosticado no parece mejorar entre el 1° y el 3° tiempo de inicialización; la correlación prácticamente no cambia y la pendiente de la recta aumenta levemente. Al observar septiembre, tanto r como m mejoran.

En la Figura 5.18.f se observa como el error porcentual del pronóstico sólo disminuye en los valores altos, que corresponden a años muy secos o muy húmedos en términos de caudal. Para los años normales el error incluso aumenta al llegar al tiempo de inicialización 1 de septiembre (puntos se alejan de la recta 1:1 en la Figura 5.18.c).

La Figura 5.18.g muestra que, si la razón graficada es menor a 1, en términos probabilísticos, es mejor utilizar ESP que la distribución histórica del volumen estacional. Como se observa, en términos probabilísticos pareciera mejor realizar el pronóstico en julio que en septiembre.

Las siguientes figuras (Figura 5.18.h-Figura 5.18.n) muestran indicadores del rendimiento histórico del pronóstico, donde en general, se aprecia la considerable mejora tras la observación de septiembre (esperable, tras observar el comportamiento del pronóstico). El único indicador que baja su calidad tras observar septiembre es el índice de confiabilidad α .

En relación con el %Bias, se observa que al pasar de septiembre a octubre este índice se acerca a 0. Es decir, al inicializar en septiembre existía un sesgo negativo en la serie de pronósticos, asociada principalmente al peso del error que aportaban los años con un volumen de deshielo mayor que disminuye al inicializar en octubre (puntos con volumen alto se acercan a la recta 1:1).

Achibueno en la Recova

El comportamiento de los indicadores para esta cuenca (Figura 5.19) se asemeja bastante a lo observado para Longaví. En este caso, algunos indicadores muestran una leve mejora entre la inicialización entre julio y septiembre, básicamente porque en julio la predictibilidad en Achibueno es menor que la observada para Longaví.

No obstante, nuevamente el cambio más significativo ocurre tras la observación de septiembre. En la Figura 5.19.g, por ejemplo, se observa que, entre las inicializaciones en julio y septiembre, sólo en la mitad de los años es mejor utilizar ESP (en términos de error probabilístico). Inicializando en octubre en cambio, al menos en $\frac{3}{4}$ de los años el error probabilístico con ESP es menor que utilizando la climatología histórica. Es importante notar que el cociente graficado sólo dice qué metodología entrega el menor error (ESP o clima promedio) pero no dice nada del error absoluto.

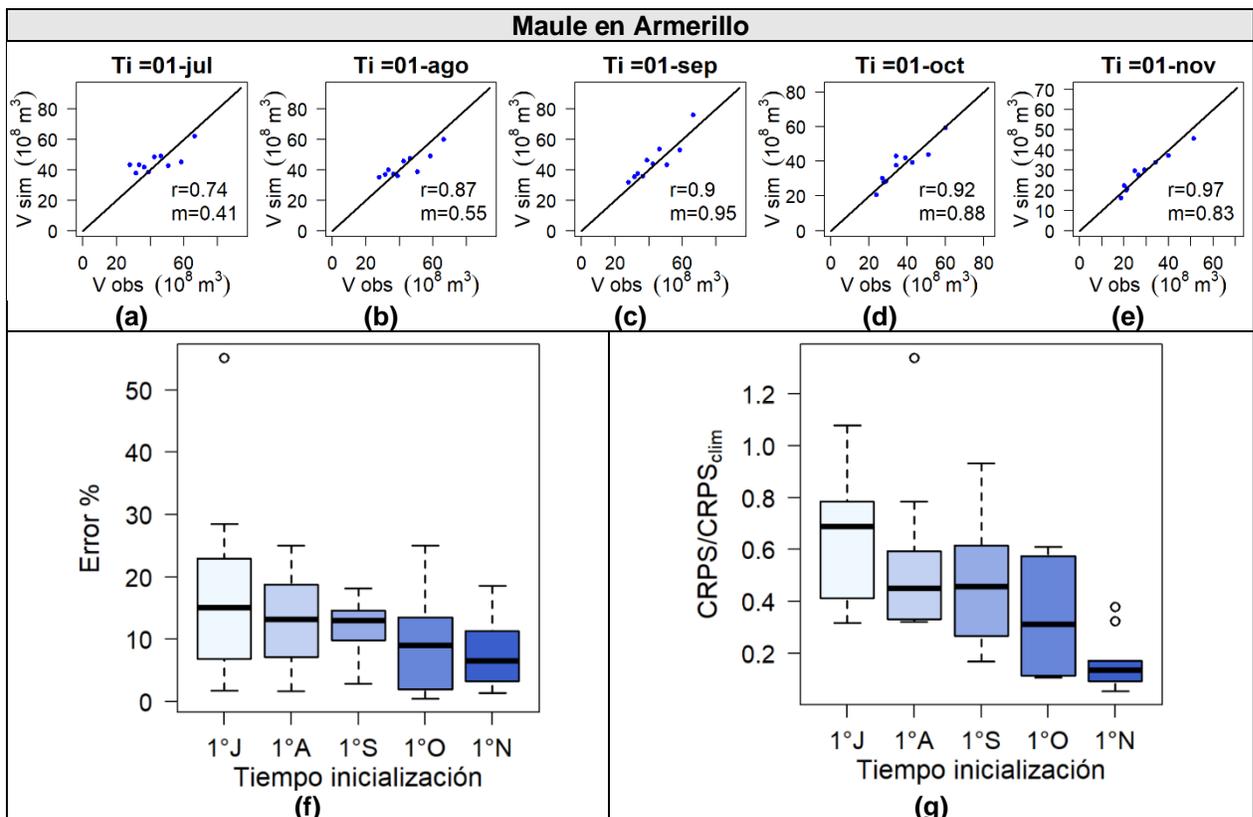


Figura 5.20 Errores pronóstico Maule en Armerillo.

Tabla 5.4 Métricas serie de pronósticos en Maule en Armerillo.

Métrica serie de pronósticos	1°J	1°A	1°S	1°O	1°N
RMSE ($10^6 m^3$)	838	648	575	426	282
CRPS _{clim}	0,38	0,52	0,61	0,73	0,83
α	0,38	0,40	0,39	0,27	0,19
%Bias	4,1	-1,9	5,3	0,8	-1,7
%abs(Bias)	16,5	12,6	11,8	9,1	7,8

Maule en Armerillo

A diferencia de las otras cuencas, en Maule se observa una mayor correlación y pendiente QQ más cercana a 1 en los primeros tiempos de inicialización; en agosto por ejemplo, $r=0,87$ y $m=0,55$, mientras que en Achibueno $r=0,5$ y $m=0,25$. El error porcentual es inferior a las otras cuencas en todos los tiempos de inicialización y disminuye entre $ti=julio$ y $ti=septiembre$, hecho que no ocurría en Longaví o Achibueno. También se observa un mejoramiento de las métricas de la serie de pronóstico con el aumento del tiempo de inicialización. La razón $CRPS/CRPS_{clim}$ se encuentra bajo 1 casi en todos los casos, es decir, en la mayoría de los años y tiempos de inicialización el error probabilístico del ESP es inferior al error de utilizar la serie de volúmenes históricos como pronóstico.

Se presenta la Figura 5.19 como una síntesis del error porcentual obtenido para los tiempos de inicialización 1 de julio – 1 de septiembre (no se grafican los otros tiempos debido a que el volumen abarca menos meses), comparado con el error que se obtendría al utilizar la mediana de volúmenes históricos como pronóstico y con el error de la

modelación al simular el volumen con las forzantes observadas para el año. En todos los boxplots el número de años es 10 (2005-2014).

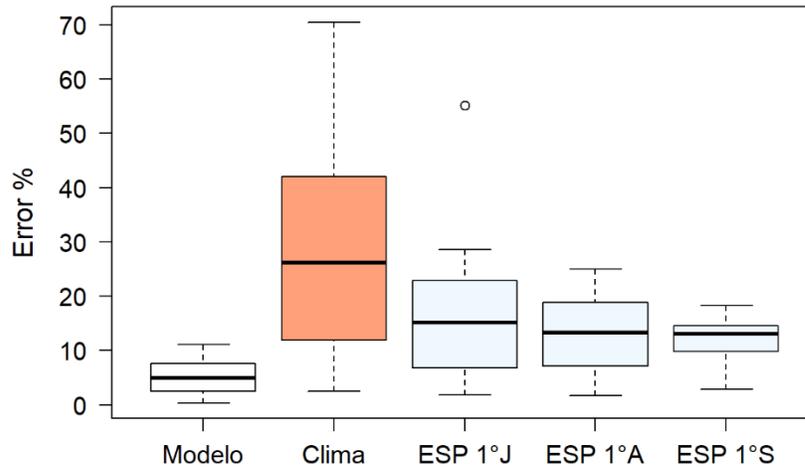


Figura 5.21 Resumen error porcentual pronóstico en Maule en Armerillo.

“Modelo” corresponde al error del volumen al forzar el modelo con las forzantes de año, “Clima” es el error de utilizar la serie histórica como pronóstico y ESP+ti corresponde al error de aplicar ESP como metodología de pronóstico.

5.3 Post procesamiento

En la Tabla 5.5 y Tabla 5.6 se presenta la correlación entre el MEI y el ONI durante los meses previos a cada inicialización y el SPI (Standard Precipitation Index) durante los meses de deshielo. En el ANEXO E se encuentran los gráficos correspondientes a cada tabla.

Tabla 5.5 Correlación entre MEI y SPI durante meses de deshielo. *En el caso de $Ti=1$ de octubre la correlación se realiza con el SPI durante los meses octubre-marzo, para $Ti=1$ de noviembre, se usa el SPI entre noviembre-marzo.

Cuenca	Coeficiente de correlación de Pearson				
	1° julio	1° agosto	1° septiembre	1° octubre*	1° noviembre*
Longaví	-0,12	0,2	0,49	0,57	0,29
Achibueno	-0,11	0,22	0,5	0,57	0,28

Tabla 5.6 Correlación entre ONI y SPI durante meses de deshielo. *En el caso de $Ti=1$ de octubre la correlación se realiza con el SPI durante los meses octubre-marzo, para $Ti=1$ de noviembre, se usa el SPI entre noviembre-marzo.

Cuenca	Coeficiente de correlación de Pearson				
	1° julio	1° agosto	1° septiembre	1° octubre*	1° noviembre*
Longaví	0,11	0,3	0,47	0,55	0,25
Achibueno	0,13	0,32	0,48	0,55	0,26

Se decidió usar parámetros constantes (α y λ) para cada tiempo de inicialización (no se observó una mejora al utilizar parámetros variables). Además, para cada tiempo de inicialización se escogió entre utilizar sólo MEI como predictor o ambos (MEI y ONI) (Tabla 5.7).

Tabla 5.7: índices escogidos para cada tiempo de inicialización y cuenca.

Cuenca	Índice utilizado				
	1° julio	1° agosto	1° septiembre	1° octubre*	1° noviembre*
Longaví	MEI+ONI	MEI+ONI	MEI	MEI	MEI+ONI
Achibueno	MEI+ONI	MEI+ONI	MEI	MEI	MEI+ONI

Tras realizar la asignación de pesos, se obtienen los conjuntos presentados (en color celeste) en la Figura 5.22. Además, se presenta el boxplot del conjunto original (blanco) y las observaciones (rojo). Para los demás tiempos de inicialización, ver el ANEXO F.

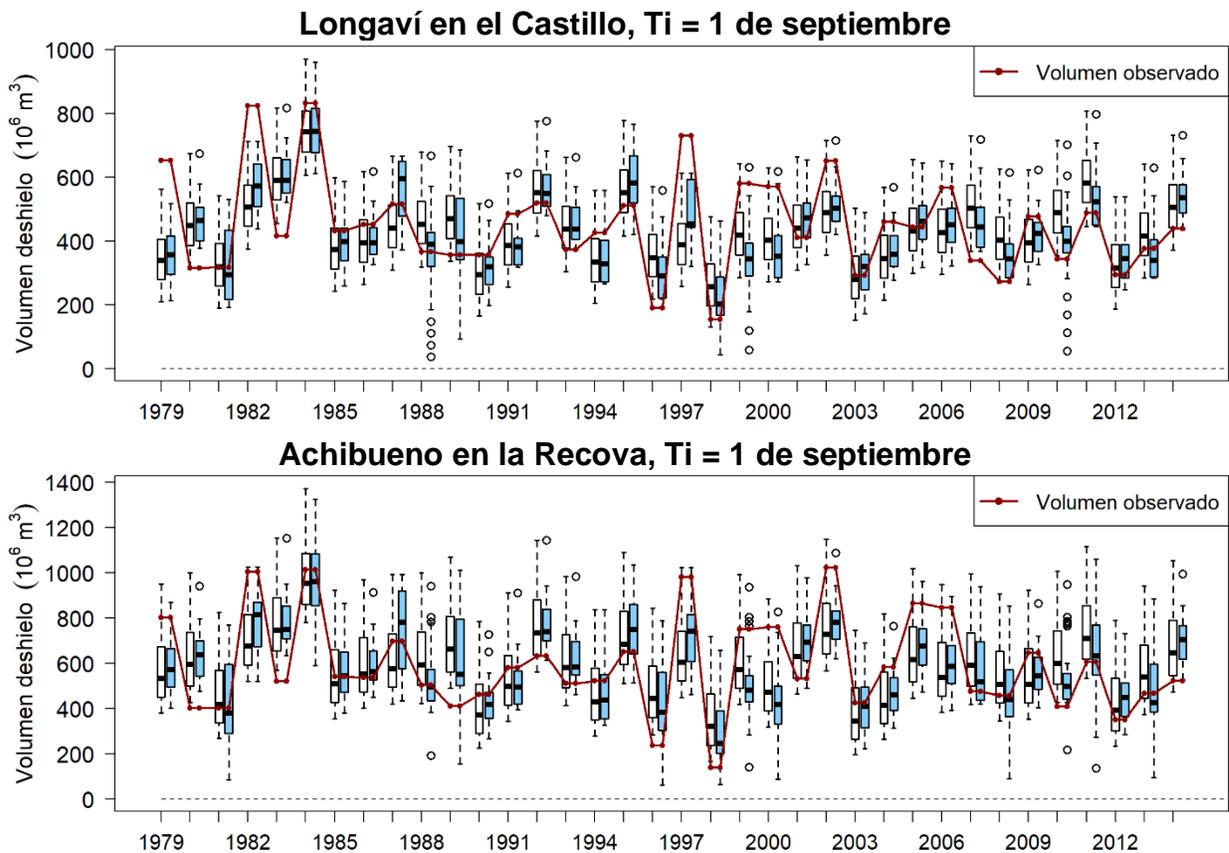


Figura 5.22 Boxplot de conjuntos antes (sin color) y después (celeste) de la asignación de pesos. Tiempo de inicialización = 1 de septiembre.

En la Figura 5.22 se observa que el post procesamiento en ambas cuencas, acerca el boxplot a la observación en la mayoría de los años. Sin embargo, hay algunos años que se ven perjudicados y que se repiten en ambas cuencas, por ejemplo, los años 1999, 2000 o 2014. En estos años, es mejor utilizar el conjunto original que el conjunto modificado por la asignación de pesos.

Nuevamente se calculan las métricas de evaluación para comparar el desempeño del conjunto modificado con respecto al original. La Figura 5.23 y Figura 5.24 presentan estas métricas, donde el color celeste simboliza el post procesamiento.

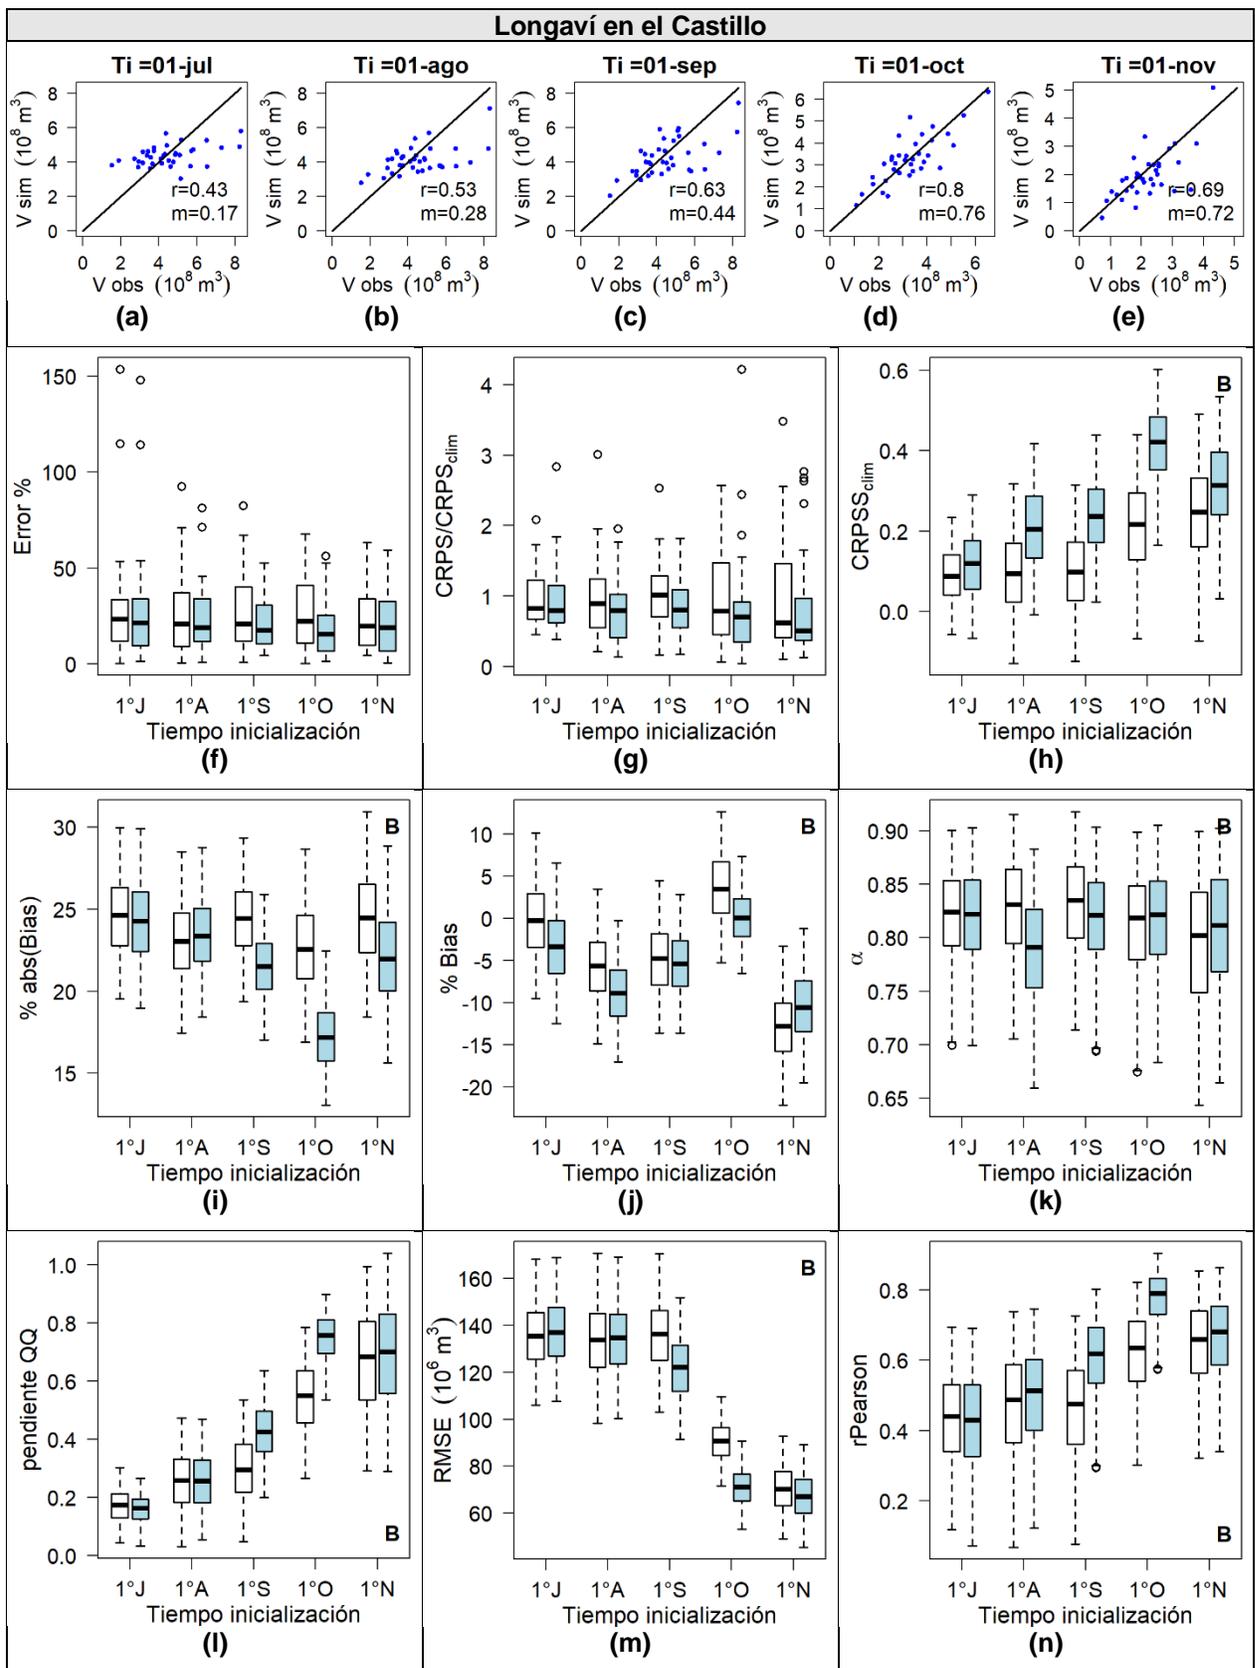


Figura 5.23 Métricas evaluación pronóstico en Longaví en el Castillo antes y después del post-procesamiento.

Longaví en el Castillo

Al comparar las Figura 5.23.a-Figura 5.23.e con sus análogas de la Figura 5.18 (ESP sin procesar), se observa que en todas las inicializaciones la correlación entre volumen total observado y pronosticado mejora.

La mejora en la inicialización de julio y agosto es bastante débil, básicamente porque durante esas fechas poco se sabe del tipo de forzantes que son similares a las de ese año (correlación con MEI y/o ONI). En septiembre en cambio, la mejora ya es un poco más significativa. Sin embargo, la inicialización que más se ve beneficiada con el post procesamiento es el 1 de octubre. Esto coincide con el hecho de que la mayor correlación entre índice climático y precipitación futura ocurre en esta inicialización (Tabla 5.5).

El resto de los índices y/o métricas es consecuente con lo expuesto en el párrafo anterior. A continuación, se resumen algunas observaciones del efecto del procesamiento sobre los índices obtenidos para cada tiempo de inicialización.

Inicialización en julio: A pesar de que la correlación mostró una leve mejora, el resto de los índices se mantienen prácticamente iguales.

Inicialización en agosto: El error porcentual (Figura 5.23.f) disminuye levemente en el valor del 3° cuartil y de los valores máx-mín, sin embargo, la mediana se mantiene prácticamente igual. Varios índices se mantienen muy similares a la situación sin procesamiento (por ejemplo, RMSE, rPearson, CRPS/CRPS_{clim}, etc) mientras que otros se alejan levemente de su valor ideal (α y %Bias). El índice que más se beneficia es el CRPSS_{clim} que pasa a estar sobre cero para todos los puntos obtenidos con bootstrapping.

Inicialización en septiembre: Mejoran todos los índices de forma considerable, a excepción de α que disminuye levemente y %Bias, que se mantiene constante.

Inicialización en octubre: Todos los índices mejoran de forma significativa (sólo α mejora levemente). El error porcentual del pronóstico baja en sus valores máx-mín, límites de cuartiles y mediana. A la vez, el CRPSS_{clim} aumenta el valor de su mediana casi al doble (pasa de 0,22 a 0,42) Es importante recordar que para esta fecha (y para noviembre) se evalúan las métricas con respecto al volumen restante, por lo tanto, el RMSE no debe ser comparado directamente con el RMSE de los meses anteriores.

Inicialización en noviembre: Los índices mejoran levemente con respecto a la situación sin procesamiento. Aun así, poseen valores inferiores (en términos del valor ideal) que los índices obtenidos al inicializar en octubre. Esto se debe a que gran parte de la correlación entre la precipitación durante el deshielo y el MEI de los meses anteriores se debía a la precipitación de octubre. De hecho, al calcular la correlación entre precipitación mensual y los índices climáticos (MEI y/o ONI), se obtiene que los últimos meses (diciembre-marzo) prácticamente no muestran correlación.

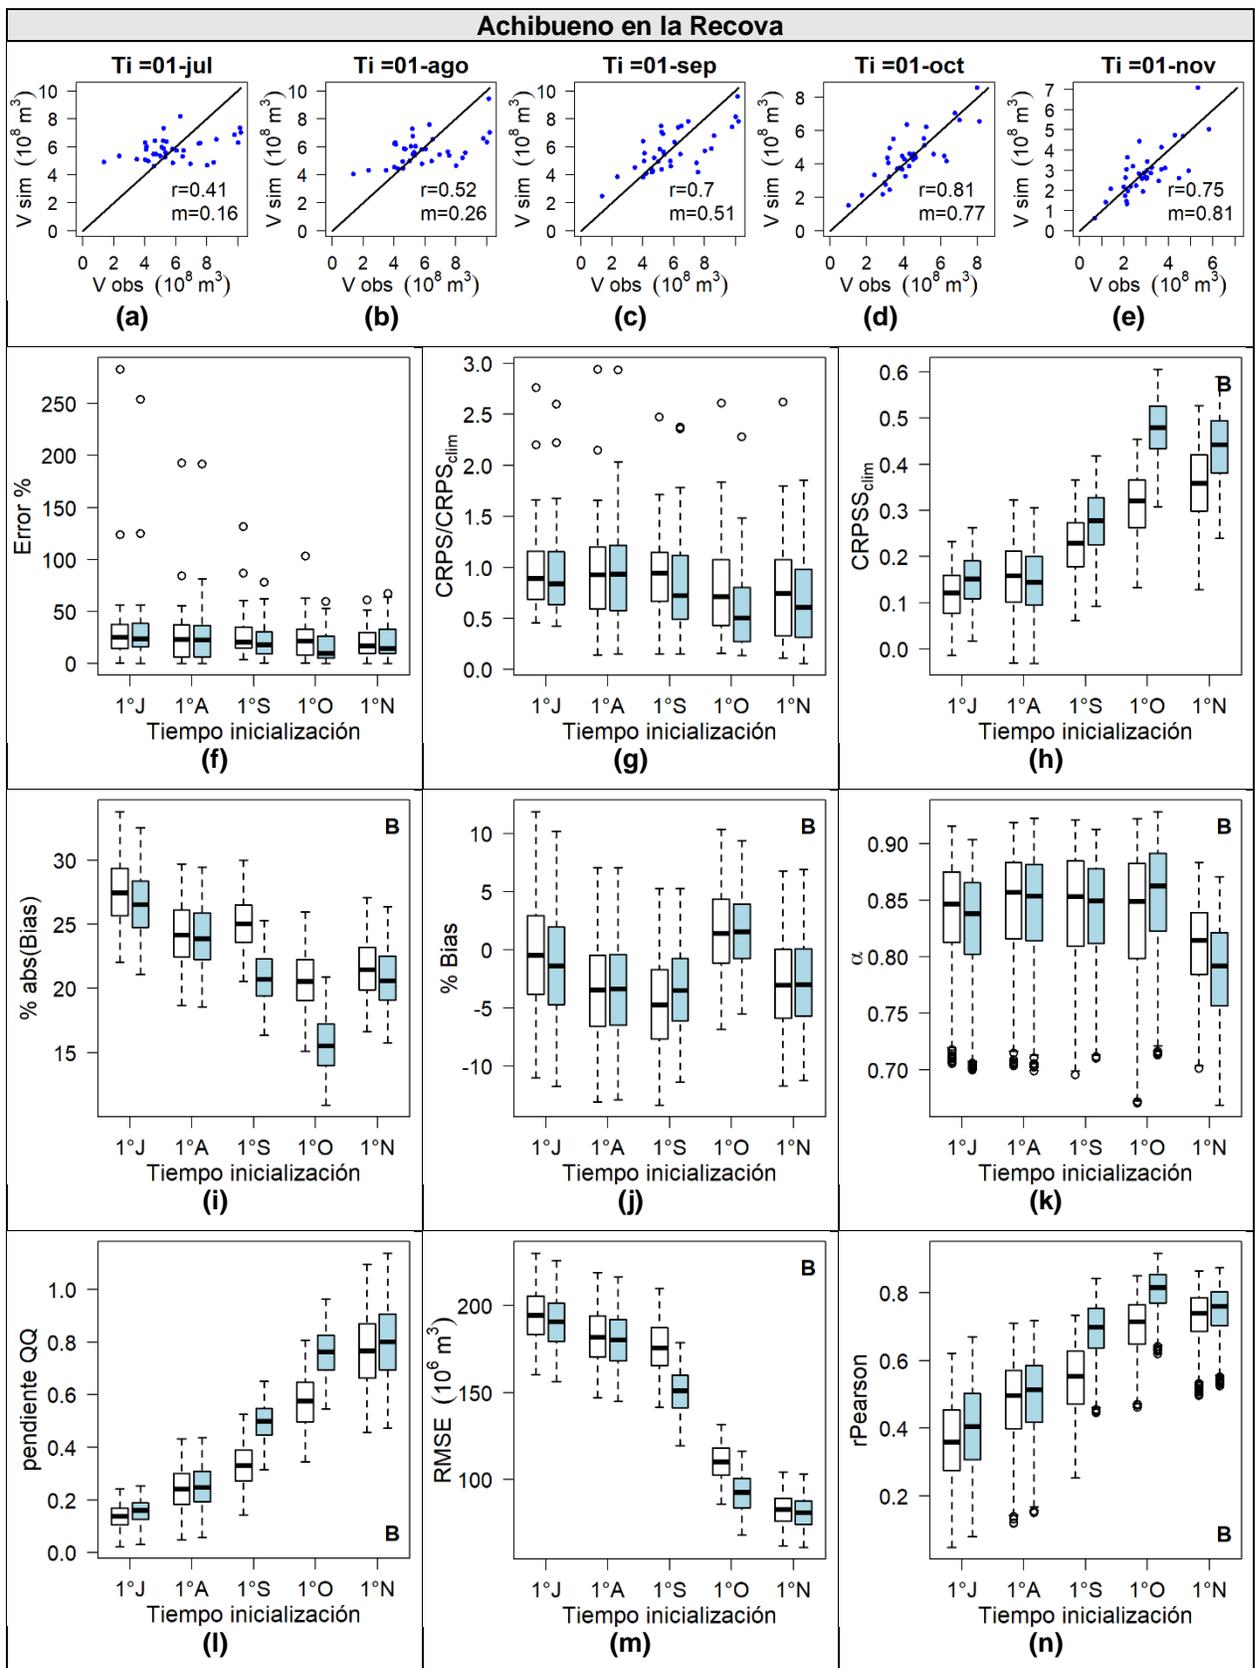


Figura 5.24 Métricas evaluación pronóstico en Achibueno en la Recova antes y después del post-procesamiento.

Achibueno en la Recova

Gran parte de las observaciones hechas para Longaví se repiten en esta cuenca. Mientras que entre julio y agosto los índices casi no son afectados por el procesamiento, en septiembre recién se observa una mejora. En este mes (septiembre) el error porcentual (Figura 5.24.f) disminuye en los valores máx-mín y límites del 1° y 3° cuartil, sin embargo, la mediana permanece constante. A excepción de α , que casi no varía, todos los demás índices mejoran.

Al igual que en Longaví, octubre es la inicialización que más se beneficia con el procesamiento. La mediana del error porcentual pasa de **21%** a **10%** mientras que el límite del 3° cuartil lo hace de **33%** a **26%**. Por otra parte, el CRPSS_{clim} es uno de los límites que más aumenta, la mediana pasa de **0,32** a **0,48**. El resto de los índices también exhiben mejoras.

En noviembre, el procesamiento sólo mejora algunos índices (correlación o CRPSS_{clim}). Algunos índices se ven disminuidos en relación con su cercanía con el valor ideal, como por ejemplo el error porcentual o α . De todas formas, es muy baja la variación entre la situación sin y con procesamiento.

5.4 Resumen Longaví y Achibueno

A modo de resumen, los siguientes gráficos (Figura 5.25-Figura 5.28) muestran el error porcentual de la mediana del conjunto y el error probabilístico (CRPS) de la CDF del conjunto normalizado por el volumen observado, para cada año. Esto se realiza con el fin de resumir una métrica determinista y una probabilística, y no perder información de cada año, como ocurre al usar métricas promedio de la serie de pronósticos (correlación, por ejemplo).

Estas métricas se presentan para los siguientes casos:

- Pronóstico utilizando la serie de volúmenes histórica como pronóstico
- Pronóstico usando ESP tradicional, es decir un conjunto de 35 miembros equiprobables
- Pronóstico usando ESP más procesamiento, es decir, un conjunto modificado a través de la asignación de pesos basada en índices climáticos

En el caso del error porcentual, también se presenta el error de la simulación realizada con forzantes observadas (como referente del error de la modelación).

Estos errores fueron graficados para el tiempo de inicialización 1 de septiembre y 1 de octubre. En los siguientes gráficos no se visualizan algunos valores atípicos del boxplot, para no distorsionar el gráfico. No obstante, bajo cada gráfico se presenta el valor máximo (además de otros estadísticos). En el ANEXO G se encuentran estos gráficos incluyendo valores atípicos.

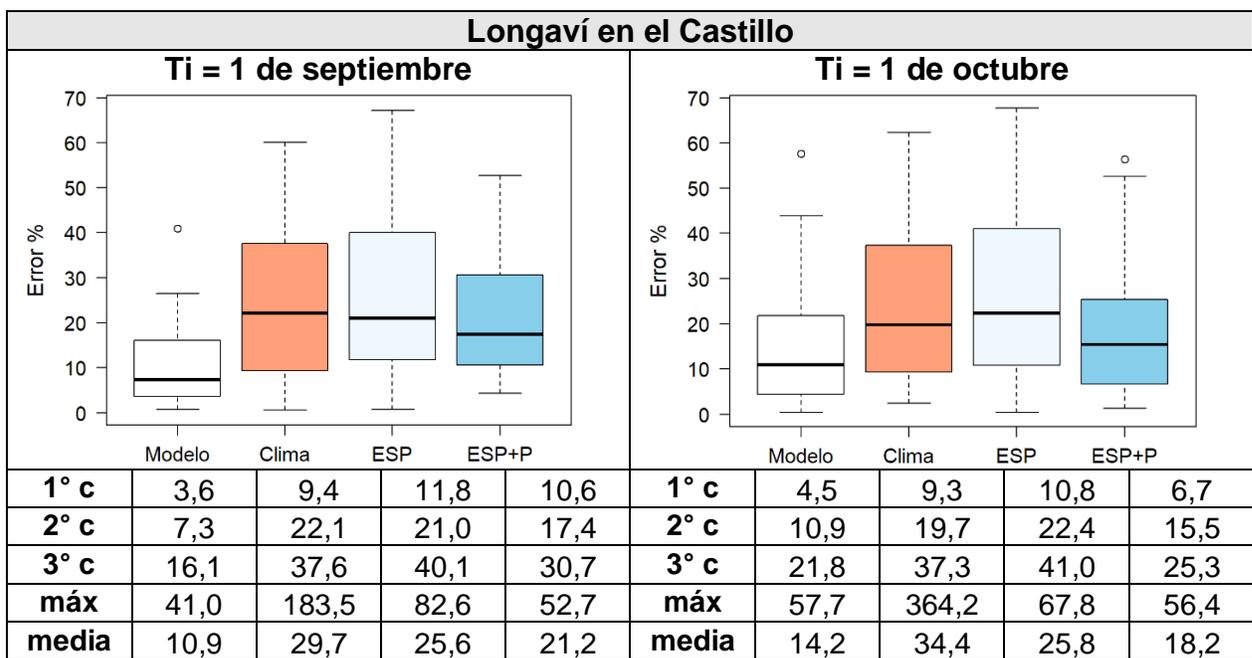


Figura 5.25 Resumen error porcentual por año, Longaví en el Castillo.

En la Figura 5.25 se observa que utilizar ESP tradicional en Longaví, inicializando en septiembre o en octubre, entrega un error comparable con usar la mediana histórica (“clima” en el gráfico) para pronosticar en cualquier año. De hecho, el error del ESP tradicional sólo disminuye los valores de los errores atípicos (*outliers*). Usar ESP más procesamiento en cambio, en ambas inicializaciones, entrega un error menor a utilizar la mediana histórica. Para la inicialización en octubre esta disminución es más evidente.

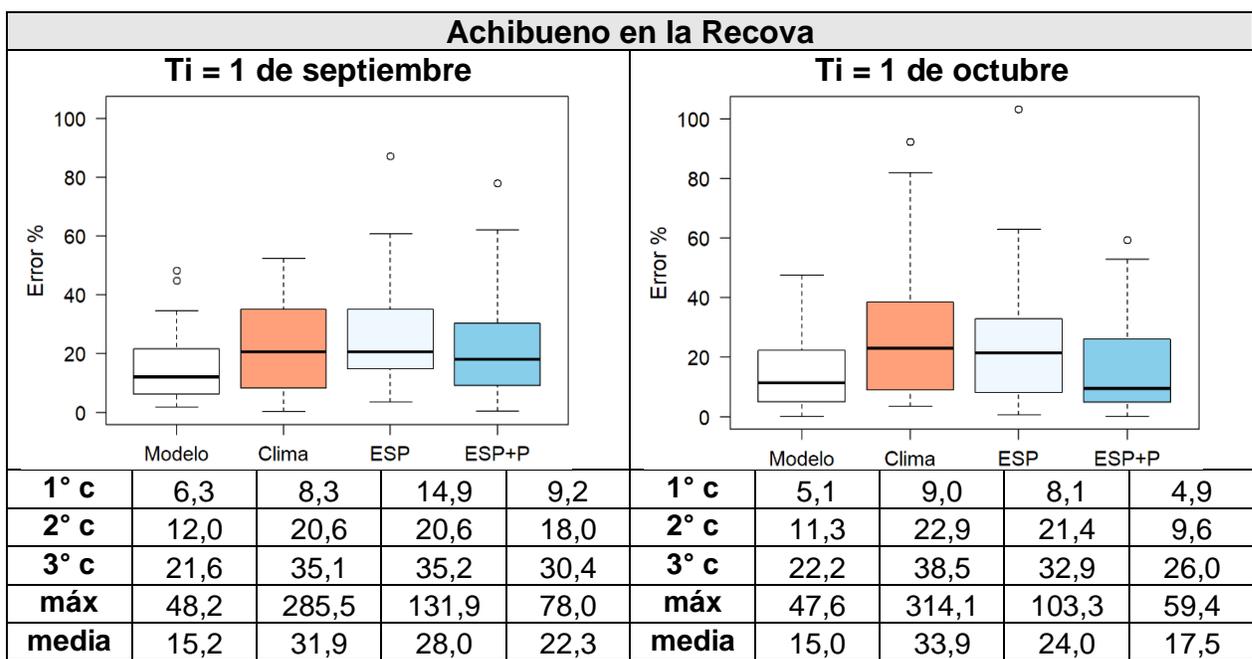


Figura 5.26 Resumen error porcentual por año, Achibueno en la Recova.

En Achibueno por otra parte, utilizar ESP tradicional sólo es mejor durante la inicialización en octubre. No obstante, el rango de errores es bastante similar. Al igual que en Longaví, el error promedio de utilizar la mediana histórica se ve perjudicado por los valores atípicos, que en el caso del ESP tradicional son disminuidos.

El post procesamiento es mucho más significativo en la inicialización de octubre, alcanzando un error promedio incluso cercano al error promedio del modelo (**17,5%** versus **15%**).

En términos probabilísticos (Figura 5.27 y Figura 5.28), coinciden algunas apreciaciones realizadas para el error determinista. En Longaví y ambas inicializaciones, el rango de errores obtenido al usar la distribución histórica y ESP tradicional es bastante similar; sólo se diferencia en una disminución de los errores altos, lo que repercute en un error promedio menor del ESP tradicional. El post procesamiento beneficia ambas inicializaciones reduciendo notoriamente los estadísticos.

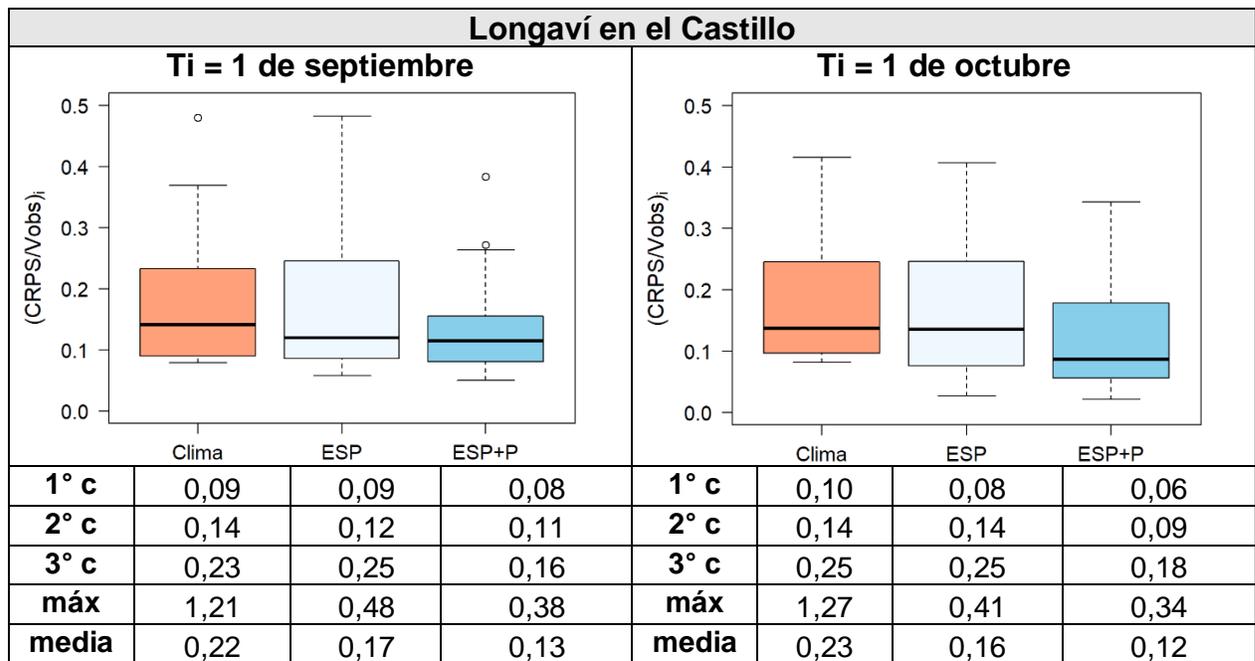


Figura 5.27 Resumen error probabilístico por año, normalizado por el volumen observado, Longaví en el Castillo.

Por otra parte, en Achibueno, se observa una leve disminución en ambas inicializaciones al utilizar el ESP tradicional en vez de la distribución histórica. El boxplot del ESP tradicional durante septiembre puede resultar un poco engañoso; al observar sus estadísticos con respecto a octubre, se aprecia que sólo el límite del 3° cuartil disminuye inicializando antes.

El procesamiento mejora el error probabilístico en ambas inicializaciones, no obstante, en octubre se observan mayores diferencias, disminuyendo los valores de todos los cuartiles. La mediana, por ejemplo, baja de 0,13 a 0,07.

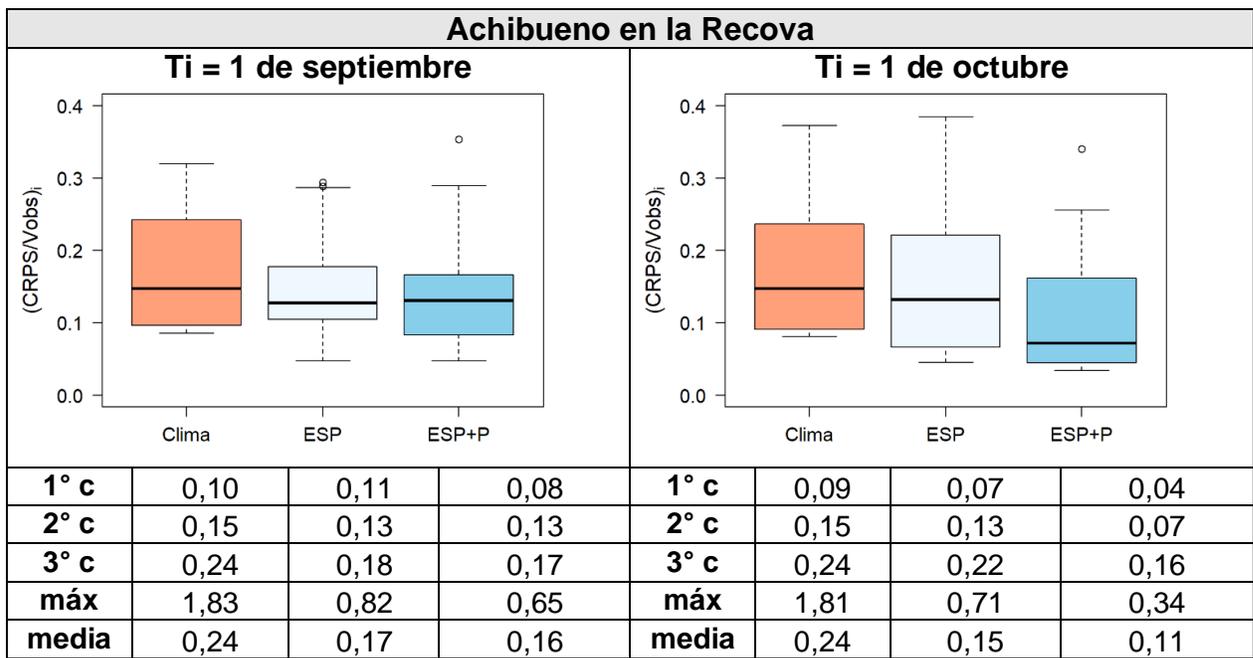


Figura 5.28 Resumen error probabilístico por año, normalizado por el volumen observado, Achibueno en la Recova.

6 CONCLUSIONES

6.1 Maule en Armerillo

La falta de registro y el carácter de este (caudales reconstruidos) no permite hacer conclusiones generalizadas.

Al contar con pocos años y además similares entre sí en términos de volumen, es difícil identificar si efectivamente el ESP tradicional es adecuado (a diferencia de las otras cuencas en que el registro es extenso). No obstante, tomando en cuenta los 10 años en que se aplicó la metodología y los años anteriores cuyos volúmenes observados varían considerablemente con respecto a la mediana histórica, es válido pensar que el ESP tradicional genera conjuntos similares debido a que los años también lo son y no porque la condición inicial tiene poco peso. Como es una cuenca nival, a diferencia de las otras, el volumen de deshielo se encuentra dominado por la condición inicial.

Sólo basándose en los años en que se aplicó la metodología, el ESP tradicional funcionaría mejor en esta cuenca que en Longaví o Achibueno.

6.2 Longaví y Achibueno

Las cuencas de Achibueno y Longaví, bastante similares en términos de sus regímenes hidrológicos, mostraron resultados similares en cuanto la modelación y posterior aplicación de ESP y post procesamiento. A pesar de que Achibueno entregó mejores resultados en la modelación (KGE e índices hidrológicos) que Longaví, esta última cuenca mostró un error menor en el cálculo del volumen total. Como fue mencionado en varias secciones de este trabajo, esto se debió a la compensación de sesgos positivos y negativos de los volúmenes mensuales, que en este caso fue más precisa. Este hecho no implica que el error mensual sea menor. En la Figura 5.3 y Figura 5.8 se observa que el error mensual es menor en Achibueno que en Longaví.

Aun cuando el modelo compensa los sesgos mensuales durante el deshielo, el error del volumen total para ambas cuencas es alto; en promedio un 11% en Longaví y un 15% en Achibueno. Los errores máximos incluso superan el 40% (en ambas cuencas). Es posible plantear la hipótesis de que existan fuentes que agregan errores sistemáticos a la modelación, como por ejemplo, las forzantes.

De acuerdo con lo observado en la serie de SWE simulado, en la mayoría de los años, el derretimiento ocurriría anticipadamente. Es importante recordar que el referente con se cuenta es producto de un reanálisis. Este derretimiento anticipado sería la causa de la sobreestimación durante octubre y noviembre. No obstante, qué tanto se equivoca el modelo durante los primeros meses depende de la precipitación y temperatura del mes. Un mes cálido (alta temperatura) tiende a aumentar el error de sobreestimación. El efecto de la precipitación por otra parte, no es tan claro, básicamente porque existe una correlación entre esta y la temperatura.

La subestimación de los meses posteriores es una consecuencia del derretimiento anticipado. Como la cuenca prácticamente ha agotado su almacenamiento en nieve, el caudal simulado proviene principalmente de la precipitación, generando una subestimación.

El ESP tradicional no entregó resultados satisfactorios para Achibueno y Longaví. Como se observó en la Figura 5.25 y Figura 5.26, utilizar la mediana histórica genera un rango cercano de errores al rango de errores obtenido con ESP tradicional. El ESP tradicional funcionaría mejor en cuencas donde claramente la condición inicial es el componente principal del pronóstico; al forzar el modelo desde esa condición usando la climatología histórica, el pronóstico debería desviarse de la mediana histórica (debido a la dependencia de la condición inicial) y acercarse a la observación.

En cuencas como Achibueno o Longaví, donde además de la condición inicial la precipitación es un componente significativo en el volumen estacional, la climatología histórica (considerando los años equiprobables) no es un conjunto de forzantes adecuado para realizar el pronóstico. Es probable que la predictibilidad que debería aportar la condición inicial se vea disminuida con el error del modelo (o más bien, la modelación) o con el hecho de que, en la realidad, está lejos de ser perfecta (como supone el ESP).

Resultó beneficioso aplicar un post procesamiento, mejorando prácticamente todos los índices (en ambas cuencas). Los índices climáticos seleccionados como predictores en el esquema de pesos presentan una alta correlación con la precipitación durante el deshielo. No obstante, esta correlación proviene principalmente de los primeros meses (septiembre-noviembre). Por otra parte, al calibrar los índices del esquema de pesos, se ataca indirectamente errores no relacionados con la elección de forzantes representativas. Esto debido a que los valores de α y λ responden a una optimización que busca reducir errores, independiente de la fuente.

En ambas cuencas, se concluyó que la observación de septiembre es clave en la disminución de los errores del pronóstico (y mejoramiento de índices). A pesar de la disminución del error resultante del post procesamiento, los pronósticos presentan errores no aceptables en la realidad; la DGA fija este valor en un 20% desde un punto de vista "práctico". Considerando post-procesamiento e inicializando en septiembre, un error del 20% es sólo levemente mayor a la mediana del error en ambas cuencas.

Pese a que los errores se alejan de lo esperado, el ESP con procesamiento logró disminuir los errores a valores, aunque mayores, comparables incluso con el error de la modelación. Por lo tanto, es posible concluir que quizá con algún modelo (o modelación: modelo, forzantes, etc) que errara menos en el cálculo del volumen, los errores de los pronósticos serían también menores. Este modelo podría ser fácilmente un modelo de tipo conceptual (como en sus inicios lo planteó el NWS), sobre todo considerando que un modelo físico requiere inputs difíciles de conseguir en tiempo inmediato (forzantes distribuidas para llegar a la condición inicial, por ejemplo). No se puede garantizar que un modelo conceptual funcionaría mejor, pero al tener menos elementos y procesos que simular, existirían menos "requisitos" (en particular, físicos) que cumplir. Además, el tiempo de cómputo sería considerablemente menor.

BIBLIOGRAFÍA

Alfieri, L., Pappenberger, F., Wetterhall, F., Haiden, T., Richardson, D., and Salamon, P. (2014). Evaluation of ensemble streamflow predictions in Europe, *J. Hydrol.*, 517, 913–922

Alvarez-Garreton, C., Mendoza, P. A., Boisier, J. P., Addor, N., Galleguillos, M., Zambrano-Bigiarini, M., Lara, A., Puelma, C., Cortes, G., Garreaud, R., McPhee, J., and Ayala, A.: *The CAMELS-CL dataset: catchment attributes and meteorology for large sample studies – Chile dataset*, *Hydrol. Earth Syst. Sci. Discuss.*, <https://doi.org/10.5194/hess-2018-23>, in review, 2018

Beven, K., & Freer, J. (2001). *Equifinality, data assimilation, and uncertainty estimation in mechanistic modelling of complex environmental systems using the GLUE methodology*. *Journal of Hydrology*, 249(1-4), 11–29. doi:10.1016/S0022-1694(01)00421-8

Clark, M. P., Slater, A. G., Rupp, D. E., Woods, R. A., Vrugt, J. A., Gupta, H. V., ... Hay, L. E. (2008). Framework for Understanding Structural Errors (FUSE): A modular framework to diagnose differences between hydrological models. *Water Resources Research*, 44(12), 1–14. <https://doi.org/10.1029/2007wr006735>

Cortés, G. (2016). Gaining insight into Andean snowpack climatology and change using a snow reanalysis approach applied over the Landsat satellite record. Los Ángeles. Tesis para optar al grado de doctor en Filosofía en Ingeniería Civil. Universidad de California.

Day, G. N. (1985). Extended Streamflow Forecasting Using NWS- RFS, *J. Water Resour. Plan. Manag.*, 111, 157–170

DGA (2017), Actualización del Balance Hídrico Nacional, SIT N° 417, Ministerio de Obras Públicas, Dirección General de Aguas, División de Estudios y Planificación, Santiago, Chile, Realizado por: Universidad de Chile & Pontificia Universidad Católica de Chile.

Duan, Q. Y., Gupta, V. K., & Sorooshian, S. (1993). *Shuffled complex evolution approach for effective and efficient global minimization*. *Journal of Optimization Theory and Applications*, 76(3), 501–521. doi:10.1007/bf00939380

Franz, K., Hartmann, H., Sorooshian, S., Bales, R., (2003). Verification of National Weather Service ensemble streamflow predictions for water supply forecasting in the Colorado River basin. *Journal of Hydrometeorology* 4, 1105–1118.

Gao, H., Tang, Q., Shi, X., Zhu, C., Bohn, T., & Su, F. (2009). 6 Water Budget Record from Variable Infiltration Capacity (VIC) Model, (Vic), 120–173.

Gobena, A. K., & Gan, T. Y. (2010). Incorporation of seasonal climate forecasts in the ensemble streamflow prediction system. *Journal of Hydrology*, 385(1–4), 336–352. <https://doi.org/10.1016/j.jhydrol.2010.03.002>

Greuell, W., Franssen, W. H. P., Biemans, H., & Hutjes, R. W. A. (2018). Seasonal streamflow forecasts for Europe – Part I: Hindcast verification with pseudo- and real observations, (Vic), 3453–3472.

Greuell, W., Franssen, W. H. P., & Hutjes, R. W. A. (2019). Seasonal streamflow forecasts for Europe – Part II: Sources of skill, 371–391.

Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). *Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling.* *Journal of Hydrology*, 377(1-2), 80–91. [doi:10.1016/j.jhydrol.2009.08.003](https://doi.org/10.1016/j.jhydrol.2009.08.003)

Hamlet A., Lettenmaier D. (1999). Columbia River streamflow forecasting based on ENSO and PDO climate signals. *J. Water Resour. Plan. Manag.* 125, 333–341. [https://doi.org/10.1061/\(ASCE\)0733-9496\(1999\)125:6\(333\)](https://doi.org/10.1061/(ASCE)0733-9496(1999)125:6(333))

Hamman, J. J., Nijssen, B., Bohn, T. J., Gergel, D. R., & Mao, Y. (2018). The Variable Infiltration Capacity model version 5 (VIC-5): infrastructure improvements for new applications and reproducibility, 5(August), 3481–3496.

Harrigan, S., Prudhomme, C., Parry, S., Smith, K., & Tanguy, M. (2018). Benchmarking ensemble streamflow prediction skill in the UK, 2023–2039.

Hrachowitz, M., & Clark, M. P. (2017). HESS Opinions: The complementary merits of competing modelling philosophies in hydrology. *Hydrology and Earth System Sciences*, 21(8), 3953–3973. <https://doi.org/10.5194/hess-21-3953-2017>

Krzysztofowicz, R. (2001). *The case for probabilistic forecasting in hydrology.* *Journal of Hydrology*, 249(1-4), 2–9. [doi:10.1016/S0022-1694\(01\)00420-6](https://doi.org/10.1016/S0022-1694(01)00420-6)

Lane, R. A., Coxon, G., Freer, J. E., Wagener, T., Johnes, P. J., John, P., ... Reaney, S. M. (2019). Benchmarking the predictive capability of hydrological models for river flow and flood peak predictions across a large-sample of catchments in Great Britain, (January).

Lewis, J. M. (2005). *Roots of Ensemble Forecasting.* *Monthly Weather Review*, 133(7), 1865–1885. [doi:10.1175/mwr2949.1](https://doi.org/10.1175/mwr2949.1)

Liang, X., Lettenmaier, D. P., Wood, E. F., & Burges, J. (1994). A Simple hydrologically Based Model of Land Surface Water and Energy Fluxes for GSMs A simple hydrologically based model of land surface water and energy fluxes for general circulation models, (May 2014). <https://doi.org/10.1029/94JD00483>

Liu, Y., & Gupta, H. V. (2007). Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework. *Water Resources Research*, 43(7), 1–18. <https://doi.org/10.1029/2006WR005756>

Lorenz, E. N.M (1975). Climate predictability. *The Physical Bases of Climate and Climate Modelling*. GARP Publ. Ser., no. 16, World Meteorological Organization, pp. 136-6.

Mason, S. J., & Stephenson, D. B. (2008). How Do We Know Whether Seasonal Climate Forecasts are Any Good? *Seasonal Climate: Forecasting and Managing Risk*, 259–289. https://doi.org/10.1007/978-1-4020-6992-5_10

McKee, T. B., N. J. Doesken, and J. Kliest, 1993: The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference of Applied Climatology, 17-22 January, Anaheim, CA*. American Meteorological Society, Boston, MA. 179-184.

Mendoza, P. A., Wood, A. W., Clark, E., Rothwell, E., Clark, M. P., Nijssen, B., ... Arnold, J. R. (2017). An intercomparison of approaches for improving operational seasonal streamflow forecasts, 3915–3935.

Moradkhani, H., & Meier, M. (2010). *Long-Lead Water Supply Forecast Using Large-Scale Climate Predictors and Independent Component Analysis*. *Journal of Hydrologic Engineering*, 15(10), 744–762. doi:10.1061/(asce)he.1943-5584.0000246

Nash, J.E., Sutcliffe, J.V., (1970). River flow forecasting through. Part I. A conceptual models discussion of principles. *Journal of Hydrology*. 10, 282–290.

Niemeyer, H., Dirección General de Aguas (198-) Hoyas hidrográficas de Chile: séptima región.

ODEPA, 2015, Catastro Frutícola de la VII región del Maule. Recuperado de: http://www.odepa.cl/documentos_informes/catastro-fruticola-ciren-odepa

Refsgaard, J. C. (1997). Parameterisation, calibration and validation of distributed hydrological models, 198, 69–97.

Todini, E. (2011) Publishing, I. W. A., & Research, H. History and perspectives of hydrological catchment modelling, 73–86. <https://doi.org/10.2166/nh.2011.096>

Todini, E. (2018). Paradigmatic changes required in water resources management to benefit from probabilistic forecasts. *Water Security*, 3(February), 9–17. <https://doi.org/10.1016/j.wasec.2018.08.001>

Todini, E. (2007) Hydrological catchment modelling: past, present and future. *Hydrol. Earth Syst. Sci.*, 11(1), 468–482, 2007 www.hydrol-earth-syst-sci.net/11/468/2007

Twedt, T.M., Schaake, J.C., Peck, E.L., (1977). National weather service extended streamflow prediction. In: Proceedings, Western Snow Conference, Albuquerque, NM, Abril, p. 52–57

Wagener, T., & Gupta, Æ. H. V. (2005). Model identification for hydrological forecasting under uncertainty, 378–387. <https://doi.org/10.1007/s00477-005-0006-5>

Werner, K., Brandon, D., Clark, M., & Gangopadhyay, S. (2004). *Climate Index Weighting Schemes for NWS ESP-Based Seasonal Volume Forecasts*. *Journal of Hydrometeorology*, 5(6), 1076–1090. doi:10.1175/jhm-381.1

Wilks, D. S. (2011), *Statistical Methods in the Atmospheric Sciences*, 3rd ed., 467 pp., Academic Press, Waltham, Mass.

Wood, A. (2016). Tracing the origins of ESP. HEPEX Historial Hydrology Series, Edition1. Recuperado de: www.hepex.irstea.fr

Wood, A., Lettenmaier, D., (2008). An ensemble approach for attribution of hydrologic prediction uncertainty. *Geophysical Research Letters* 35. doi:10.1029/2008GL034648.

Wood, A.W., Schaake, J.C., (2008). Correcting errors in streamflow forecast ensemble mean and spread. *J. Hydrometeorol.* 9, 132–148. <http://dx.doi.org/10.1175/2007JHM862.1>.

Yilmaz, K. K., H. V. Gupta, and T. Wagener (2008), A process-based diagnostic approach to model evaluation: Application to the NWS distributed hydrologic model, *Water Resour. Res.*, 44, W09417, doi:10.1029/2007WR006716.

Šípek, V., & Daňhelka, J. (2015). *Modification of input datasets for the Ensemble Streamflow Prediction based on large-scale climatic indices and weather generator*. *Journal of Hydrology*, 528, 720–733. doi:10.1016/j.jhydrol.2015.07.008

ANEXO A

Parámetros calibrados

Los parámetros del modelo VIC calibrados para las distintas cuencas son los expuestos en la Tabla A. 1

Tabla A. 1 Parámetros calibrados en las distintas cuencas.

Notación	Definición	Rango calibración	Valor calibrado		
			Longaví	Achibueno	Maule
$b_{infiltr}$	Parámetro que define la curva de infiltración variable. Grandes valores de $b_{infiltr}$ producen más escorrentía.	0,0050 – 0,5	0,331	0,368	0,087
D_s	Fracción de $D_{s_{max}}$ donde comienza el flujo base no lineal (que aumenta rápidamente). Con un valor más alto de D_s , el flujo base será mayor a menor contenido de agua en la capa más baja del suelo.	0,01 – 1	0,869	0,87	0,134
$D_{s_{max}}$	Flujo base máximo que puede ocurrir desde la capa más baja del suelo (en mm / día).	0,1 – 100	87,9	74,686	16,221
W_s	Fracción de la humedad máxima del suelo (de la capa más baja) donde ocurre el flujo base no lineal.	0,01 – 1	0,02	0,028	0,719
C_{excp}	Exponente en la ecuación de Campbell para la conductividad hidráulica.	3 – 12,00	3,06	4,175	11,601
$depth1$	Profundidad de la primera capa en metros.	0,05 – 1,5	0,064	0,075	0,545
$depth2$	Profundidad de la segunda capa en metros.	0,5 – 4,0	0,502	0,747	0,503
$depth3$	Profundidad de la tercera capa en metros.	0,5 – 4,0	0,73	0,717	2,096
$newalb$	Nuevo Albedo	0,7 – 0,99	0,71	0,735	0,898
$albaa$	Base de la función del albedo para acumulación	0,85 – 0,99	0,904	0,852	0,919
$albtha$	Base de la función del albedo para derretimiento	0,7 – 0,98	0,978	0,979	0,812
K_{sat}	Conductividad hidráulica saturada.	0 – 500	499	291	240
T_{min}	Mínima temperatura para que exista precipitación líquida.	-2 – 2	1,12	1,23	-1,864
$rsnow$	Rugosidad de la superficie de la capa de nieve.	0,000001 – 0,01	1,95E-06	0,00003941	0,006575

ANEXO B

Índices SSI y SPI

Ambos índices fueron calculados de la misma forma. El procedimiento fue el siguiente:

- Para cada año, la variable (caudal en el caso del SSI y precipitación para el SPI) fue agrupada en los periodos de interés, es decir, entre abril y agosto (“invierno”) y entre septiembre y marzo (“deshielo”).
- Se estima la función de densidad de probabilidad usando una distribución de Pearson-III (i.e., gamma 3-parámetros).
- La distribución es posteriormente transformada a una distribución normal acumulada, de la que se puede extraer el índice estandarizado.

La Figura B. 1 muestra el procedimiento descrito.

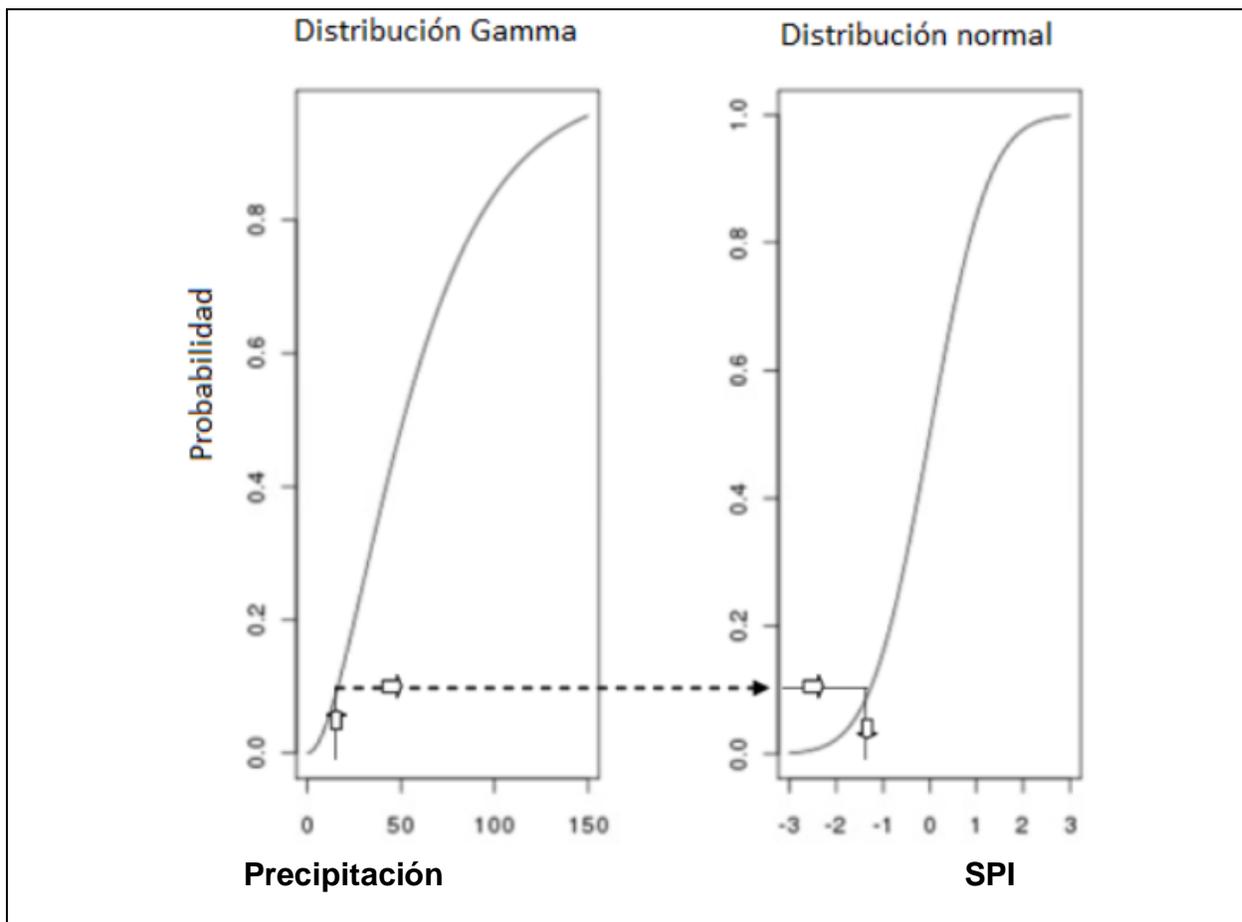


Figura B. 1 Cálculo índice estandarizado. Fuente: climatelibrary.cl

ANEXO C

Métricas de evaluación del modelo

Eficiencia de Nash-Sutcliffe (NSE)

$$NSE = 1 - \frac{\sum_{i=1}^N (S_i - O_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (16)$$

Donde:

N : número de observaciones.

S_i : variable simulada en el tiempo i .

O_i : variable observada en el tiempo i .

\bar{O} : media variables observadas.

Los siguientes índices hidrológicos fueron extraídos de Yilmaz, 2008.

Porcentaje de sesgo en el índice de escorrentía general (% BiasRR)

$$\%BiasRR = \frac{\sum_{t=1}^N (QS_t - QO_t)}{\sum_{t=1}^N QO_t} \cdot 100 \quad (17)$$

Donde:

QS_t : caudal simulado en el tiempo t .

QO : caudal observado en el tiempo t .

Porcentaje de sesgo en la pendiente del segmento medio (% BiasFMS)

$$\%BiasFMS = \frac{[\log(QS_{m1}) - \log(QS_{m2})] - [\log(QO_{m1}) - \log(QO_{m2})]}{[\log(QO_{m1}) - \log(QO_{m2})]} \cdot 100 \quad (18)$$

Donde:

$m1$ y $m2$: probabilidades de excedencia de flujo más altas y más bajas (0,2 y 0,7 respectivamente) dentro del segmento medio de la curva de duración del flujo.

Porcentaje de sesgo en el volumen del segmento alto (% BiasFHV)

$$\%BiasFHV = \frac{\sum_{h=1}^H (QS_h - QO_h)}{\sum_{h=1}^H QO_h} \cdot 100 \quad (19)$$

Donde:

$h = 1, 2, \dots$.H: índices para flujos con probabilidades de excedencia inferiores a 0,02.

Porcentaje de sesgo en el volumen del segmento bajo (% BiasFLV)

$$\%BiasFLV = \frac{\sum_{l=1}^L [\log(QS_l) - \log(QS_l)] - [\log(QO_l) - \log(QO_l)]}{\sum_{l=1}^L [\log(QO_l) - \log(QO_l)]} \cdot 100 \quad (20)$$

Donde:

$l = 1, 2, \dots$.L: índices para flujos con probabilidades de excedencia entre 0,7-1.

ANEXO D

Boxplot

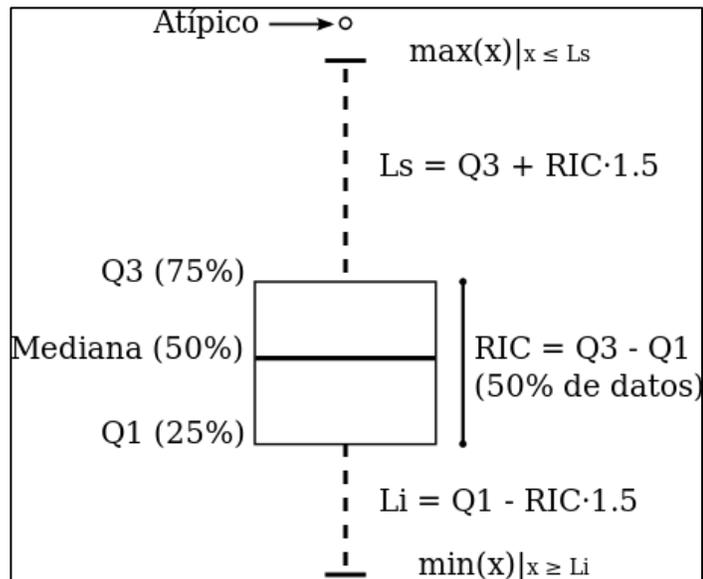


Figura D. 1 Esquema boxplot. Fuente: Wikipedia.

- **Mediana:** La mitad de los casos se encuentra por debajo de este valor.
- **Primer Cuartil (Q1):** El 25% de los casos se encuentran por debajo de este valor.
- **Tercer Cuartil (Q3):** El 75% de los casos se encuentran por debajo de este valor.
- **Rango Intercuartílico (RIC):** Es la diferencia entre el tercer y el primer cuartil.
- **Límites Superior o Inferior (Ls o Li):** Ls y Li fijan los límites $Q3 + 1,5RIC$ y $Q3 - 1,5RIC$, respectivamente. Cuando el valor mínimo de la muestra es mayor a Li, se escoge este valor como Li. Análogamente, se escoge el máximo de la muestra cuando este valor es menor a Ls.
- **Valores atípicos o outliers** son puntos que están más allá de Ls y Li.

Gráficos ESP sin procesar

Longaví en el Castillo

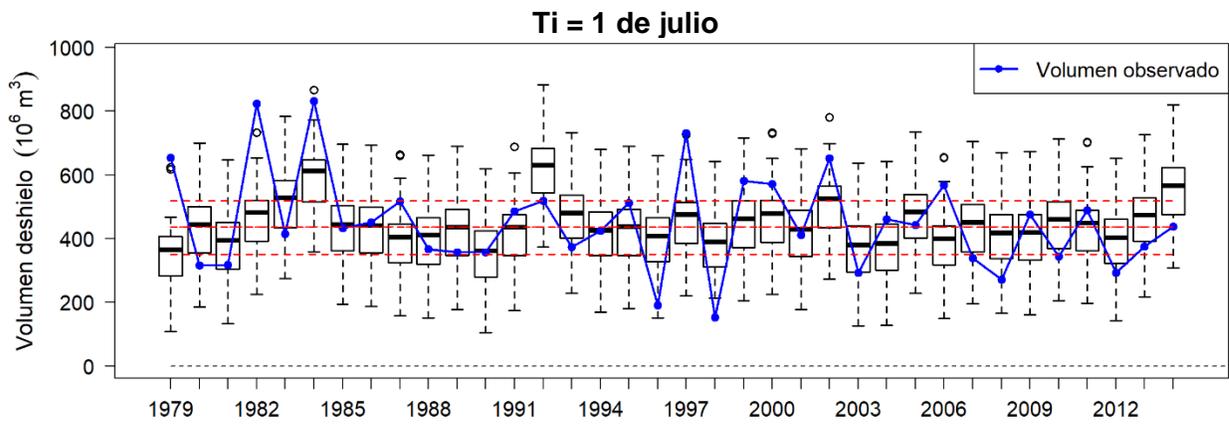


Figura D. 2 Pronóstico Longaví en el Castillo, desde $T_i = 1$ de julio.

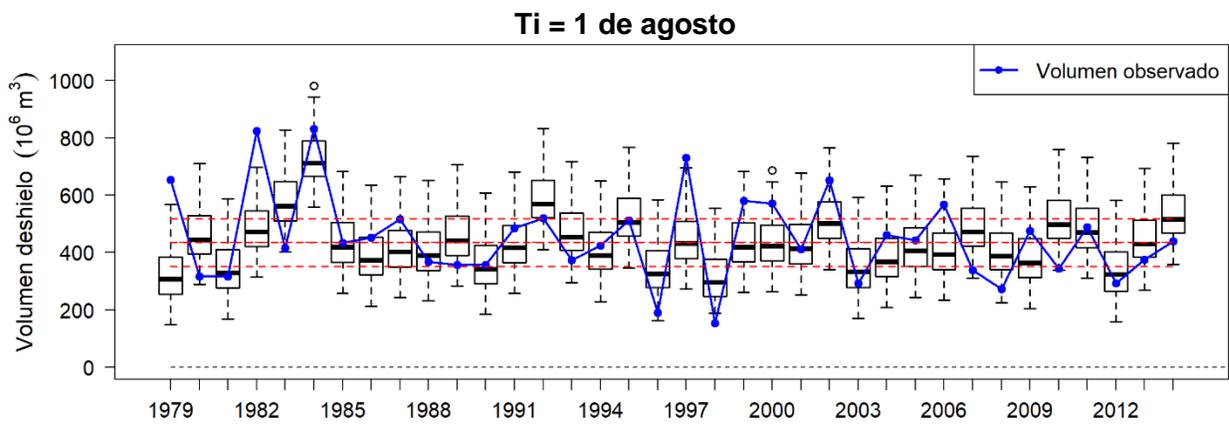


Figura D. 3 Pronóstico Longaví en el Castillo, desde $T_i = 1$ de agosto.

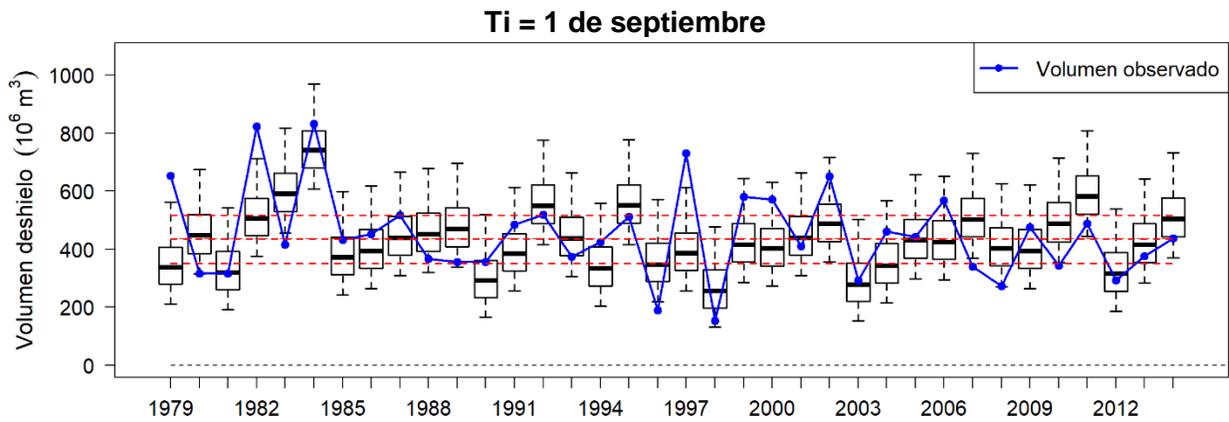


Figura D. 4 Pronóstico Longaví en el Castillo, desde $T_i = 1$ de septiembre.

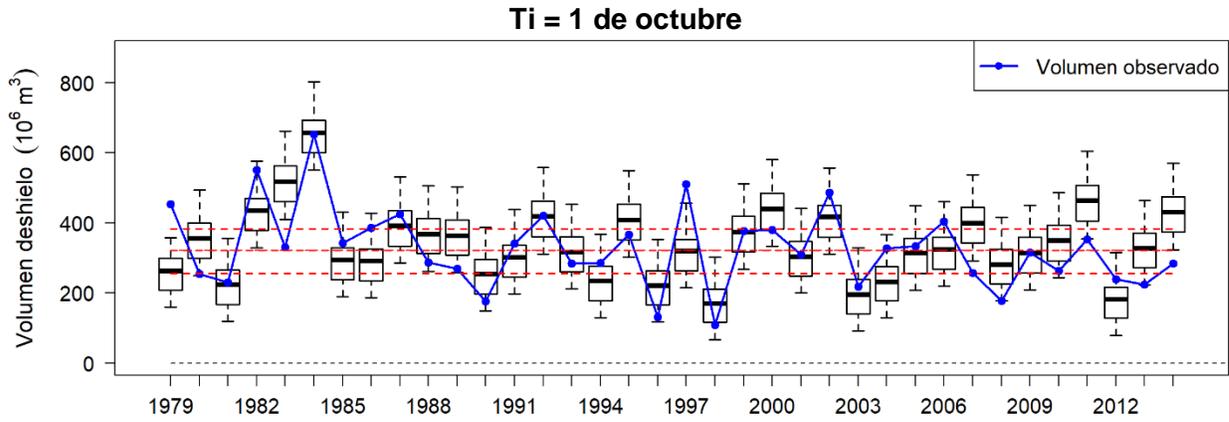


Figura D. 5 Pronóstico Longaví en el Castillo, desde Ti = 1 de octubre.

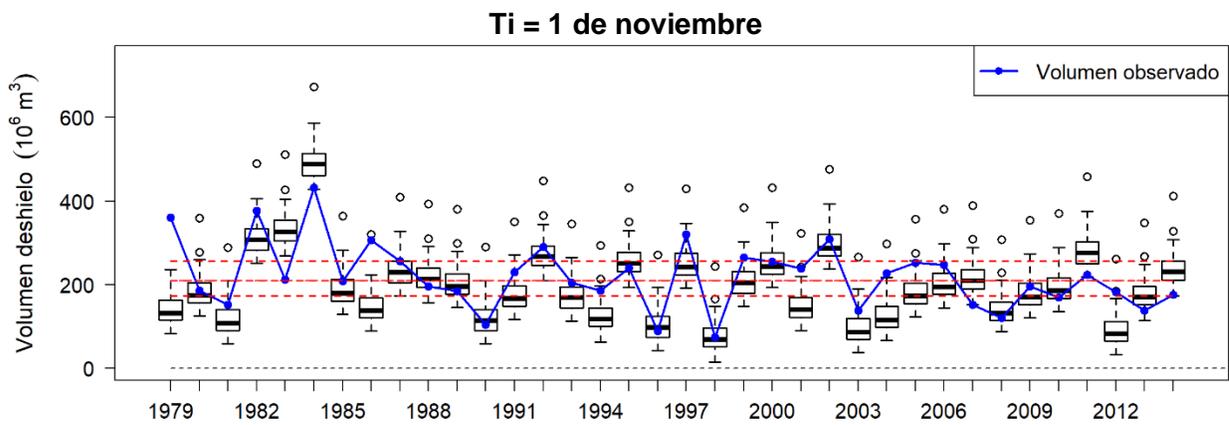


Figura D. 6 Pronóstico Longaví en el Castillo, desde Ti = 1 de noviembre.

Achibueno en la Recova

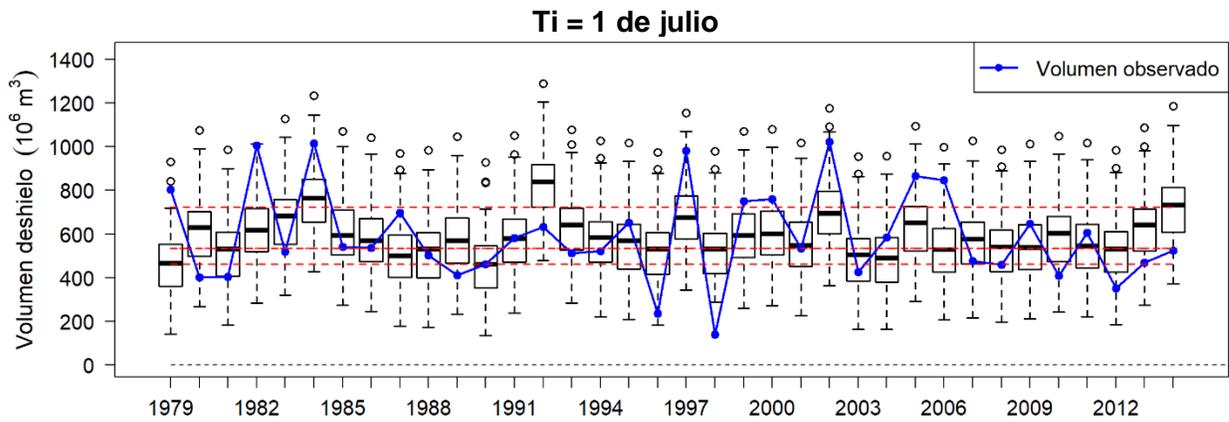


Figura D. 7 Pronóstico Achibueno en la Recova, desde Ti = 1 de julio.

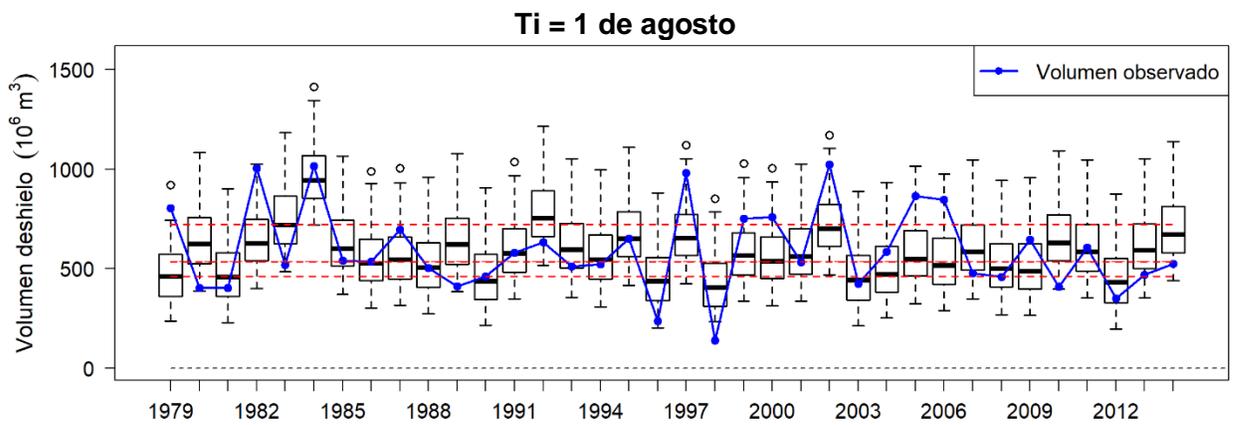


Figura D. 8 Pronóstico Achibueno en la Recova, desde $T_i = 1$ de agosto.

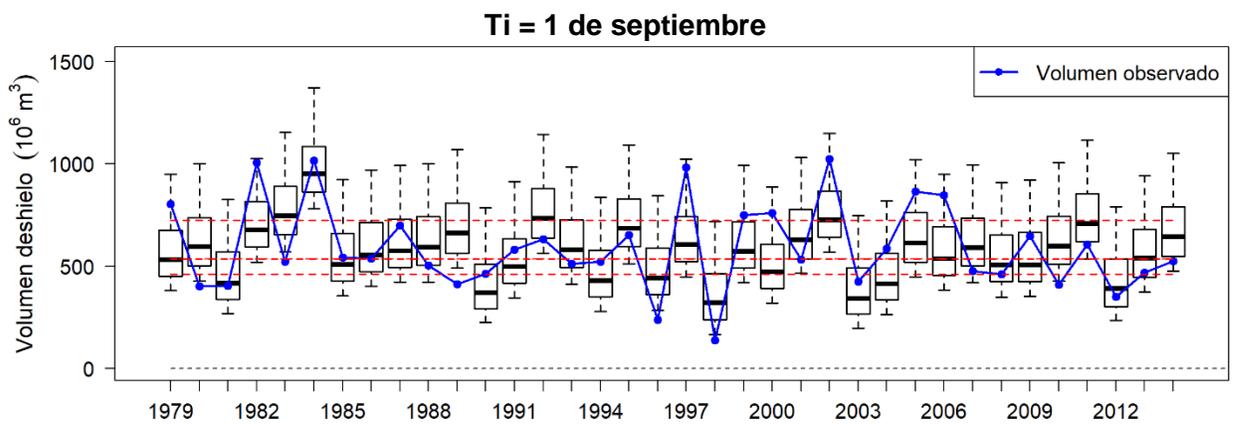


Figura D. 9 Pronóstico Achibueno en la Recova, desde $T_i = 1$ de julio.

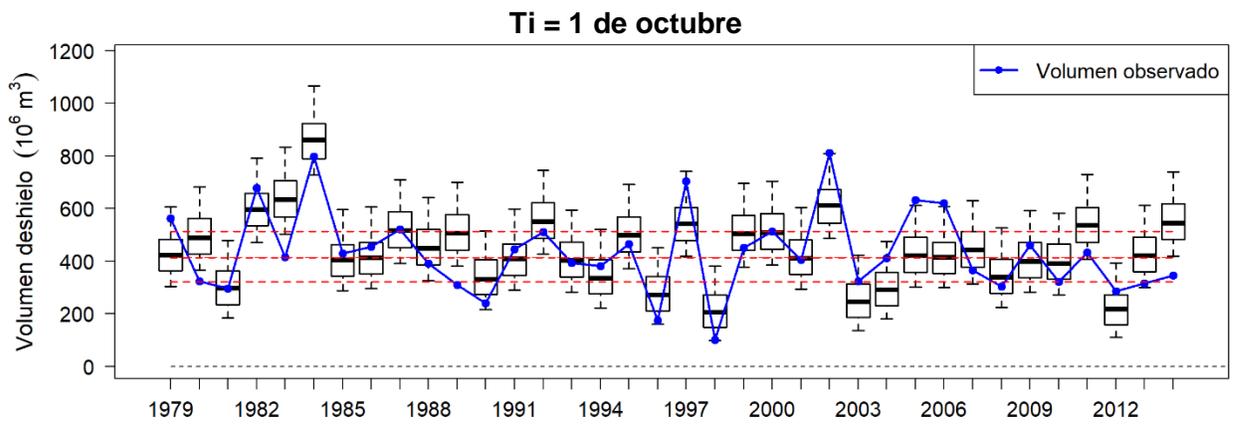


Figura D. 10 Pronóstico Achibueno en la Recova, desde $T_i = 1$ de julio.

Ti = 1 de noviembre

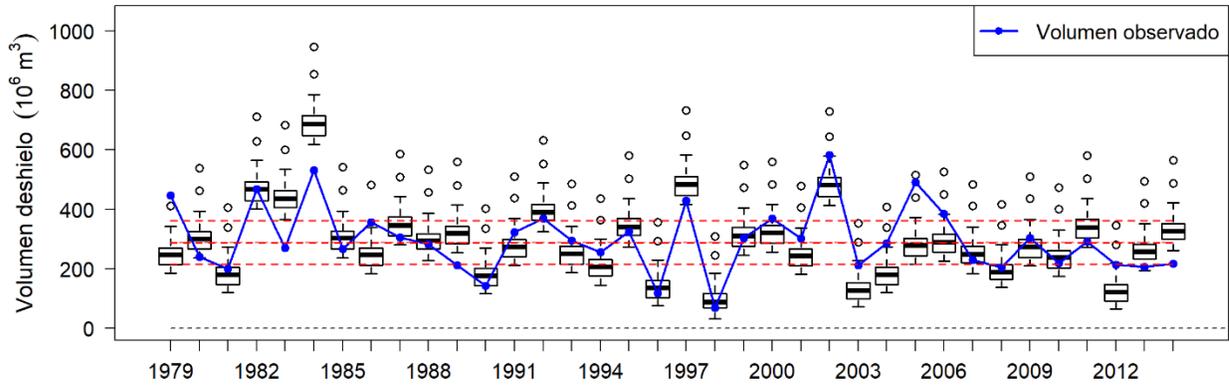


Figura D. 11 Pronóstico Achibueno en la Recova, desde Ti = 1 de julio.

Maule en Armerillo

Ti = 1 de julio

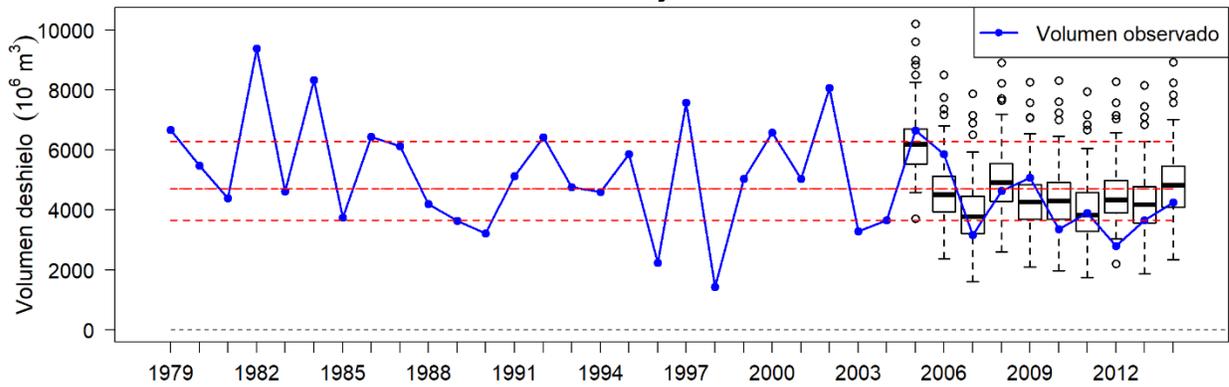


Figura D. 12 Pronóstico Maule en Armerillo, desde Ti = 1 de julio.

Ti = 1 de agosto

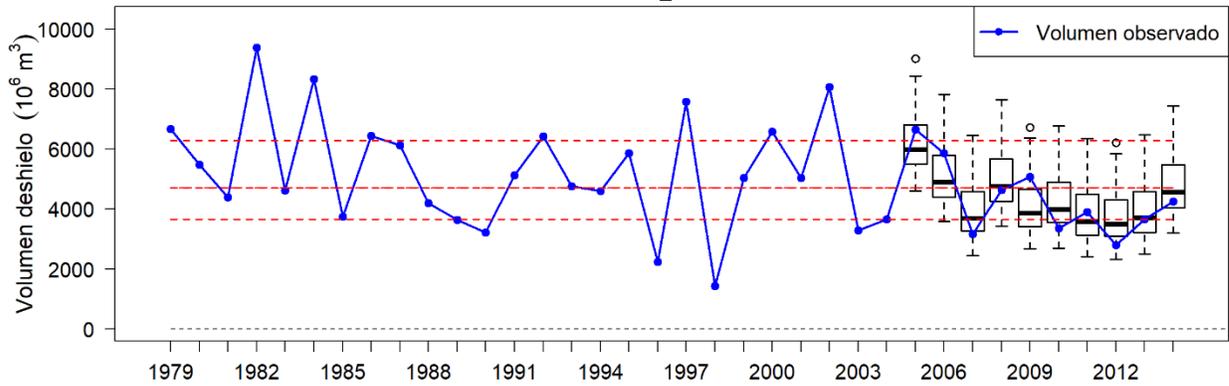


Figura D. 13 Pronóstico Maule en Armerillo, desde Ti = 1 de agosto.

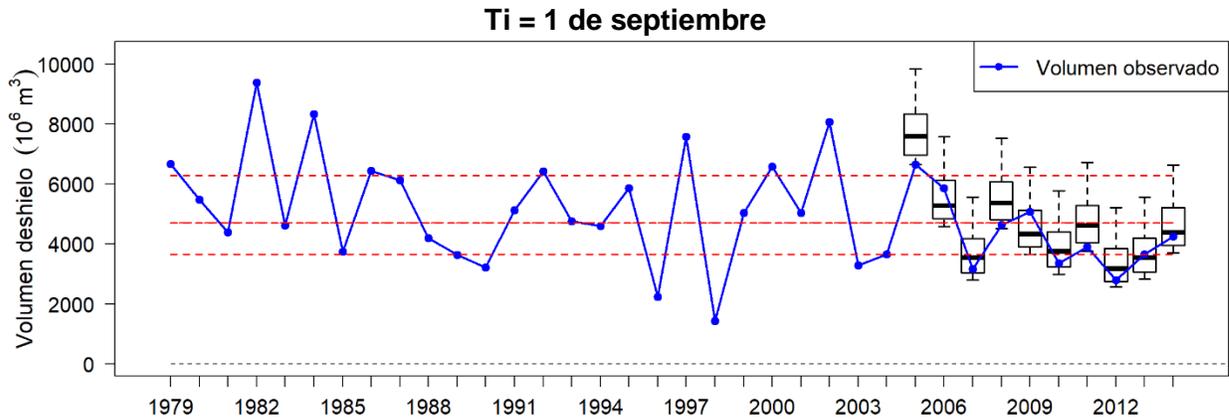


Figura D. 14 Pronóstico Maule en Armerillo, desde $T_i = 1$ de septiembre.

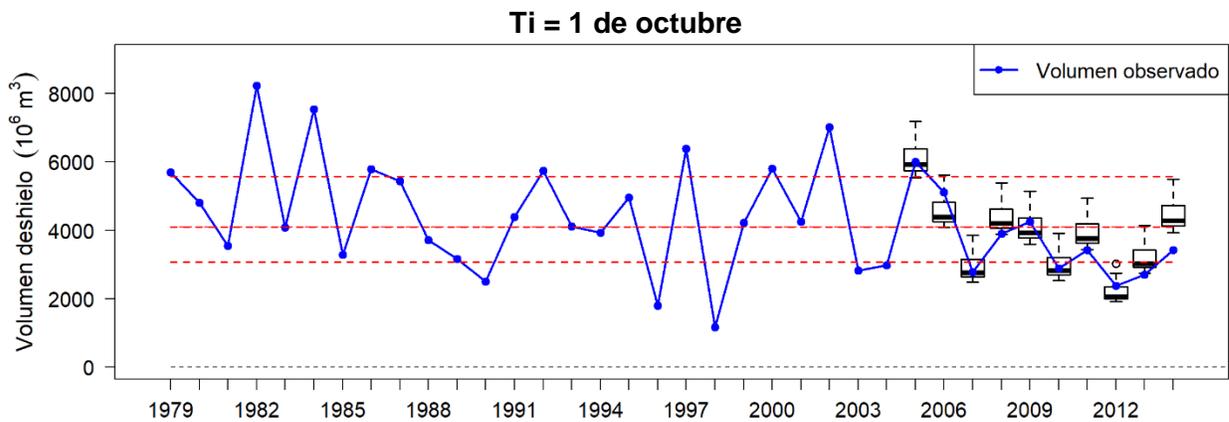


Figura D. 15 Pronóstico Maule en Armerillo, desde $T_i = 1$ de octubre.

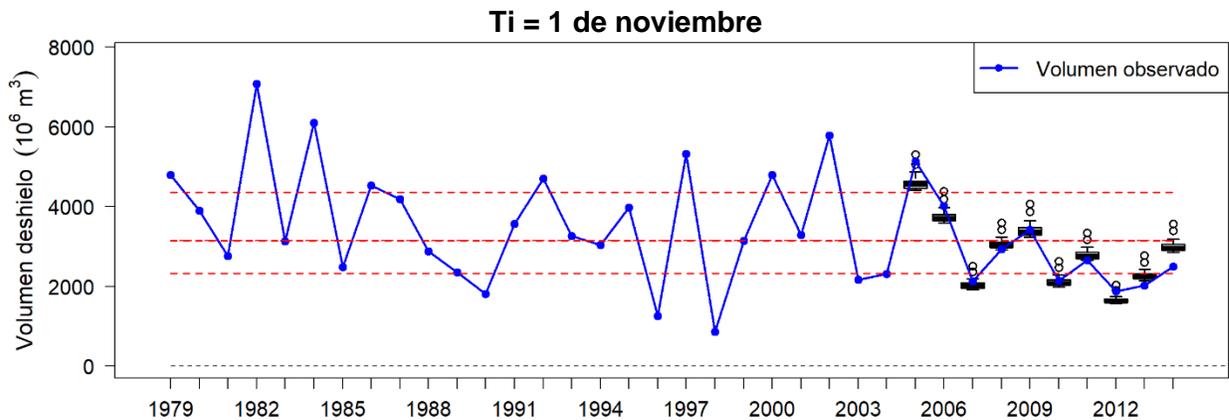


Figura D. 16 Pronóstico Maule en Armerillo, desde $T_i = 1$ de noviembre.

ANEXO E

Correlación índices climáticos y SPI deshielo

Longaví en el Castillo

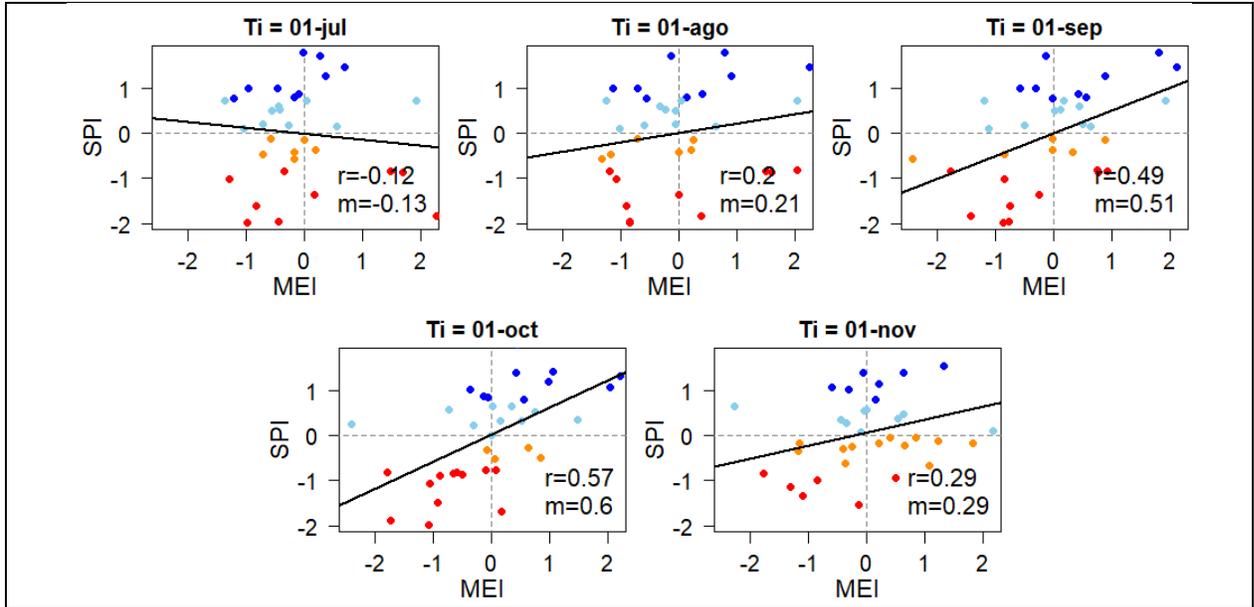


Figura E. 1 Correlación MEI y SPI-deshielo, Cuenca: Longaví en el Castillo. En las figuras "Ti" representa el tiempo de inicialización para el cual es utilizada la correlación graficada.

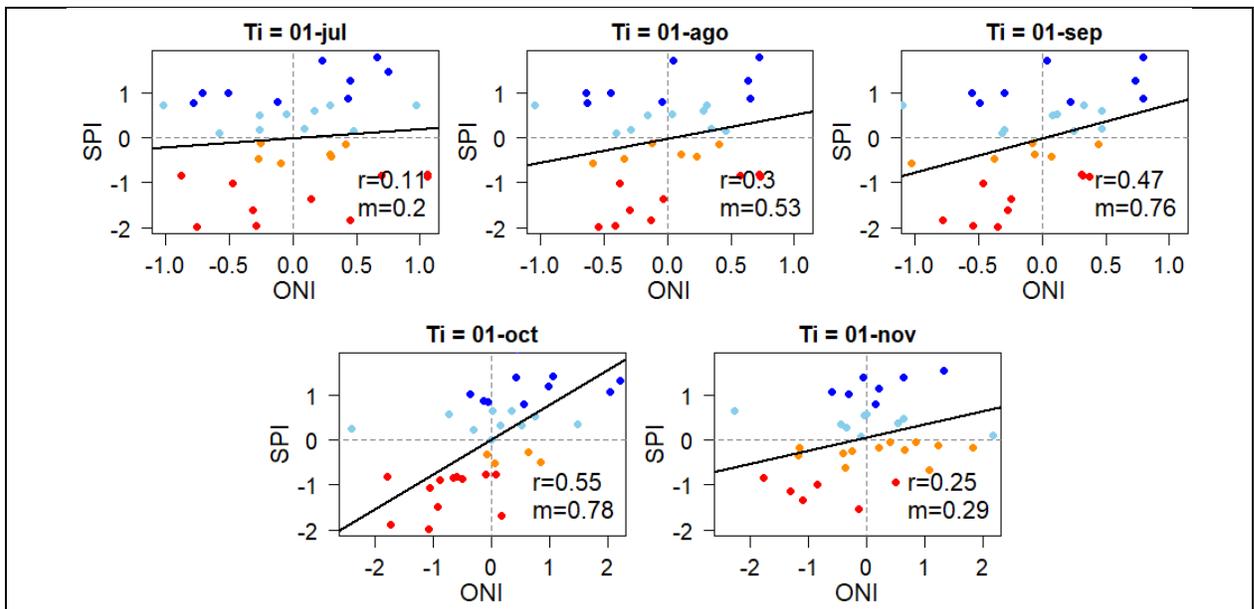


Figura E. 2 Correlación ONI y SPI-deshielo, Cuenca: Longaví en el Castillo. En las figuras "Ti" representa el tiempo de inicialización para el cual es utilizada la correlación graficada.

Achibueno en la Recova

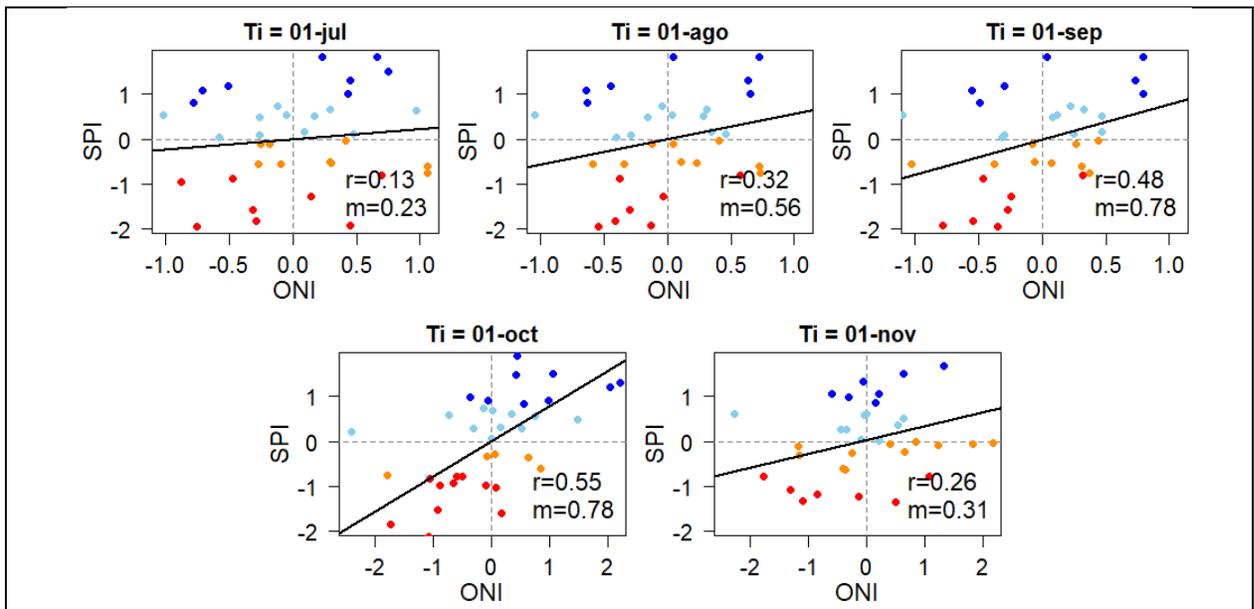


Figura E. 3 Correlación ONI y SPI-deshielo, Cuenca: Achibueno en la Recova. En las figuras "Ti" representa el tiempo de inicialización para el cual es utilizada la correlación graficada.

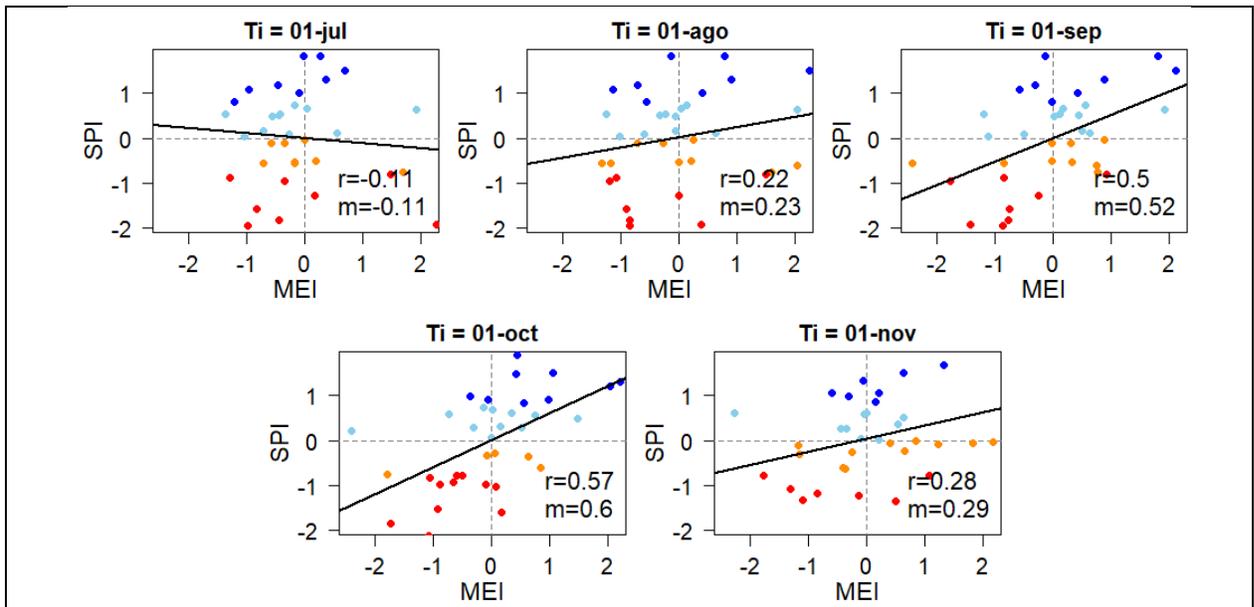
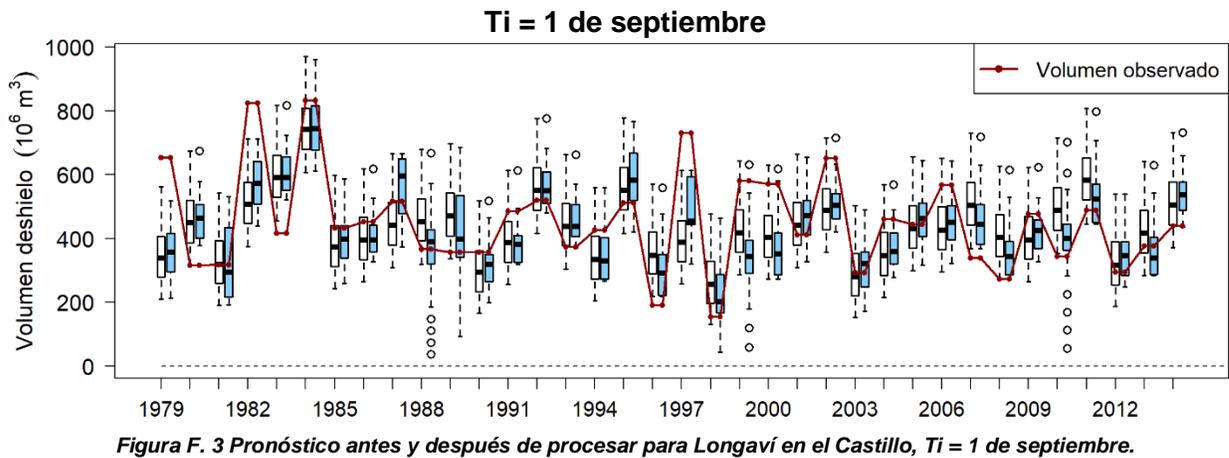
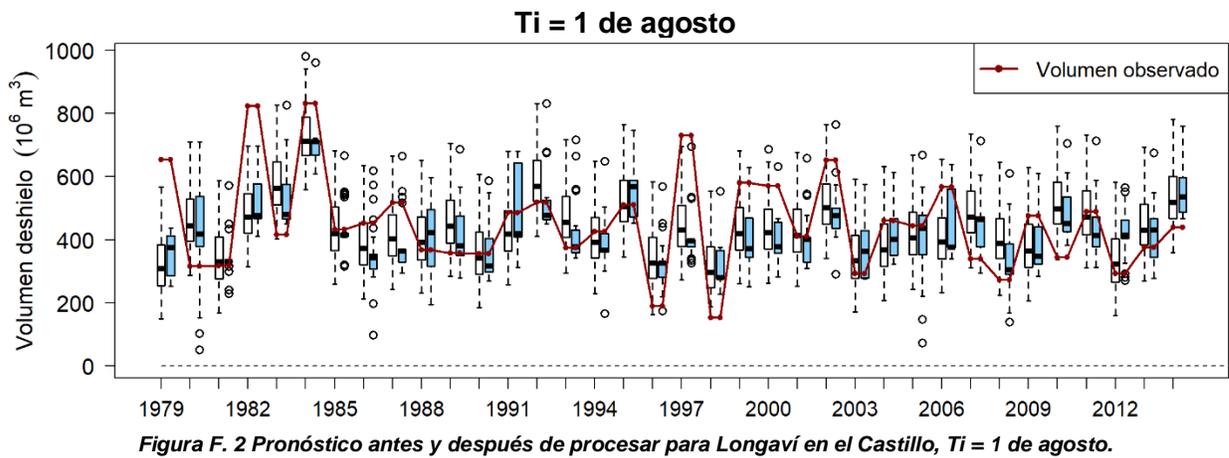
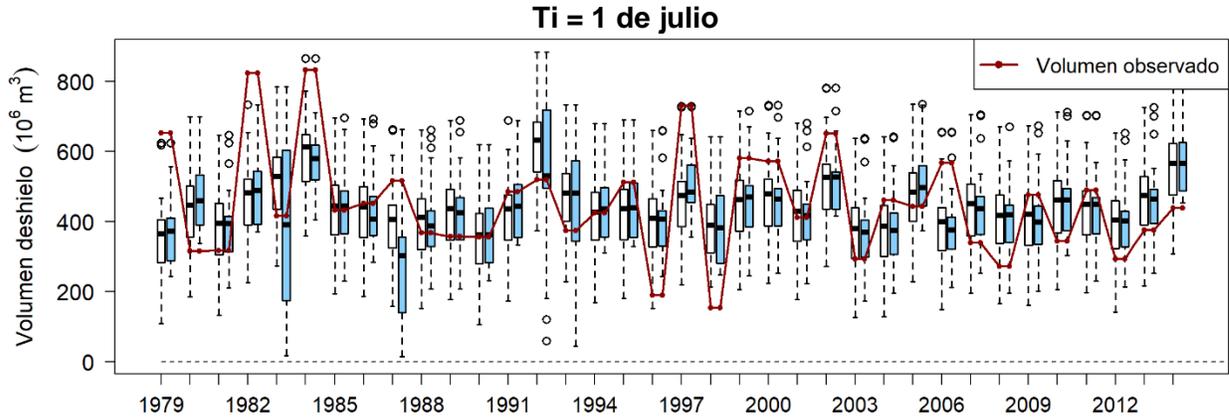


Figura E. 4 Correlación MEI y SPI-deshielo, Cuenca: Achibueno en la Recova. En las figuras "Ti" representa el tiempo de inicialización para el cual es utilizada la correlación graficada.

ANEXO F
Gráficos ESP post procesamiento
Longaví en el Castillo



Ti = 1 de octubre

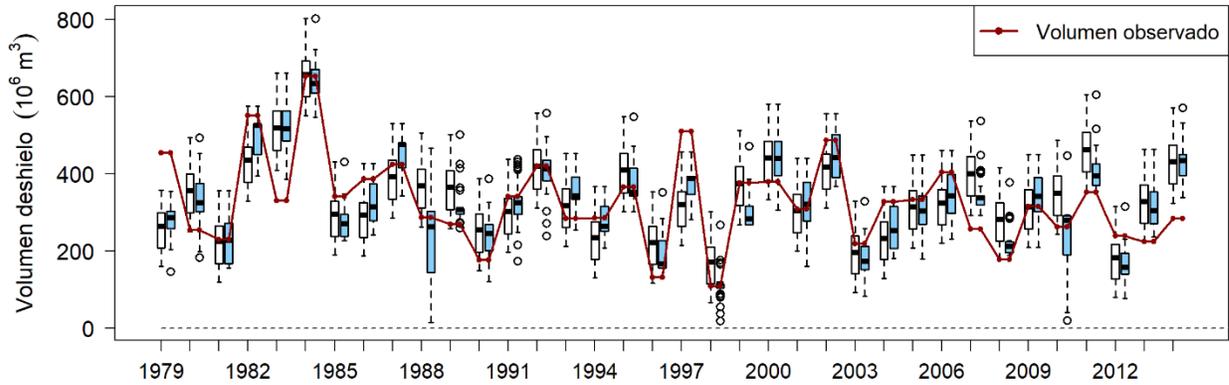


Figura F. 4 Pronóstico antes y después de procesar para Longaví en el Castillo, Ti = 1 de octubre.

Ti = 1 de noviembre

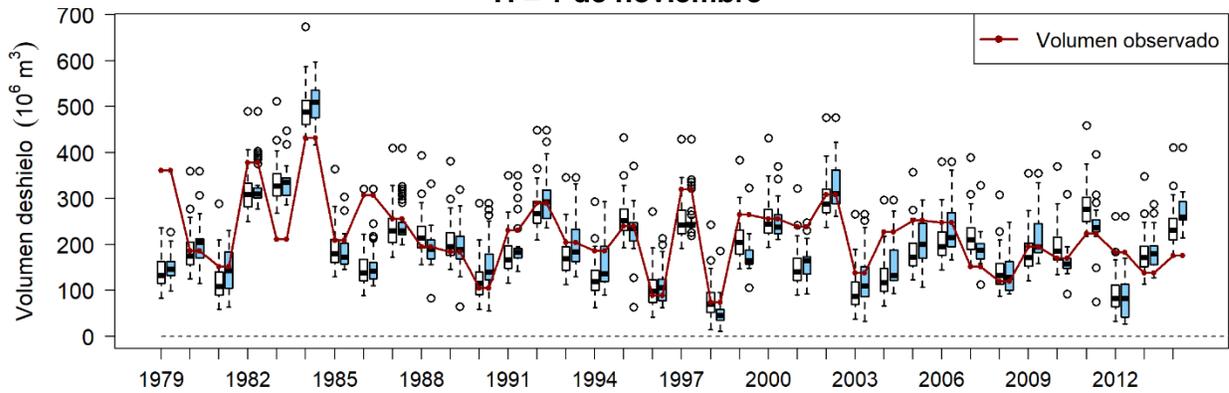


Figura F. 5 Pronóstico antes y después de procesar para Longaví en el Castillo, Ti = 1 de noviembre.

Achibueno en la Recova

Ti = 1 de julio

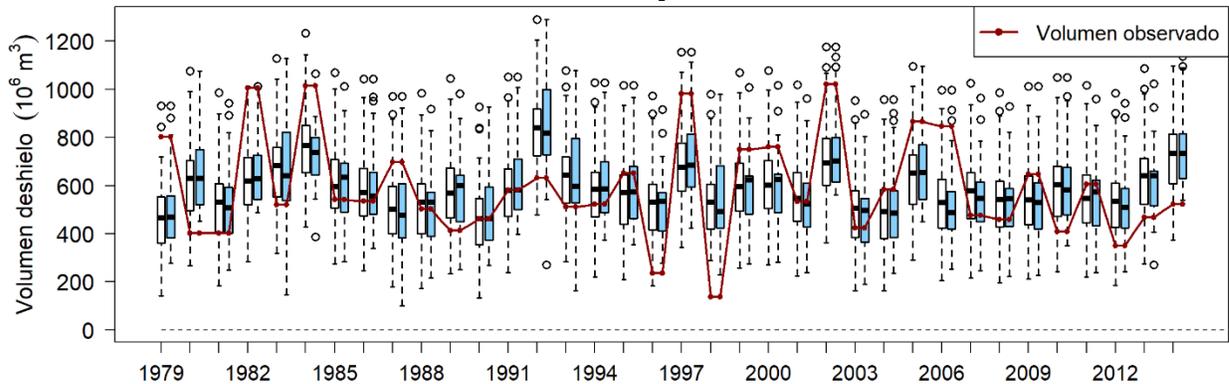


Figura F. 6 Pronóstico antes y después de procesar para Achibueno en la Recova, Ti = 1 de julio.

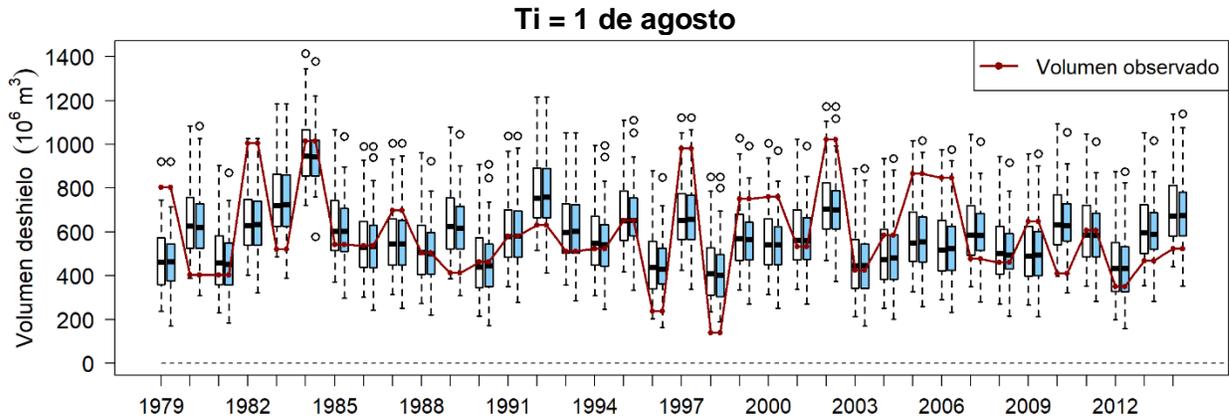


Figura F. 7 Pronóstico antes y después de procesar para Achibueno en la Recova, $T_i = 1$ de agosto.

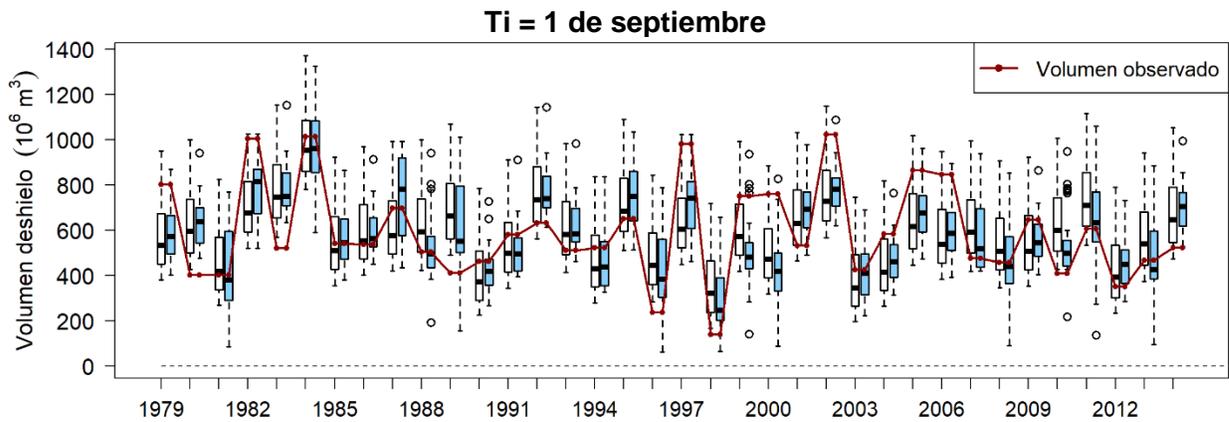


Figura F. 8 Pronóstico antes y después de procesar para Achibueno en la Recova, $T_i = 1$ de septiembre.

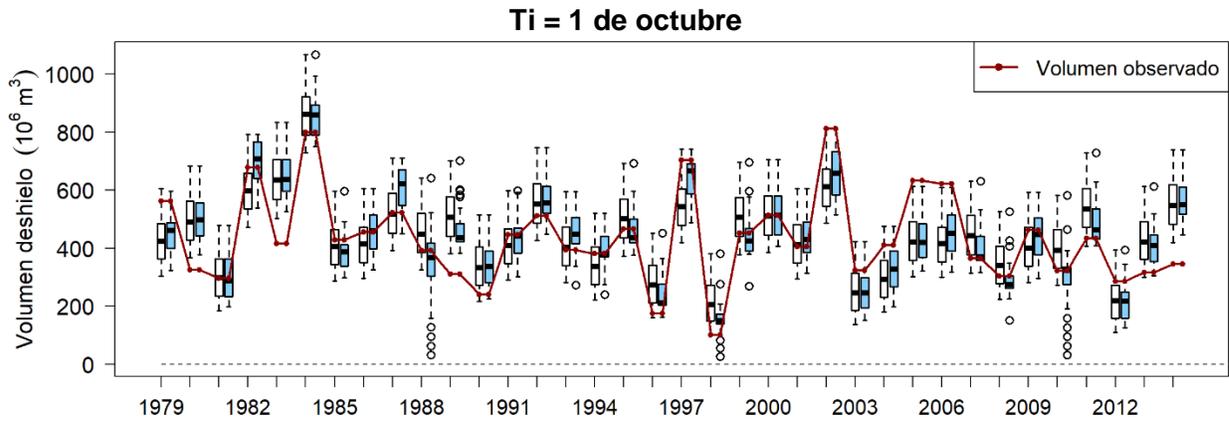


Figura F. 9 Pronóstico antes y después de procesar para Achibueno en la Recova, $T_i = 1$ de octubre.

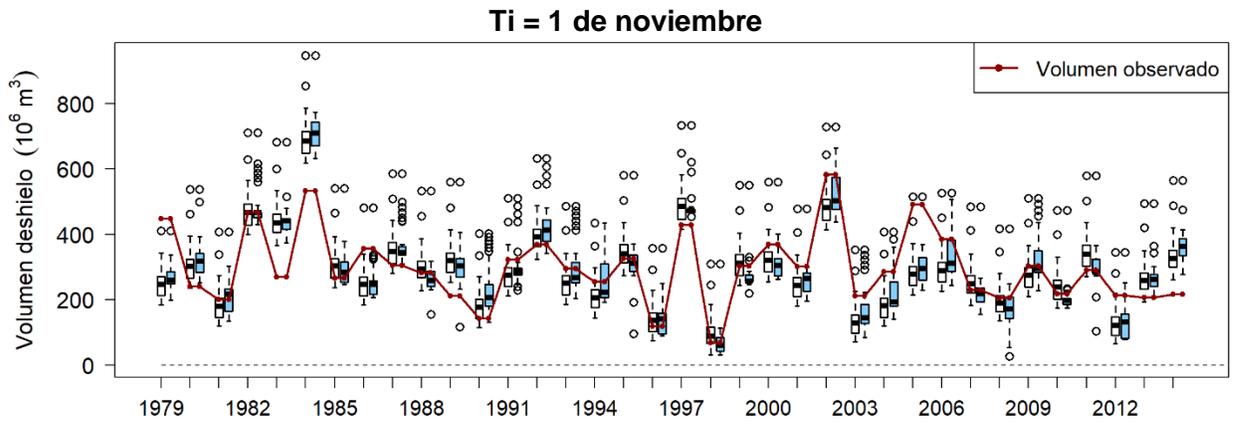


Figura F. 10 Pronóstico antes y después de procesar para Achibueno en la Recova, $T_i = 1$ de noviembre.

ANEXO G

Gráficos Resumen

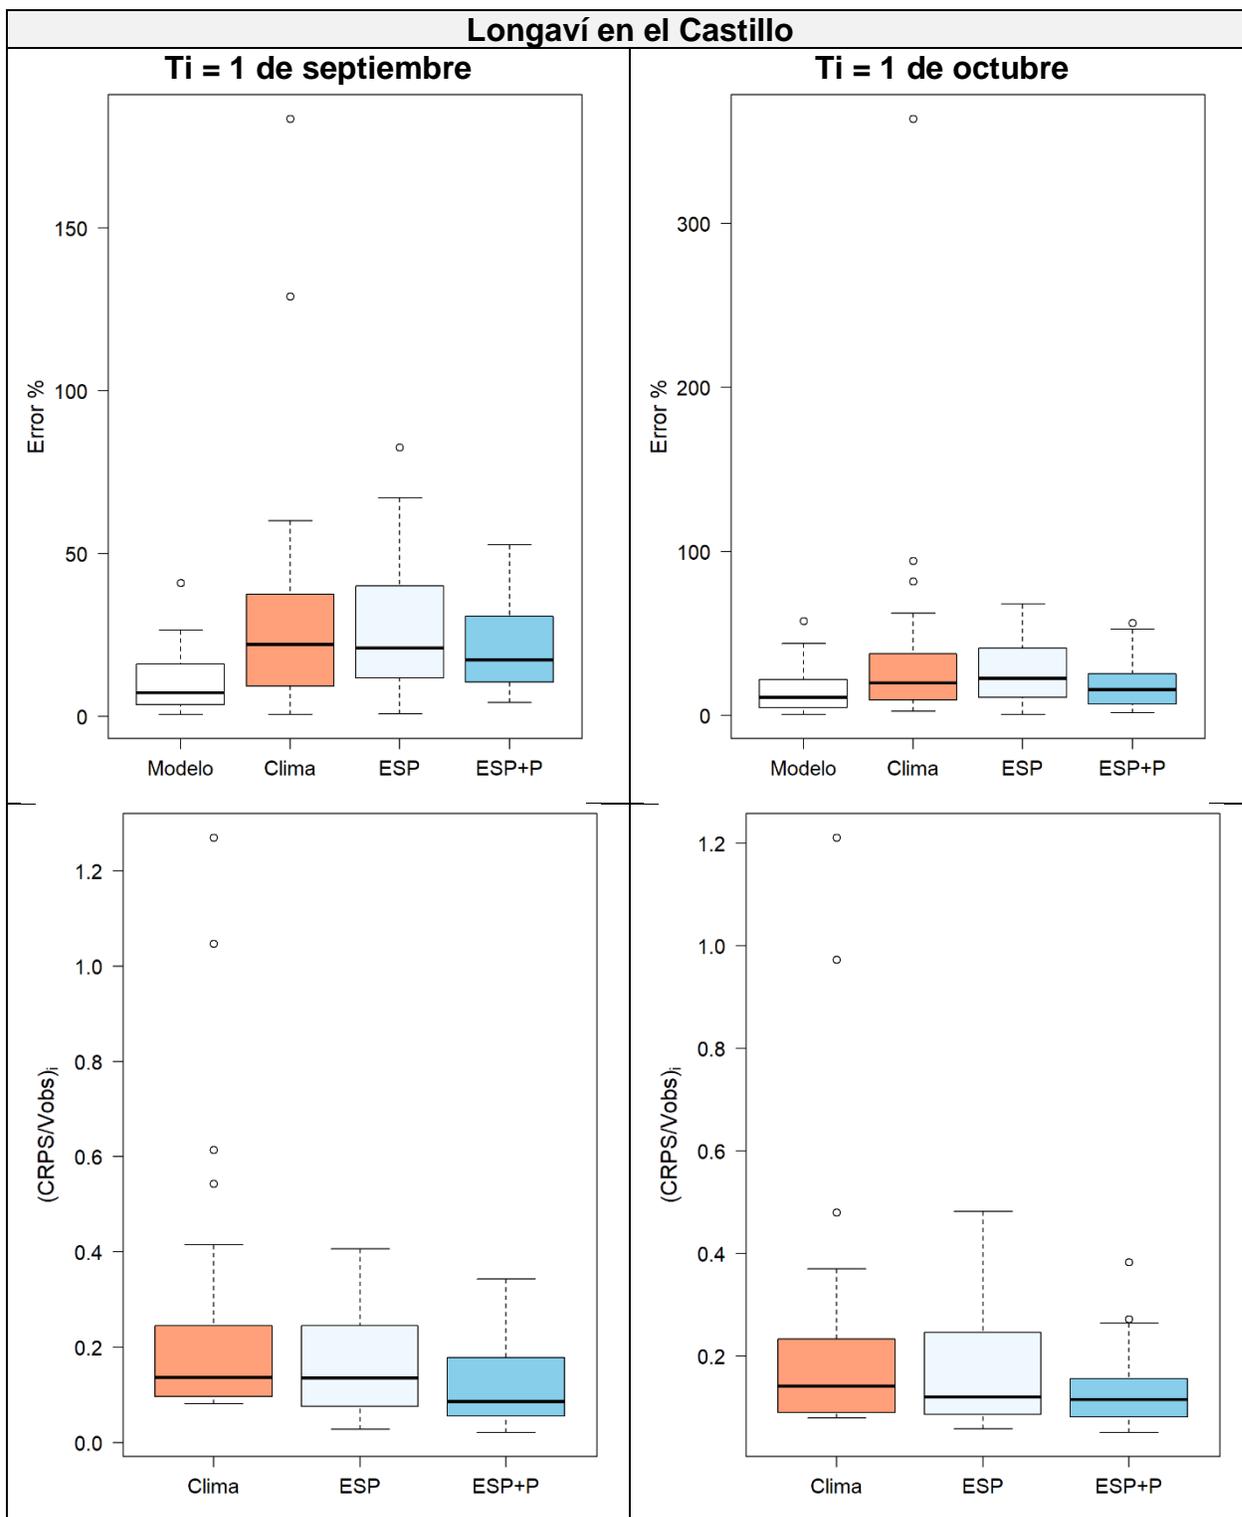


Figura G. 1 Resumen errores Longaví en el Castillo.

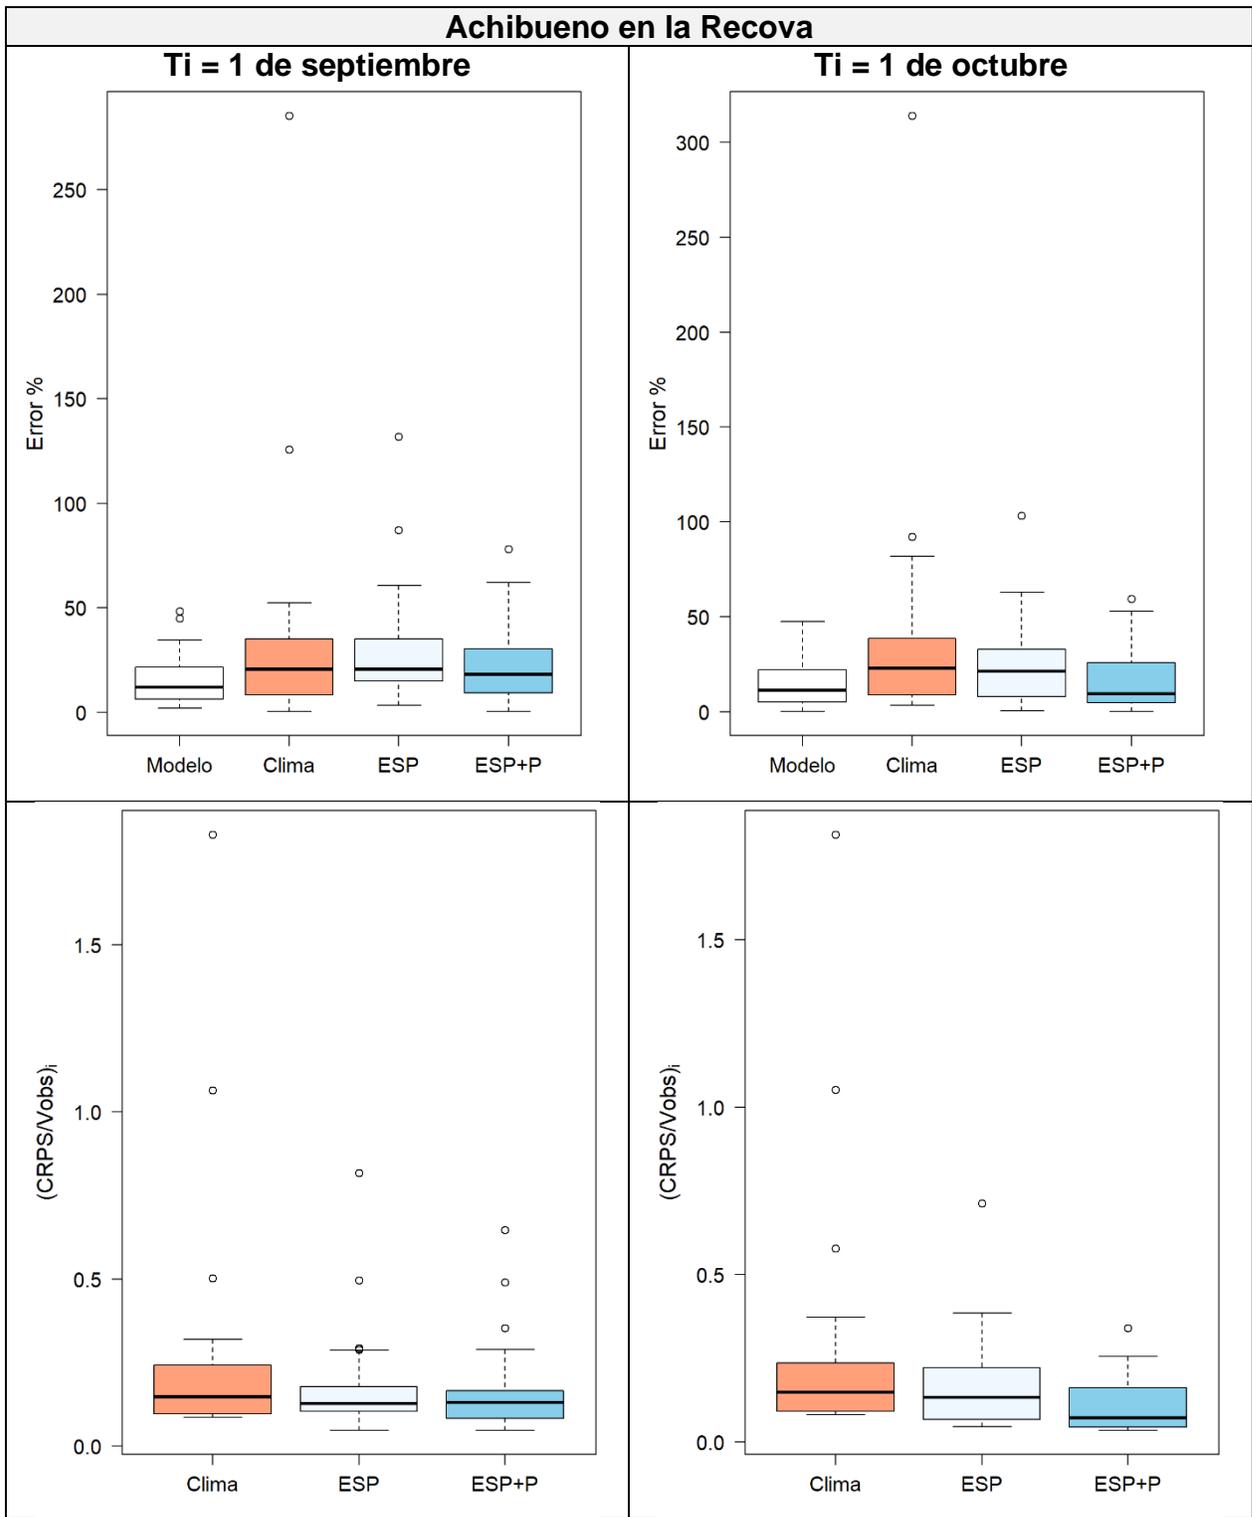


Figura G. 2 Resumen errores Achibueno en la Recova.